



UNIVERSIDADE FEDERAL DO AMAZONAS
FACULDADE DE TECNOLOGIA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

INSPEÇÃO DE FALHAS EM CONECTORES PTH DE PLACAS DE
CIRCUITO IMPRESSO UTILIZANDO MACHINE LEARNING

Jorge Eduardo Santos Penedo

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, PPGEE, da Universidade Federal do Amazonas, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Waldir Sabino da Silva Júnior

Manaus
Julho de 2025



Ministério da Educação
Universidade Federal do Amazonas
Coordenação do Programa de Pós-Graduação em Engenharia Elétrica

FOLHA DE APROVAÇÃO

Poder Executivo Ministério da Educação
Universidade Federal do Amazonas
Faculdade de Tecnologia
Programa de Pós-graduação em Engenharia Elétrica

Pós-Graduação em Engenharia Elétrica. Av. General Rodrigo Octávio Jordão Ramos, nº 3.000 - Campus Universitário, Setor Norte - Coroado, Pavilhão do CETELI. Fone/Fax (92) 99271-8954 Ramal:2607. E-mail: ppgee@ufam.edu.br

JORGE EDUARDO SANTOS PENEDO

INSPEÇÃO DE FALHAS EM CONECTORES PTH DE PLACAS DE CIRCUITO IMPRESSO UTILIZANDO MACHINE LEARNING

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica na área de concentração Controle e Automação de Sistemas.

Aprovada em 21 de julho de 2025.

BANCA EXAMINADORA
Prof. Dr. Waldir Sabino da Silva Júnior- Presidente
Prof. Dr. Gabriel Matos Araújo - Membro Titular 1 - Externo
Prof. Dr. Celso Barbosa Carvalho- Membro Titular 2 - Interno

Manaus, 14 de julho de 2025.



Documento assinado eletronicamente por **Gabriel Matos Araujo, Usuário Externo**, em 24/07/2025, às 10:15, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Waldir Sabino da Silva Júnior, Coordenador**, em 24/07/2025, às 10:30, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Celso Barbosa Carvalho, Professor do Magistério Superior**, em 24/07/2025, às 10:54, conforme horário oficial de Manaus, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufam.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2682127** e o código CRC **7D57BA5F**.

Av. General Rodrigo Octávio Jordão Ramos, nº 3.000 - Bairro Coroado Campus Universitário, Setor Norte
- Telefone: 99271-8954
CEP 69080-900 Manaus/AM - Pavilhão do CETELI. E-mail: ppgee@ufam.edu.br

Referência: Processo nº 23105.025766/2025-91

SEI nº 2682127

Ficha Catalográfica

Elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

- P398i Penedo, Jorge Eduardo Santos
Inspeção de falhas em conectores PTH de placas de circuito impresso
utilizando machine learning / Jorge Eduardo Santos Penedo. - 2025.
59 f. : il., color. ; 31 cm.
- Orientador(a): Waldir Sabino da Silva Júnior.
Dissertação (mestrado) - Universidade Federal do Amazonas, Programa
de Pós-Graduação em Engenharia Elétrica, Manaus, 2025.
1. máquina de vetores de suporte. 2. k-vizinhos mais próximo. 3. árvore
de decisão. 4. aprendizado de máquina. 5. modos de falhas. I. Silva Júnior,
Waldir Sabino da. II. Universidade Federal do Amazonas. Programa de
Pós-Graduação em Engenharia Elétrica. III. Título
-

*Gostaria de expressar minha
gratidão...*

Agradecimentos

Primeiramente ao meu grande amigo e aliado Deus por me conceder o dom da vida, saúde plena e pelas oportunidades que me concede ao longo de minha vida, gratidão eterna às pessoas que estiveram ao meu lado ao longo da minha jornada, a minha mãe, meu pai, minha filha Jehovahnna, Marcia Costa e ao tio Sávio, pela ajuda e incentivo nos momentos difíceis, aos meus irmãos/amigos Carlos Américo, Eugenio Gomes e Eliton Smith que deram a mão e apoio nas dificuldades, ao professor Cleonor Neves e ao meu orientador Professor Waldir Sabino, pelas orientações repassadas. Aos meus colegas de trabalho que nas últimas semanas ficaram no apoio das tarefas laborais.

Resumo da Dissertação apresentada à UFAM como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica

INSPEÇÃO DE FALHAS EM CONECTORES PTH DE PLACAS DE CIRCUITO IMPRESSO UTILIZANDO MACHINE LEARNING

Jorge Eduardo Santos Penedo

Orientador: Waldir Sabino da Silva Júnior

Programa: Pós-Graduação em Engenharia Elétrica

A crescente eletrificação da indústria automotiva exige aprimoramento contínuo dos processos de controle de qualidade, com foco na detecção precoce de anomalias em componentes críticos. Esta dissertação apresenta o desenvolvimento de um modelo de aprendizado de máquina (ML, do inglês *machine learning*) para realizar predição de modos de falha nos terminais de conectores (PTH, do inglês *plated through-hole*) e parafusos de fixação em placas de circuito impresso (PCI, do inglês *printed circuit boards*). O modelo emprega técnicas de processamento de imagem e algoritmos de aprendizado de máquina para segmentar áreas de interesse e classificar defeitos, notadamente a ausência de terminais de conectores PTH. Um diferencial metodológico substancial foi a compilação de um banco de dados customizado, composto por 3800 imagens, que permitiu o treinamento de modelos com dados representativos das condições de produção. A integração do modelo em uma linha de produção real demonstra a viabilidade da automação da inspeção, prescindindo de intervenções manuais. Avaliações quantitativas revelaram desempenho superior dos modelos, com acurácias de 0,93% para KNN, Decision Tree e de 0,97% para SVM, significativamente mais altas que as obtidas por inspeções manuais. Qualitativamente, o modelo proporciona redução do tempo de inspeção e otimização da eficiência operacional, resultando na melhoria da qualidade final do produto e na mitigação de custos associados a retrabalho e paradas de linha.

Palavras-chave: máquina de vetores de suporte, k-vizinhos mais próximo, árvore de decisão, aprendizado de máquina, classificação, modos de falhas.

Abstract of Dissertation presented to UFAM as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering

FAULT INSPECTION IN PTH CONNECTORS ON PRINTED CIRCUIT
BOARDS USING MACHINE LEARNING

Jorge Eduardo Santos Penedo

Advisor: Waldir Sabino da Silva Júnior

Department: Postgraduate in Electrical Engineering

The increasing electrification of the automotive industry demands continuous improvement of quality control processes, focusing on the early detection of anomalies in critical components. This dissertation presents the development of a machine learning (ML) model to predict failure modes in plated through-hole (PTH) connector terminals and fastening screws on printed circuit boards (PCB). The model employs image processing techniques and machine learning algorithms to segment areas of interest and classify defects, notably the absence of PTH connector terminals. A substantial methodological advantage was the compilation of a custom database of 3,800 images, which allowed the training of models with data representative of production conditions. The integration of the model into a real production line demonstrates the feasibility of inspection automation, eliminating manual intervention. Quantitative evaluations revealed superior model performance, with accuracies of 0.93

Keywords: support vector machine, k-nearest neighbor, decision tree, machine learning, classification, failure modes.

Sumário

1	Introdução	1
1.1	Objetivos da Dissertação	2
1.1.1	Objetivo geral	2
1.1.2	Objetivos específicos	3
1.2	Justificativa	3
1.3	Revisão de Literatura	4
1.4	Estado da arte	4
1.5	Organização do trabalho	5
1.6	Resultados gerados pela dissertação	5
1.6.1	Patentes	6
1.6.2	Artigos	6
2	Fundamentos Teóricos	7
2.1	Processos Produtivos Industriais	7
2.1.1	Linha de Montagem	8
2.1.2	Tecnologia na Manufatura	8
2.1.3	Qualidade da Produção	8
2.2	Métodos FMEA	9
2.2.1	Análise de Modo de Efeitos de Falha	10
2.2.2	Análise Quantitativa FMEA	11
2.3	Placas de Circuito Impresso	12
2.3.1	Tecnologia THT	13
2.3.2	Tecnologia SMT	13
2.3.3	Componentes PTH	14
2.4	Processamento Digital de Imagens	14

2.4.1	Fundamentos da Imagem Digital	14
2.4.2	Aquisição de Imagens	15
2.5	Amostragem e Quantização de Imagens	15
2.6	Representação de Imagens Digitais	16
2.7	Segmentação	18
2.8	Limiarização	19
2.9	Pontos Chaves de Correspondência	20
2.9.1	Detecção e Descrição de característica	21
3	Metodologia	22
3.1	Diagrama de bloco	22
3.2	Coleta de imagens	23
3.2.1	Coleta de imagens – Iluminação	23
3.2.2	Coleta de imagens – Iluminação Dark Field	23
3.2.3	Coleta de imagens – Câmera	24
3.2.4	Coleta de imagens – Rotulação das imagens	26
3.3	Pré-processamento de imagens	27
3.3.1	Redimensionamento de imagens	28
3.3.2	Recorte de imagens	28
3.4	Segmentação	29
3.4.1	Extração e descrição de características	31
3.4.2	Divisão dos dados em conjuntos de treino, validação e teste	33
3.5	Escolha e Implementação do Modelo de Aprendizado de Máquina	34
3.6	Diagrama de bloco do treinamento do modelo	35
3.7	Escolha do modelo	35
3.7.1	SVM	35
3.7.2	Árvore de Decisão	36
3.7.3	KNN	36
3.8	Treinamento do modelo	37
3.8.1	Validação do modelo	37
3.9	Deploy	43

4	Procedimento Experimental	44
4.1	Experimento	44
4.1.1	Experimento de predição do modelo	45
4.1.2	Experimento com PCI em conformidade	47
5	Conclusão	51
5.1	Trabalhos Futuros	52
	Referências Bibliográficas	54

Lista de Figuras

1.1	PCI Reprovada na inspeção - modos de falha - ausência de terminal.	1
1.2	PCI Aprovada na inspeção - sem modos de falha.	2
2.1	Parte da tabela de análise de modos e efeitos de falhas FMEA.	10
2.2	Placas de Circuito Impresso - Fonte Manual IPCA-610H.	12
2.3	PCI com tecnologia THT - Fonte Manual IPCA-610H.	13
2.4	PCI com tecnologia SMT - Fonte Manual IPCA-610H.	13
2.5	Componenetes PTH - Fonte Manual IPCA-610H.	14
2.6	Geração de uma imagem digital. (a) imagem contínua, (b) imagem utilizada para ilustrar os conceitos de amostragem e quantização, (c) discretização da amplitude, baseado em Gonzalez 2009.	16
2.7	Representação matricial, (a) imagem, (b) níveis de cinza da região, baseado em Gonzalez 2009.	18
3.1	Diagrama do treinamento do modelo de aprendizado de máquina.	22
3.2	Iluminação dakk field.	24
3.3	Dispositivo para aquisição das imagens.	25
3.4	Rotulação de imagens.	26
3.5	Modo de falhas dos terminais e parafusos.	26
3.6	Recorte da área de interesse Figura 3.6(a) ilustra ausência de terminais, Figura 3.6(b) ilustra a presença de todos os terminais e os parafusos de fixação, Figura 3.6(c) ilustra ausência de terminais e de um parafuso e a Figura 3.6(d) ilustra a ausência de dois parafusos.	29
3.7	Área de interesse segmentada.	30
3.8	Extração de característica da ausência de terminais e um parafuso.	31
3.9	Extração de característica terminais e parafusos presentes.	32

3.10	Extração de característica terminais e parafusos presentes.	32
3.11	Extração de característica terminais e parafusos presentes.	33
3.12	Imagens do dataset.	33
3.13	Digrama de bloco do treinamento de aprendizado de máquina.	35
3.14	Divisão do conjunto de dados em treinamento, validação e teste.	38
3.15	Matriz de confusão do modelo KNN.	41
3.16	Matriz de confusão do modelo SVM.	41
3.17	Matriz de confusão do modelo de árvore de decisão.	42
4.1	Imagens utilizadas para testar a predição do modelo.	45
4.2	PCIs com modo de falhas.	47
4.3	PCIs sem falhas.	49

Lista de Tabelas

1.1	Tabela dos principais trabalhos relacionados.	4
1.2	Tabela das patentes geradas.	6
3.1	Conjunto de dados - Fonte o autor.	34
3.2	Definição das classes para treinamento do modelo – Fonte o autor. . .	34
3.3	Valores dos hiper parâmetros usados para treinar os modelos – Fonte o autor.	37
3.4	Matriz de confusão - Fonte o autor.	39
3.5	Métricas de classificação dos modelos de aprendizado de máquina. . .	42
4.1	Taxas de acertos - Fonte o autor.	49

Capítulo 1

Introdução

A indústria automobilística é um setor altamente dinâmico, que exige processos produtivos eficientes e controle rigoroso de qualidade para atender às crescentes demandas do mercado. A incorporação de sistemas eletrônicos avançados, como as centrais multimídia, aumenta a complexidade dos veículos e traz novos desafios relacionados à confiabilidade, especialmente nos terminais de conectores (PTH, do inglês *pin through hole*), componentes críticos para a integridade elétrica das placas de circuito impresso.

Falhas nos conectores PTH, decorrentes de processos inadequados de fabricação ou montagem, podem comprometer o desempenho e a segurança dos veículos. Por isso, o monitoramento e a inspeção automática desses componentes são essenciais para garantir a qualidade e prevenir falhas funcionais [1]. A Figura 1.1 ilustra PCI com modos de falha da ausência de terminal.

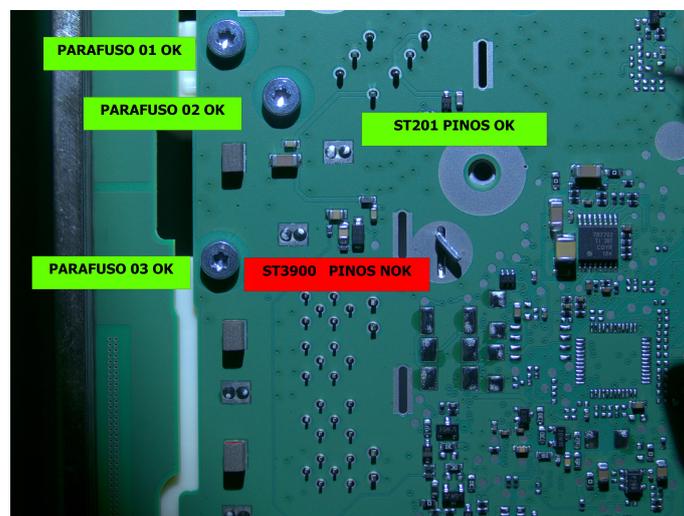


Figura 1.1: PCI Reprovada na inspeção - modos de falha - ausência de terminal.

Nesse cenário, o uso de técnicas de aprendizado de máquina (ML, do inglês *machine learning*) tem se destacado ao possibilitar a detecção precoce e precisa de defeitos sutis ou não evidentes a métodos tradicionais [2]. Ahmad e Rahimi [3] destacam o uso de tecnologias alinhada às demandas da indústria 4.0, pelo uso de automação e análise de dados em tempo real [1]. A Figura 1.2 ilustra PCI sem modos de falha.

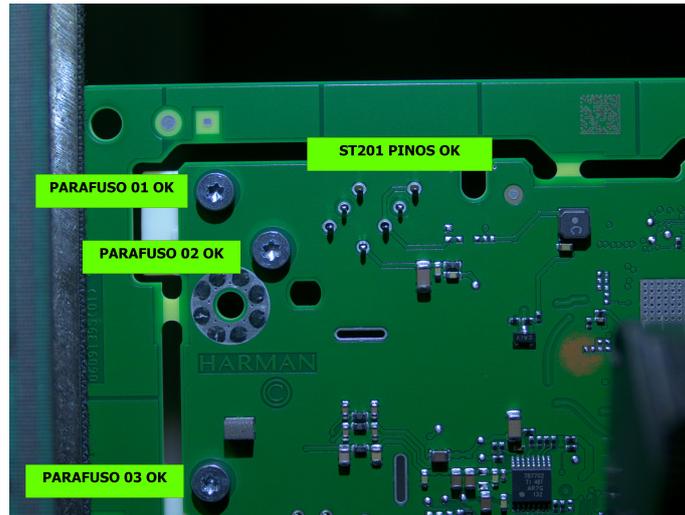


Figura 1.2: PCI Aprovada na inspeção - sem modos de falha.

O presente trabalho se propõe a explorar a aplicação de algoritmos de aprendizado de máquina para a predição de modos de falha em terminais de conectores PTH. Serão especificamente utilizados os algoritmos (SVM, do inglês *support vector machine*), (KNN, do inglês *k-nearest neighbors*) e (árvore de decisão, do inglês *decision tree*) para a classificação desses defeitos, visando aprimorar a precisão e eficiência dos processos de inspeção e controle de qualidade na indústria.

1.1 Objetivos da Dissertação

1.1.1 Objetivo geral

O objetivo principal deste trabalho é desenvolver um classificador de modo de falhas utilizando técnicas de aprendizado de máquina, com foco na realização de inspeção visual automática. A proposta visa explorar e implementar modelos de aprendizado de máquina capazes de classificar e detectar a ausência dos terminais de

conectores PTHS e parafusos. Espera-se, com isso, aumentar a eficiência, a precisão e a confiabilidade dos sistemas de controle de qualidade.

1.1.2 Objetivos específicos

- Definir os hiper parâmetros do modelo de aprendizado de máquina para cada um dos algoritmos, validando e armazenando os resultados obtidos.
- Implementar e analisar os resultados dos algoritmos para a classificação.
- Implementar e analisar os resultados dos algoritmos de classificação para predição do modo de falha.
- Obter um comparativo entre os resultados obtidos para diferentes algoritmos de aprendizado de máquina, demonstrando por meio de métricas o desempenho de cada modelo.

1.2 Justificativa

A crescente demanda por qualidade, confiabilidade e eficiência na produção de componentes eletrônicos tem impulsionado a adoção de soluções automatizadas nos processos de inspeção. Em particular, os conectores do tipo Plated Through Hole (PTH) representam elementos críticos em placas de circuito impresso, sendo amplamente utilizados em aplicações que exigem robustez mecânica e condutividade elétrica consistente, como na produção automotiva.

Os métodos tradicionais de inspeção, geralmente realizados de forma manual, são sujeitos à variabilidade humana como fadiga, que limitam a predição, e tendem a se tornar ineficientes frente ao aumento da complexidade e miniaturização dos componentes. Nesse contexto, a inspeção visual automática baseada em técnicas de aprendizado de máquina surge como uma alternativa promissora para superar tais limitações. Essa abordagem permite a detecção precisa e em tempo real da ausência de terminais de conectores PTH e parafusos, viabilizando a automação do controle de qualidade com maior consistência e velocidade.

1.3 Revisão de Literatura

A inspeção automática de componentes PTH emergiu como um campo de pesquisa de suma importância na indústria eletrônica. A demanda incessante por garantir a robustez, funcionalidade e longevidade dos produtos eletrônicos tem catalisado o desenvolvimento de técnicas e sistemas de inspeção cada vez mais sofisticados.

Para contextualizar o presente estudo e evidenciar sua originalidade e contribuições, foi realizada uma pesquisa de trabalhos correlacionados. Essa pesquisa permitirá mapear o estado da arte, identificando as principais abordagens adotadas, bem como as lacunas existentes na literatura e oportunidades para futuras pesquisas. Com isso, o escopo deste trabalho será claramente posicionado em relação aos esforços e avanços já estabelecidos na área. A Tabela 1.1 apresenta um resumo comparativo de cinco estudos relevantes, destacando suas técnicas e métricas.

Tabela 1.1: Tabela dos principais trabalhos relacionados.

Autor	Ano	Técnica	Tipos de defeito	Base	Acurácia
Chang-Yeh et al.	2024	YOLOv8	Furos passantes.	Própria	99,48%
Lingyun Zhu et al.	2025	SRN_Net	Furos ausentes.	Pública	0,79%
Bowen Liu et al.	2024	YOLOv5	Diversos.	Pública	99,6%
Kavindu Weerakkody et al.	2025	R-CNN	Diversos.	Kaggle	88,00%
Nils Hütten et al.		Diversas	Diversos.	Vários	75%

1.4 Estado da arte

O aprendizado de máquina emerge da necessidade de dotar os sistemas digitais da capacidade de processar e interpretar sinais e características presentes em imagens, impulsionando a evolução do setor automotivo no contexto da Indústria 4.0.

Na área da medicina, o uso do aprendizado de máquina tem avançado consideravelmente. Um exemplo notável é a aplicação desses algoritmos na classificação de dados de expressão genética para diagnóstico de câncer de pulmão [4]. Possibilitando ao profissional uma melhor precisão superior no diagnóstico do paciente.

No setor industrial, a adoção dessa tecnologia para controle de qualidade tem sido motivada pela busca por redução de custos de produção, minimizando tanto as paradas para retrabalhos quanto o desperdício de materiais, como o scrap. A implementação de sistemas de inspeção automática possibilita a inspeção em tempo real, além de prever falhas recorrentes, garantindo maior eficiência e qualidade na linha de produção.

No contexto da montagem de centrais multimídia, o aprendizado de máquina pode ser utilizado para avaliar a qualidade da montagem manual de componentes PTHs. Isso possibilita a detecção de falhas como ausência de terminais nos conectores e parafusos, garantindo maior precisão e confiabilidade no processo de produção.

1.5 Organização do trabalho

A organização deste trabalho é observada conforme a estrutura a seguir:

- No Capítulo 2, são revisados os conceitos fundamentais utilizados nesta dissertação. Englobando conceitos sobre os algoritmos de aprendizado de máquina e treinamento de modelos. A seguir, são abordados os conceitos-chave que implicam na complexidade e motivações para o uso de aprendizado de máquina no contexto de inspeção visual automática.
- No Capítulo 3, é apresentado o detalhamento sobre a metodologia utilizada para o desenvolvimento do modelo de aprendizado de máquina. Abordando a extração de características, segmentação e escolha do modelo de aprendizado de máquina.
- No Capítulo 4, é apresentado o detalhamento sobre os experimentos realizado para a predição do modelo de aprendizado de máquina.

1.6 Resultados gerados pela dissertação

Como resultado, esta dissertação gerou quatro patentes e dois artigos científicos publicados.

1.6.1 Patentes

As patentes, utilizadas como fonte técnica complementar, para contextualizar a pesquisa, definir o estado da arte e comprovar a originalidade da proposta. As patentes são apresentadas na Tabela 1.2.

Tabela 1.2: Tabela das patentes geradas.

Id	Título	Patente
1	Sistema inteligente para detecção de falhas utilizando algoritmo de máquina de vetores de suporte - SVM.	BR512025001172-5
2	Sistema inteligente para classificação de falhas na manufatura de placas utilizando algoritmo de Machine Learning KNN.	BR512025001171-7
3	Sistema inteligente para detecção de falhas utilizando algoritmo de Árvore de Decisão.	BR512025001173-3
4	Sistema inteligente para classificação de defeitos na manufatura de placas com Rede Neural Convolutacional.	BR512025001170-3

1.6.2 Artigos

Esses artigos desempenham papel fundamental na consolidação e expansão do impacto da pesquisa, fortalecendo suas contribuições tanto no âmbito acadêmico quanto tecnológico. A seguir, apresentam-se os artigos publicados.

[1] C. A. D. S. Silva, J. E. S. Penedo, E. P. Paladini, e W. S. D. Silva Junior, “Smart-Inspection System on Assembly Process of Pin-Through Components Using Machine Learning”, ITEGAM, vol. 11, no 51, 2025, doi: 10.5935/jetia.v11i51.1525.

[2] Carlos Americo De Souza Silva, Edson Pacheco Paladini, Jorge Eduardo Santos Penedo, e Waldir Sabino Da Silva Júnior, “Digital and Smart Production Using Simulation Systems to Improve the Manufacturing Performance”, em Proceedings do Simpósio Brasileiro de Sistemas Elétricos, Manaus, AM, Brasil: SBA Sociedade Brasileira de Automática, out. 2023. doi: 10.20906/sbai-sbse-2023/3915.

Capítulo 2

Fundamentos Teóricos

Neste capítulo são apresentados os conceitos teóricos utilizados neste trabalho. Inicialmente, são introduzidos os processos produtivos industriais. Logo em seguida, é apresentado o método FMEA, modelagem e simulação digital, placa de circuito impresso, processo digital de imagens, amostragem e quantização de imagens, representação de imagens digitais e os processos de inspeção.

2.1 Processos Produtivos Industriais

A busca por resultados mais eficientes na gestão de produção tem levado a indústria a novas perspectivas, com a integração de tecnologias para a melhoria da produção de seus produtos. Os processos de manufatura vêm passando por diversas mudanças tecnológicas em seus processos tradicionais, integrando máquinas e ferramentas aos sistemas ciberfísicos.

Conforme Kusiak [5], a crescente complexidade e a busca por excelência na fabricação de produtos eletrônicos vêm mudando os processos de inspeção visual para a redução ou eliminação de falhas que agreguem valores ao produto produzido.

Na transformação da manufatura em produtos para atender a um determinado propósito, os processos, bem como suas estruturas de trabalho, vêm sendo cada vez mais otimizados para se adaptarem às suas funções pré-estabelecidas. As melhorias feitas nos processos de inspeção automática vêm se tornando cada vez mais confiáveis, permitindo sua adequação ou implantação em qualquer modelo de linha de produção [6].

2.1.1 Linha de Montagem

A linha de montagem é caracterizada pela união de duas ou mais peças, ou componentes que criam um produto, desta junção resultam os subsistemas que formam um produto final [7]. Que consistem no transporte de peças ou componentes de um posto para outro, tendo um ciclo de parada determinado em cada posto [8].

As linhas de produção são definidas conforme seu volume médio de bens ou de serviços. Conforme o pesquisador Debevec [9], os sistemas em jobbing lidam com uma grande variedade de produtos que são geralmente fisicamente menores, que têm um baixo volume de produção. Esta baixa se dá pelo compartilhamento dos recursos de produção. Já os sistemas em lote, segundo o pesquisador Kusiak [5], possibilitam um volume médio na produção de bens ou de serviços, onde cada lote segue uma determinada série de operações definidas em seu processo de produção, nesse modelo a próxima fase da produção só é iniciada a medida que as instruções anteriores forem concluídas.

2.1.2 Tecnologia na Manufatura

Segundo [10], o uso da tecnologia na manufatura vem apresentando um crescimento significativo dentro da indústria. O uso de ferramentas tecnológicas, a cada dia, vem ganhando espaço dentro do chão de fábrica, fato que tem proporcionado uma crescente mudança no processo de produção industrial, exigindo estratégias para a implementação de novas soluções. Ebayyeh [11], destaca a importância da implementação de tecnologias avançadas de manufatura para o ganho de vantagem competitiva.

2.1.3 Qualidade da Produção

O emprego de padrões de qualidade vem sendo agregado como valor na produção de bens de consumo e, conseqüentemente, mudando a ideia de que a qualidade é o meio de minimizar defeitos nos processos de produção, tais mudanças tem feito as indústrias buscarem melhorias em seus padrões de qualidade para manterem a competitividade de seus produtos e conseguir, manter suas vantagens no mercado [8].

Segundo Yousaf [12], a qualidade do produto é um conjunto de características

que agrega conformidade, bem como as especificações do projeto ou produto, que são cada vez mais utilizadas para atender às exigências dos consumidores. Segundo Filz [13], as contribuições do uso da qualidade no processo fabril são significativas para o aumento de produtividade, a implementação ou melhorias na produção promovem benefícios, por meio da Análise de Modos e Efeitos de Falha (FMEA) para identificar e avaliar de forma abrangente falhas comuns no projeto e no processo de fabricação, com intuito de garantir a satisfação do cliente, redução dos índices de falhas e a confiabilidade do produto.

2.2 Métodos FMEA

Os desafios que a indústria tem em manter seus processos manuais sob controle são desafiadores. Paradas programadas para manutenções preventivas fazem parte do ciclo de produção industrial [14]. Conforme o pesquisador Filz [13], para que esse processo seja aceitável, o mínimo de falhas deverá ocorrer durante a montagem do produto na linha de produção. Por meio da eficiência da qualidade dos processos de inspeção, é possível reduzir as falhas na produção.

Segundo Yousaf [12], a qualidade e a confiabilidade vêm se tornando essenciais dentro dos processos de produção, mesmo que seu retrabalho ou reparo seja feito em um curto espaço de tempo.

Falhas na produção podem estar relacionadas ao não atendimento aos requisitos e/ou especificações do produto, ou serviço, sejam físicos ou lógicos. Isso leva a indústria a criar processos para discriminar os diversos tipos de falhas que possam existir na produção de um determinado produto, pois elas irão existir enquanto houver vida útil da produção desse produto [13].

Conforme o manual de análise do modo de falha e efeito (FMEA, do inglês *failure mode and effect analysis*), as falhas podem ocorrer por característica de projeto ou por falha operacional. Existem três formas de medir falhas, com uso de técnicas que compreendem as causas e modos de falhas e seus efeitos, com objetivo de conhecer todos os possíveis defeitos e avaliar quais os efeitos que estas falhas acarretam sobre os demais componentes. Buscando aumentar a confiabilidade dos produtos ou processo, tendo como objetivo final um produto livre de defeitos.

O manual FMEA AIAG&VDA 1ª edição é amplamente adotado pela indústria automobilística, a qual elaborou manuais específicos sobre seu uso e introduziu como requisito obrigatório em suas normas, estendendo-se para os fornecedores diretos da cadeia automotiva em seus produtos e processos [12].

O FMEA busca a prevenção de modos de falhas na produção e utilização do produto e, conseqüentemente, reduz custos operacionais e no desenvolvimento do produto. Conforme o manual FMEA, para obter um bom resultado em sua utilização é necessário identificar os possíveis tipos de falhas, descrever seus efeitos, as causas de cada modo de falha, calcular o risco para cada falha, o grau da severidade e a probabilidade de detecção e recomendar ações corretivas para as causas de falhas apontadas.

2.2.1 Análise de Modo de Efeitos de Falha

Conforme o manual FMEA, para cada modo de falha foram atribuídos três valores: a severidade do impacto do defeito (S), a ocorrência do modo de defeito (O) e a capacidade de detecção do defeito antes que ele ocorra (D). Com a multiplicação destes três valores, é gerado o valor do risco, conhecido como (NPR, do inglês *risk priority number*), ilustrado na Figura 2.1.

O FMEA é utilizado para avaliar falhas nos processos de produção que antecedem a liberação para a próxima etapa de produção em série, sendo necessária sua revisão durante toda a vida útil do produto, definidos para cada uma de suas características.

Etapa do processo	Processo / Função	Requisito	Modo Potencial de Falha	Efeito(s) Potencial(ais) de Falha	S E V	Causa(s) Potencial(ais) de Falha	Processo Corrente (Controles Preventivos)	D C O R	D E T	NPR	Ação Recomendada
130	Inserção Manual + Parafusamento + Clinch	Conector(es) com o comprimento do terminal dentro do especificado	Conector(es) com o terminal curto	Funções elétricas não OK	6	Máquina que realizar a pré-forma falhou	Instrução operacional	5	7	210	Não requer ação
130			Conector(es) com o terminal longo	Funções elétricas não OK	6	Máquina que realizar a pré-forma falhou	Instrução operacional	2	7	84	Não requer ação
130	Inserção Manual + Parafusamento + Clinch	Placa montada corretamente com os conectores na posição correta	Placa montada com conector(es) faltando	Funções elétricas não OK Interrupção do processo	6	Operador não montou o(s) conector(es)	Instrução operacional	2	4	48	Não requer ação
130			Placa montada com conector(es) mal posicionado	Funções elétricas não OK Processos subsequentes não podem ser realizados	6	Operador posicionou conector(es) incorretamente	Treinamento operacional	2	4	48	Não requer ação

Figura 2.1: Parte da tabela de análise de modos e efeitos de falhas FMEA.

A tabela de análise do modo de falha e efeito FMEA, mostrada na Figura 2.1, define os critérios de avaliação elaborados pela equipe multidisciplinar, para a etapa

do processo 130, para a montagem do produto produzido em uma fábrica automotiva instalada no polo industrial de Manaus. Foram adotadas as principais métricas da fábrica para a elaboração da análise qualitativa do processo de produção, descritas a seguir:

Etapas do processo: Nesta etapa, são listadas as não conformidades encontradas no processo analisado. Processo/Função: neste passo são listadas as funções realizadas no posto de montagem. Requisito: nesta fase são levantados os requisitos necessários para a montagem dos itens do processo. Identificar modo potencial de falha: identificadas as não conformidades, devem-se determinar quais os defeitos no produto que podem ser gerados nas respectivas operações. Identificar os efeitos do potencial de falha: por meio do conhecimento teórico ou prático, são identificados os efeitos que causarão cada falha ao cliente interno, bem como ao usuário final. Identificação das causas potenciais de falha: por meio do conhecimento prático, são identificadas as causas de cada falha. Identificar os meios de prevenção e detecção: após identificar as possíveis causas, é definida a forma de monitoramento do processo para a prevenção e detecção do defeito no produto ou a causa raiz do defeito.

2.2.2 Análise Quantitativa FMEA

A análise quantitativa do FMEA adotada nas etapas do processo foram três:

1) Severidade: Para definir o número da severidade, foi questionado o quanto de impacto da falha afetaria o cliente. O valor é atribuído de acordo com uma escala que varia de 1 a 10. Tendo 1 como impacto baixíssimo ao cliente e 10 como impacto altíssimo que afeta a segurança do cliente. 2) Ocorrência: A ocorrência é dada pela probabilidade de ocorrer o defeito. 3) Detecção: indica a probabilidade de detecção do defeito. Tendo 1 para uma grande probabilidade de detecção da falha e 10 para muito pequena de não detecção da falha.

Segundo o manual FMEA, o NPR é o resultado da multiplicação entre a severidade (S), ocorrência (O) e a detecção (D), resultando no limite do NPR, cuja definição é atribuída pela fábrica conforme a severidade. Se o resultado for maior que o limite, haverá a necessidade de uma ação.

Após a definição de todos os passos estipulados no formulário, as ações recomendadas devem ser definidas para redução ou eliminação das falhas.

2.3 Placas de Circuito Impresso

Segundo Seidel [15], as placas de circuito impresso (PCI, do inglês *printed circuit boards*) vêm sendo fundamentais para a produção de bens eletroeletrônicos. Sua utilização, segue especificações conforme a complexidade e empregabilidade a serem executadas.

Conforme Mallaiyan [16], as placas de circuito impresso, ilustrado na Figura 2.2 são fundamentais no cotidiano da sociedade. A PCI consiste em uma placa formada por camadas de fenolite, fibra de vidro ou outro material polímero, com finas camadas de substância metálica como cobre, prata, ouro ou níquel [17]. Essas camadas formam as trilhas, que servem como condutores de corrente elétrica para a alimentação e funcionamento dos componentes inseridos nas ilhas da PCI. Essas ilhas fazem parte das trilhas, com espaço suficiente para a junta de solda entre os terminais de cada componente e a PCI. Esses espaços podem ter furos para a inserção dos componentes com terminais (PTH, do inglês *through-hole technology*) ou sem terminais (SMD, do inglês *surface mounted device*) que podem ser inseridos diretamente sobre a superfície em ambos os lados da PCI [15].

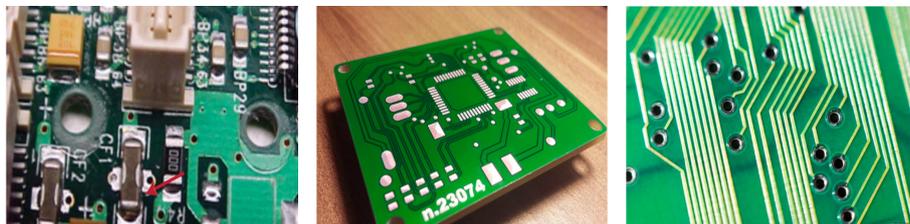


Figura 2.2: Placas de Circuito Impresso - Fonte Manual IPCA-610H.

Segundo Sobolewski [18], existem dois tipos de tecnologias relacionadas à fixação de componentes nas PCIs, a tecnologia (THT, do inglês *through-hole technology*) que vem sendo utilizada há várias décadas para montagem de equipamentos eletrônicos, e recentemente vem sendo adotada a tecnologia de montagem em superfície (SMT, do inglês *surface mounted technology*), a tecnologia THT ainda é amplamente usado na fabricação de dispositivos eletrônicos.

2.3.1 Tecnologia THT

Na tecnologia de furo passante THT. O primeiro procedimento que antecede na montagem de qualquer produto eletrônico é a definição do desenho da passagem da corrente elétrica que será utilizada, para a perfuração da placa e a criação das trilhas da PCI [15], ilustrado na Figura 2.3. Após essa fase, é possível realizar a montagem de qualquer equipamento usando componentes (PTH, do inglês *pin through hole*).

Segundo Hu [19], os sistemas baseados nesta tecnologia são fáceis de serem produzidos, porém, não são indicados para projetos, mais complexos, devido ao tamanho físico que a PCI possa ter e a dificuldade da alimentação dos componentes nas máquinas de inserção automática de componentes.

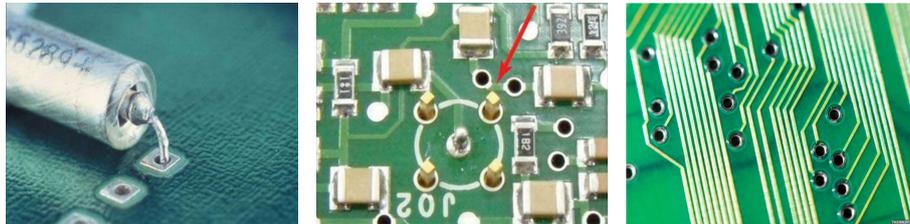


Figura 2.3: PCI com tecnologia THT - Fonte Manual IPCA-610H.

2.3.2 Tecnologia SMT

Na tecnologia de montagem em superfície SMT. Os componentes não possuem fios como terminais e a placa não necessita ser perfurada [15], ilustrado na Figura 2.4. Os componentes são posicionados em cima da ilha e então soldados. Segundo Shamkhalichenar [17], a tecnologia SMT possibilita uma alta densidade de componentes e suporta um alto desempenho. No entanto, sua manufatura e seus reparos são mais difíceis. Devido a este fato, torna-se necessário um alto investimento em equipamentos automatizados para inspeção e reparos.



Figura 2.4: PCI com tecnologia SMT - Fonte Manual IPCA-610H.

2.3.3 Componentes PTH

Segundo Ishak [20], os componentes eletrônicos com terminais PTH são inseridos por meio de um orifício feito na PCI. Esse tipo de componente possui terminais salientes e longos, e então soldados na outra face da placa para serem conectados ao circuito. Na Figura 2.5 é ilustrado o componente.

Conforme o pesquisador Shamkhalichenar [17], o uso de componentes PTHs vem sendo utilizado na maioria dos processos produtivos da indústria automobilística, feito em boa parte por meio de inserção manual, onde o componente é montado na placa por meio dos furos na PCI. Neste tipo de montagem, o componente possui um ou mais terminais que fazem a condução da corrente elétrica, que atravessam a PCI [15].

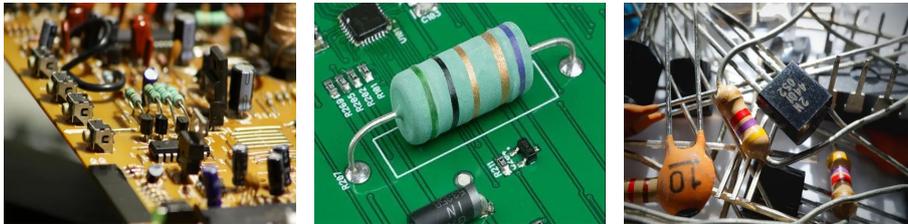


Figura 2.5: Componentes PTH - Fonte Manual IPCA-610H.

2.4 Processamento Digital de Imagens

2.4.1 Fundamentos da Imagem Digital

Uma imagem pode ser definida por meio da função $f(x, y)$, onde x e y são coordenadas espaciais, que têm como resposta um valor ou conjunto de valores para cada ponto no espaço x, y [21]. A imagem é considerada digital quando tanto x quanto y e os valores de $f(x, y)$ são finitos e discretos. Uma imagem digital é formada por um número finito de elementos, cada um com uma localização no espaço x, y e um valor atribuído. Conforme Alves [22], o processamento digital de imagens (PDI, do inglês *digital image processing*) é um ramo da computação aplicada que visa fornecer métodos e aplicativos para o tratamento de imagens digitais das mais diversas naturezas, que aumentam a capacidade de interpretação e extração de informações de uma determinada imagem.

2.4.2 Aquisição de Imagens

A aquisição da imagem representa a etapa inicial em um sistema de PDI, na qual uma cena capturada do ambiente real é convertida para o formato digital, servindo como base para todas as etapas subsequentes [22]. Esse processo envolve dois componentes principais, o sensor, que captura o sinal eletromagnético e o converte em um sinal elétrico correspondente e o digitalizador, responsável pela transformação desse sinal elétrico em dados digitais [21].

2.5 Amostragem e Quantização de Imagens

A amostragem e quantização são processos primordiais no processamento de imagens digitais. Utilizadas na representação de imagens contínuas de forma discreta das coordenadas espaciais quanto aos valores de brilho, possibilitando o armazenamento e o processo computacional de imagens captadas por meio de sensores [21]. A formação da imagem digital passa pela conversão dos dados capturados [23], a Figura 2.6 ilustra o processo de amostragem e quantização.

Na Figura 2.6(a) é exibida uma imagem contínua submetida ao processo de conversão de imagem digital. Os valores de x e y são coordenadas espaciais em um plano, as imagens são contínuas assim como sua amplitude [21]. As coordenadas representam o processo de amostragem da intensidade da imagem em pontos pré-definidos sendo efetuada de forma uniforme, tendo os seus espaçamentos iguais em todos os pontos da amostragem que ocorrem nas direções horizontais e verticais [24], atribuindo valores discretos para cada pixel da imagem, por meio da divisão do intervalo dos valores dos pixels em um número finito de níveis, atribuindo valores específicos, determinando a quantidade de níveis para a quantização determinar a precisão dos dados da imagem, é usualmente utilizado 8 bits para cada pixel da imagem, que equivale a 256 níveis possíveis entre zero que representa ausência de energia e 255 que representa a saturação [24]. A Figura 2.6(b) ilustra a amostragem e intensidade da imagem contínua em pontos pré-definidos, A energia incidente no sensor é contínua, sua representação na forma digital necessitaria de muita memória, nesse processo a quantização transforma um conjunto de cores em níveis de cinza com M elementos em um conjunto de N elementos, sendo $M > N$, na prática,

é armazenado apenas uma quantidade finita [25]. Na Figura 2.6(c) é ilustrada a imagem digital após a execução dos processos de amostragem e quantização.

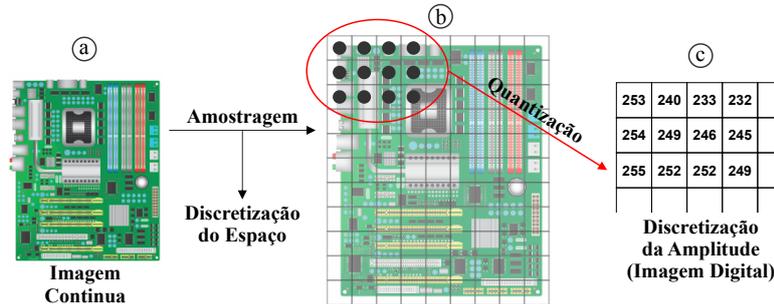


Figura 2.6: Geração de uma imagem digital. (a) imagem contínua, (b) imagem utilizada para ilustrar os conceitos de amostragem e quantização, (c) discretização da amplitude, baseado em Gonzalez 2009.

2.6 Representação de Imagens Digitais

Segundo [24] uma imagem em níveis de cinza é definida pela função $f(x, y)$ de intensidade luminosa, contendo M linhas e N colunas, tendo x, y como coordenadas discretas sendo definidas como variáveis e coordenadas espaciais que fornecem a intensidade ou brilho em um determinado ponto da imagem.

No momento em que uma imagem é gerada por meio de um processo físico, seus respectivos valores de intensidade são proporcionais à irradiação da energia gerada por uma fonte, tendo $f(x, y)$ diferente de zero e finito [21], ilustrada na equação (2.1).

$$0 < f(x, y) < \infty \quad (2.1)$$

A função $f(x, y)$ é expressa pela quantidade de luz que incide sobre um determinado objeto visto e pela quantidade de luz refletida em determinados pontos do objeto [26], que necessitam dos componentes de iluminação e refletância definidas por $i(x, y)$ e $r(x, y)$, o produto dessas funções geram o resultado da função $f(x, y)$ [21], ilustrada na equação (2.2).

$$f(x, y) = i(x, y) \cdot r(x, y) \quad (2.2)$$

$$0 < i(x, y) < \infty \text{ e } 0 < r(x, y) < 1 \quad (2.3)$$

Os valores da função $i(x, y)$ definem a iluminância recebida por meio de uma fonte de luz. A função de refletância $r(x, y)$ é gerada por meio da captura das características do objeto da cena [21]. A equação (2.3) ilustra que a reflectância está em absorção total 0 e em refletância total 1.

Como citado na Seção 2.5, para a transformação do sinal analógico obtido em uma imagem digital são necessárias realizar duas etapas. Na etapa da amostragem, a imagem analógica é convertida em uma matriz M por N onde cada elemento é uma aproximação do nível de cinza no ponto de amostragem para um conjunto de valores $(0, 1, \dots, L - 1)$ [24]. Conforme [21], é associado ao limite inferior 0 a faixa de níveis de cinza de um determinado pixel ao preto e ao limite superior $L - 1$ ao branco. Os pixels entre 0 e $L - 1$ são visualizados em diferentes tons de cinza. Os processos de aplicação de amostragem e quantização na imagem implicam na perda de informações da imagem analógica, a qualidade dos valores de M , N e L [24]. A equação (2.4) ilustra a representação de uma matriz $M \times N$.

$$f(x, y) = \begin{bmatrix} f(0, 0) & f(0, 1) & \dots & f(0, N - 1) \\ f(1, 0) & f(1, 1) & \dots & f(1, N - 1) \\ \cdot & \cdot & \dots & \cdot \\ f(M - 1, 0) & f(M - 1, 1) & \dots & f(M - 1, N - 1) \end{bmatrix} \quad (2.4)$$

Na quantização da imagem, é atribuído um valor inteiro a cada pixel entre o intervalo de 0 a $2^n - 1$, sendo que quanto maior o valor de n mais alto fica o seu nível de cinza presente na imagem digital [21].

Segundo [24] uma imagem digital é representada por meio de uma matriz bidimensional, onde cada pixel da imagem corresponde a um ponto da matriz. A

representação matricial da imagem é ilustrada na Figura 2.7, tendo uma área destacada para representar os níveis de cinza atribuídos aos pixels da imagem.

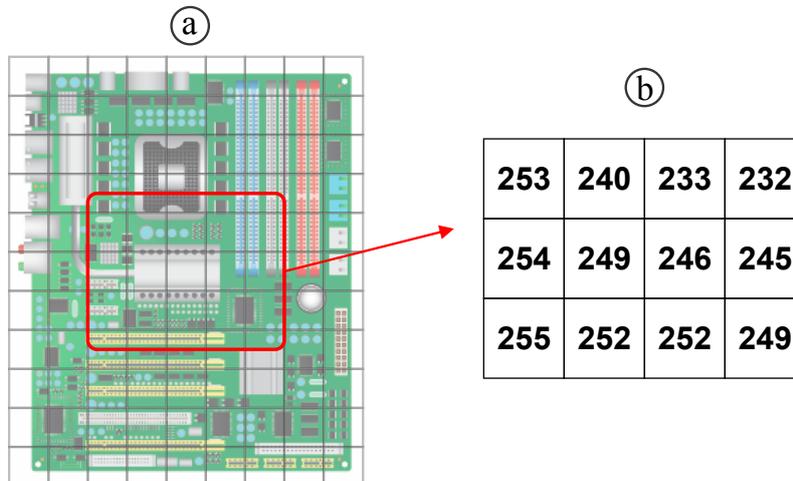


Figura 2.7: Representação matricial, (a) imagem, (b) níveis de cinza da região, baseado em Gonzalez 2009.

2.7 Segmentação

A segmentação refere-se ao processo de dividir uma imagem em áreas significativas, que podem incluir o primeiro plano, o fundo ou um objeto específico a ser identificado. Essas áreas são determinadas com base em atributos como cor, contorno ou similaridade entre os pixels [27].

A segmentação fundamentada na análise cromática depende diretamente da diferença significativa entre as tonalidades do objeto de interesse e do fundo [21]. Para tal, estabelece-se um limiar único ou uma faixa de valores que permite a categorização dos pixels, classificando-os como pertencentes ao primeiro plano, fundo ou objeto, conforme suas intensidades ou propriedades colorimétricas estejam acima, abaixo ou compreendidas dentro do intervalo definido. Adicionalmente, são aplicadas métricas de distância no espaço, como a distância euclidiana [21]. Essa distância é dada pela raiz quadrada da soma dos quadrados das diferenças entre as coordenadas correspondentes dos dois pixels, conforme ilustra a Equação 2.5. Essa técnica possibilita uma segmentação baseada na proximidade das cores dos pixels, assegurando uma delimitação precisa e consistente das regiões de interesse.

$$D_e(A, B) = \sqrt{(x_a - x_b)^2 + (y_a - y_b)^2} \quad (2.5)$$

Onde $D_e(A, B)$ representa o cálculo da distância euclidiana entre os pontos A e B, sendo x_a e y_a as coordenadas do pixel A e x_b e y_b as coordenadas do pixel B.

2.8 Limiarização

A segmentação por limiarização é uma técnica que classifica pixels com base em sua intensidade, utilizando um valor limiar T para separar regiões, geralmente gerando imagens binárias. Pode ser aplicada globalmente ou de forma adaptativa, ajustando-se a variações locais.

A limiarização global é fundamental que consiste em segmentar uma imagem digital em duas regiões principais objeto de interesse e fundo. Para isso, define-se um único valor limiar T aplicado a toda a imagem, de modo que os pixels cuja intensidade seja maior ou igual a T sejam classificados como pertencentes ao objeto, enquanto os demais são classificados como fundo. Essa operação resulta, em geral, em uma imagem binária, onde as regiões são claramente separadas com base nesse critério único de intensidade [21]. A Equação 2.1 ilustra o teste da função T .

$$T = f(x, y, p(x, y)) \quad (2.6)$$

em que $f(x, y)$ é o nível de cinza do ponto (x, y) e $p(x, y)$ denota alguma propriedade local do ponto. A limiarização da imagem é ilustrada na Equação 2.2.

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T \\ 0 & \text{se } f(x, y) < T \end{cases} \quad (2.7)$$

Os pixels rotulados como 1 correspondem ao fundo, enquanto pixels rotulados como 0 indicam o texto, considerando-se texto preto sobre fundo branco. Quando o valor do limiar T depende apenas da intensidade do pixel x, y , o limiar é chamado

global. Se T depender tanto da intensidade $f(x, y)$ quanto de propriedades locais $p(x, y)$, o limiar é denominado dinâmico, permitindo ajuste local e maior precisão em variações da imagem.

Entre os algoritmos mais utilizados para obter o limiar global destaca-se o método de Otsu, que determina o valor de T que maximiza a variância entre classes, ou seja, a separação estatística entre os pixels de objeto e fundo conforme seu histograma normalizado. De forma diversa, ao reduzir a soma da variância interna das classes, aumenta-se, de maneira implícita, a variância externa a elas, culminando em uma segmentação ideal. Tal metodologia se revela particularmente eficaz em imagens apresentando histogramas bimodais, nos quais existe uma nítida distinção entre os agrupamentos de pixels [28]. A Equação 2.8 ilustra a variância intraclasse.

$$\sigma_W^2 = W_b\sigma_b^2 + W_f\sigma_f^2 \quad (2.8)$$

Onde W representa o peso associado a cada classe, correspondendo à probabilidade de um pixel pertencer à classe de fundo ou à classe de primeiro plano. O ponto fundamental é que, em vez de calcular diretamente a complexa variância intraclasse, o método utiliza uma equivalência matemática que permite maximizar a variância interclasse, o que torna o procedimento mais eficiente.

2.9 Pontos Chaves de Correspondência

Na visão humana, a identificação e a caracterização de pontos-chave constituem etapas essenciais para a interpretação do ambiente ao redor. Esses pontos funcionam como marcos geométricos que auxiliam na distinção de contornos, formatos e limites dos objetos na cena, possibilitando ao cérebro processar e compreender o espaço de forma eficiente e precisa.

Em visão computacional, os pontos-chave são regiões de interesse que contêm informações essenciais e invariantes, fundamentais para reconhecimento e rastreamento. Esses pontos são selecionados conforme o problema, o que permite que sistemas processem às imagens de forma precisa e repetível [28].

2.9.1 Detecção e Descrição de característica

Os pontos-chave identificados em imagens possuem uma localização exata e estão normalmente relacionados a mudanças expressivas em atributos como intensidade, cor e textura. A técnica de descrição desses pontos consiste em atribuir-lhes características específicas, oferecendo não apenas a sua posição, mas também informações detalhadas sobre suas propriedades [29].

A descrição dos pontos-chave consiste na extração das características específicas de cada ponto para sua representação discriminativa e robusta. Diferentes algoritmos empregam abordagens variadas para essa descrição. Dentre eles, o algoritmo ORB destaca-se por sua eficácia e ampla aplicação na representação dos pontos-chave.

Capítulo 3

Metodologia

Este capítulo descreve os procedimentos metodológicos adotados para o desenvolvimento do sistema de inspeção visual automática baseado em aprendizado de máquina, voltado para a detecção da ausência dos terminais de conectores (PTH do inglês *plated through hole*). A pesquisa é de natureza aplicada, com abordagem quantitativa e delineamento experimental, tendo como objetivo principal a construção e validação de um classificador de falhas.

3.1 Diagrama de bloco

O processo de treinamento do modelo de aprendizado de máquina pode ser representado por meio de um diagrama de blocos, que descreve, de forma concisa, as principais etapas envolvidas na preparação e construção de um classificador. Sendo fundamental para garantir a ordem lógica e conduzir a implementação dos métodos adotadas. A Figura 3.1 ilustra o diagrama de bloco utilizado para a realização do treinamento do modelo de aprendizado de máquina.

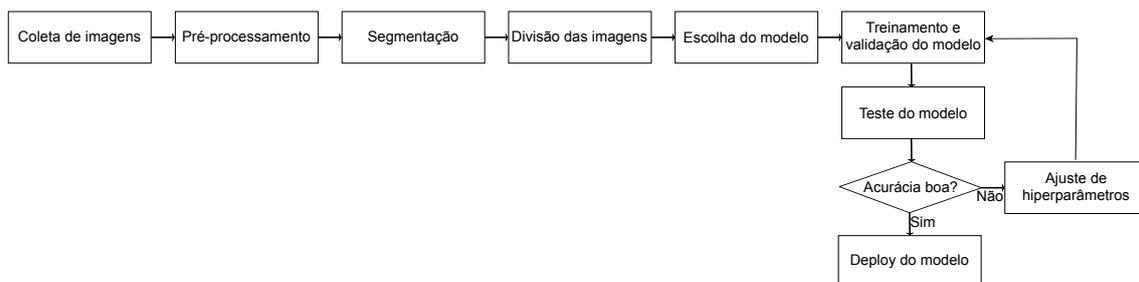


Figura 3.1: Diagrama do treinamento do modelo de aprendizado de máquina.

3.2 Coleta de imagens

A base de dados utilizada para o treinamento do modelo de aprendizado de máquina foi obtida diretamente de uma linha de produção automotiva, visando classificar falhas nos terminais de conectores de componentes PTHs. Para garantir que o conjunto de dados refletisse fielmente as condições reais de produção, ele foi organizado, abrangendo uma ampla variedade de cenários de falhas que podem ocorrer durante o processo de montagem.

3.2.1 Coleta de imagens – Iluminação

Para treinamento do modelo de aprendizado de máquina, especificamente os voltados para visão computacional, uma iluminação consistente e de alta qualidade é fundamental para reduzir sombra, ruído e aumentar o contraste que refletem diretamente no aprendizado e precisão do modelo [11]. A iluminação em um sistema de inspeção automática não se resume apenas ao tipo de luz utilizada, mas também à forma como ela incide sobre o objeto e à sua posição em relação à câmera [30]. A disposição da fonte de luz, deve ser planejada segundo os objetivos específicos da inspeção, a fim de otimizar os recursos computacionais [11]. Para a coleta das imagens foi utilizada a iluminação *dark field*.

3.2.2 Coleta de imagens – Iluminação Dark Field

A iluminação *dark field* ilumina o objeto lateralmente, deixando o fundo escuro e destacando os detalhes brilhantes do objeto. Sendo útil para realçar bordas, texturas e imperfeições em superfícies, sendo aplicada em inspeções de alta precisão, como na análise de superfícies metálicas. A Figura 3.2 ilustra a iluminação *dark light*.

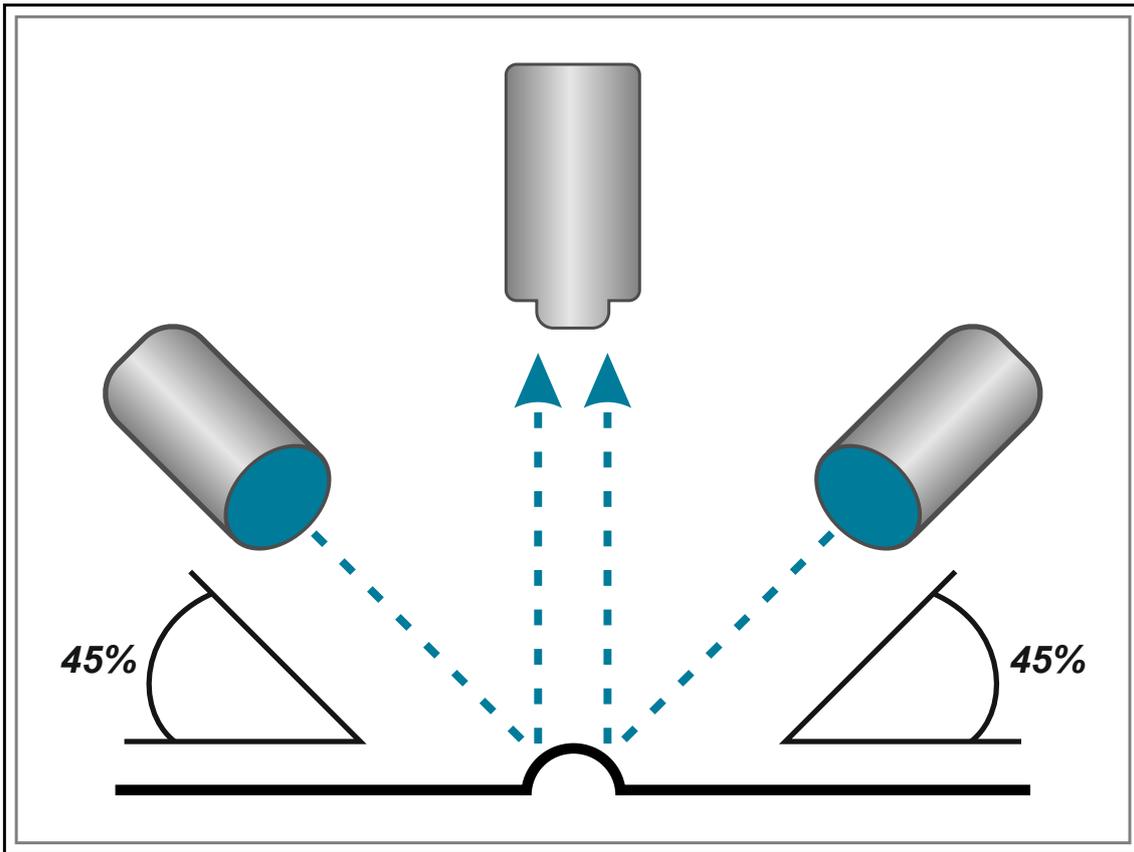


Figura 3.2: Iluminação dakk field.

3.2.3 Coleta de imagens – Câmera

A câmera desempenha um papel fundamental na captura de imagens. Sua importância vai além da simples tarefa de capturar uma imagem, a qualidade da imagem obtida depende do tipo de sensor escolhido que possibilita a captura de imagens com boa qualidade que têm impacto direto na precisão do modelo [30].

Os principais sensores utilizados para captura e conversão da imagem em sinais elétricos são o (CCD do inglês *charge-coupled device*) e o (CMOS do inglês *complementary metal oxide semiconductor*). Estes sensores operam utilizando o princípio de carga acoplada, ou seja, armazenam e convertem em sinal elétrico uma carga proporcional à intensidade luminosa à qual são expostos. Os sensores CMOS são mais rápidos que os CCDs apesar de resultarem numa imagem com menor qualidade e menos detalhes [31].

As imagens foram capturadas utilizando os mesmos parâmetros por meio de uma câmera Basler ace U acA4024-8gm equipada com sensor CMOS IMX226 com retroiluminação (BSI - Backside Illuminated) que possibilita melhorias na captação

de luz com altas taxas de transferências de dados. Este sensor oferece uma resolução de 12,2 megapixels (4024 x 3036 pixels) com tamanho de 1,85 μ m pixel, que possibilita a captura de detalhes do objeto que, por sua vez, atendem às exigências exigidas pelo cliente para processos de inspeção visual e análise de defeitos.

Neste contexto, foi desenvolvido um dispositivo in line na linha de produção para fixação da câmera Basler ace U acA4024-8gm e do projetor de iluminação Banner LEDWSM PresencePLUS 30mm spot Light White para realização da inspeção automática. As dimensões do dispositivo são de 100cm x 40cm, a câmera e o projeto de iluminação foram instaladas embaixo do conveyor da linha de produção tendo uma distância focal de 175mm entre a câmera e a PCI e o projetor foi instalado em uma posição angular de 45^o graus, tendo uma iluminação satisfatória no objeto da cena, possibilitando a captura de imagens com resolução de 4024x3036, com tempo de exposição do objeto de 6s, permitindo detalhes precisos dos terminais dos conectores e parafusos. A Figura 3.3 ilustra o dispositivo.



Figura 3.3: Dispositivo para aquisição das imagens.

3.2.4 Coleta de imagens – Rotulação das imagens

A rotulação de imagens consiste em associar a cada imagem ou a partes dela um rótulo que descreve seu conteúdo. Esse rótulo pode ser definido como uma classe, como "NOK" ou "OK" para que o modelo possa aprender a identificar padrões e fazer previsões baseadas nesses rótulos. A Figura 3.4 ilustra a rotulação de imagens.

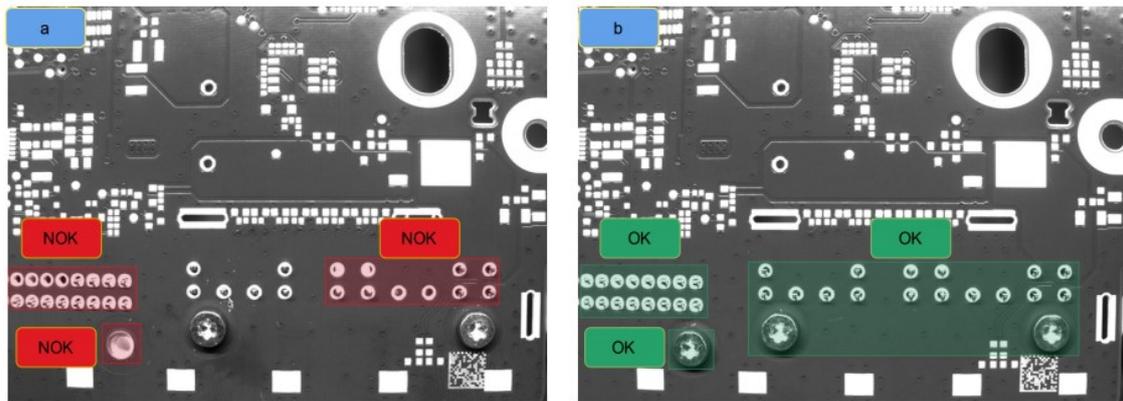


Figura 3.4: Rotulação de imagens.

O dataset de imagens possui 3800 imagens, que abrangem vários modos de falhas, como pinos e parafusos ausentes, falta de parafuso, ausência de pinos, parafusos e conectores, pinos ausentes e PCI com todos os conectores e parafusos inseridos, ilustrados na Figura 3.5.

Itens	Tipo de Defeitos	Imagens dos modos de falhas	Processo	Descrição	Especificação
1	Pino e parafuso ausentes.		Fundo	Nenhuma evidência de pinos e parafusos.	OK / NOK
2	Parafuso faltando.		Fundo	Parafusos faltando.	OK / NOK
3	Pino, parafuso e conector ausentes.		Fundo	Nenhuma evidência de projeção de pinos e falta de parafuso e conector.	OK / NOK
4	Pino ausente.		Fundo	Nenhuma evidência de projeção de pinos.	OK / NOK
5	PCI padrão.		Fundo	Placa padrão	OK / NOK

Figura 3.5: Modo de falhas dos terminais e parafusos.

A diversidade dos modos de falha presentes no dataset utilizado neste trabalho desempenhou um papel crucial no desenvolvimento de um modelo de aprendizado de máquina com elevada capacidade de generalização. Essa variedade de exemplos possibilitou o treinamento de um classificador satisfatório, capaz de classificar os diferentes modos de falhas ilustrados na Figura 3,5, mesmo diante de variações naturais nas imagens coletadas, como iluminação, ângulo de captura e pequenas diferenças de montagem.

Essa abordagem contribuiu significativamente no processo de inspeção de modo de falhas na ausência dos terminais dos conectores PTHs e parafuso de fixação na superfície da PCI, contribuindo para torna a inspeção automática mais eficiente, escalável e confiável.

Neste trabalho é importante destacar que o objetivo não está na identificação individualizada de cada modo de falhas específico, o que exigiria um processo altamente detalhado de rotulagem manual e conhecimento técnico aprofundado para discriminar nuances entre diferentes tipos de defeitos. Em vez disso, optou-se por uma abordagem baseada na abstração dos modos de falhas, direcionando a detecção de classes de anomalias associadas à ausência dos terminais dos conectores PTH e à ausência de parafusos de fixação na superfície da PCI. Essa estratégia reduz significativamente a complexidade envolvida nas etapas de anotação e treinamento, ao mesmo tempo, em que preserva a capacidade do sistema de identificar falhas com impacto direto na funcionalidade e na integridade do produto final. Dessa forma, a solução proposta revela-se prática, eficiente e altamente aplicável em cenários industriais reais, com a vantagem adicional de poder ser adaptada a diferentes modelos de placas ou linhas de produção, sem a necessidade de reconfigurações complexas ou retrabalho sistemático do modelo de inspeção.

3.3 Pré-processamento de imagens

O pré-processamento de imagens tem como principal função preparar as imagens de forma adequada, permitindo que sejam analisadas corretamente por algoritmos de extração de características. A imagem digital gerada durante a etapa de aquisição pode apresentar diversas imperfeições, como pixels com valores distorci-

dos, problemas de brilho ou contraste. Esses defeitos ou ruídos podem ser gerados pelo sensor de captura utilizado, iluminação do ambiente, condições climáticas no momento da captura e a posição relativa entre o objeto de interesse e o sensor [21]. O ruído não se limita a interferir no sinal da imagem, mas também pode comprometer a interpretação e o reconhecimento dos objetos nela presentes. A etapa de pré-processamento visa a aplicação de técnicas computacionais para aprimorar ou corrigir imperfeições nas imagens [11].

3.3.1 Redimensionamento de imagens

De acordo com [11], o redimensionamento de imagens é uma etapa fundamental no pré-processamento de dados. No aprendizado de máquina, essa prática é indispensável por diversos motivos, como a adaptação à arquitetura do modelo, a redução da complexidade computacional e a garantia de que o modelo consiga generalizar de maneira eficaz a entrada de dados de diferentes tamanhos.

3.3.2 Recorte de imagens

A etapa de recorte é fundamental para o processo de normalização, por meio desta técnica é possível eliminar artefatos indesejados que poderiam comprometer a qualidade dos dados, mas também preserva as informações e características essenciais dos dados, garantindo que a entrada de dados no modelo seja alimentada com informações relevantes e precisas. Esse refinamento aprimora a eficiência e a precisão dos processos subsequentes, otimizando a análise e a interpretação das informações do modelo.

Para a construção do dataset, foi aplicado o redimensionamento fixo, ajustando as imagens para uma dimensão constante de 2100 x 470 pixels, o recorte aplicado na imagem é ilustrado na Figura 3.6. Esse método é amplamente utilizado, pois garante que os dados de entrada apresentem tamanhos uniformes, facilitando o processamento e a predição do modelo [11]. A Figura 3.6 ilustra quatro recortes feitos nas imagens capturadas.

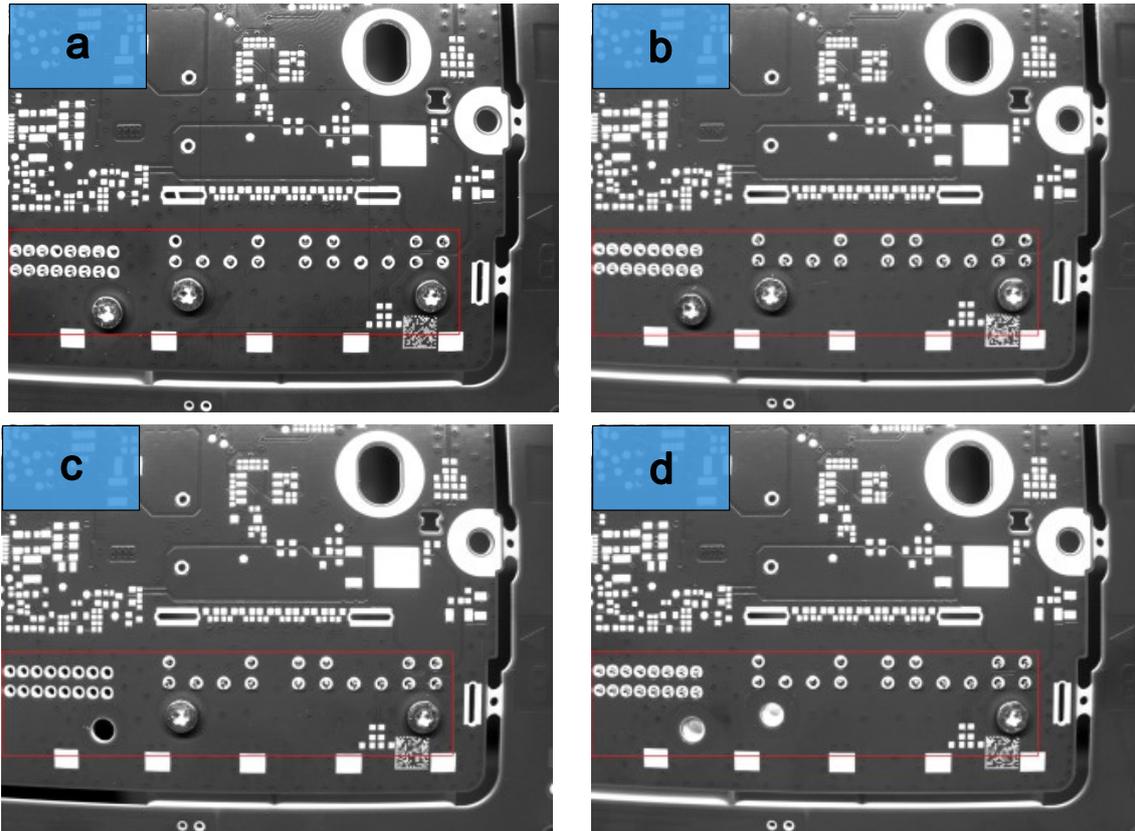


Figura 3.6: Recorte da área de interesse Figura 3.6(a) ilustra ausência de terminais, Figura 3.6(b) ilustra a presença de todos os terminais e os parafusos de fixação, Figura 3.6(c) ilustra ausência de terminais e de um parafuso e a Figura 3.6(d) ilustra a ausência de dois parafusos.

3.4 Segmentação

A segmentação é um processo que consiste em dividir uma imagem em regiões significativas, como o primeiro plano, fundo ou um objeto específico a ser detectado. Essas regiões são definidas com base em características distintas, como cor, bordas ou similaridade, que ajudam a destacar as partes relevantes da imagem [27].

Quando a segmentação é baseada na cor, sua eficácia depende da diferença significativa entre a cor do objeto de interesse e a cor do fundo [27]. Nessa abordagem, foi utilizado um limiar global único aplicado a todos os pixels da imagem com valor de 128 servindo como base para conversão do pixel em preto ou branco, se a intensidade do pixel da imagem estiver acima de 128 o pixel é convertido em branco e seu valor passa a valer 255, se o valor for menor de 128 o pixel é convertido em preto e seu valor passa a valer zero.

A Figura 3.6(a) ilustra uma imagem com ausência de terminais e parafuso, da qual desejasse isolar (segmentar) os terminais e parafusos do restante da imagem. Observa-se que quando há a ausência de terminais é segmentado tons brancos com mais relevância nos orifícios utilizados para a inserção dos terminais e tons escuros na ausência de parafusos.

A Figura 3.6(b) ilustra uma imagem com ausência de terminais e parafuso, da qual desejasse isolar (segmentar) os terminais e parafusos do restante da imagem. Observa-se que quando não há a ausência de terminais é segmentado tons mais escuros com mais relevância nos orifícios utilizados para a inserção dos terminais e tons claros quando não há ausência de parafusos.

A Figura 3.6(c) ilustra uma imagem com ausência de parafusos. Observa-se que quando há a ausência de parafusos é segmentado tons mais escuros com mais relevância.

A Figura 3.6(d) ilustra uma imagem com ausência de parafusos e terminais dos conectores. Observa-se que quando há a ausência de parafusos é segmentado tons mais escuros com mais relevância e tons mais claros nas áreas onde há ausência dos terminais.

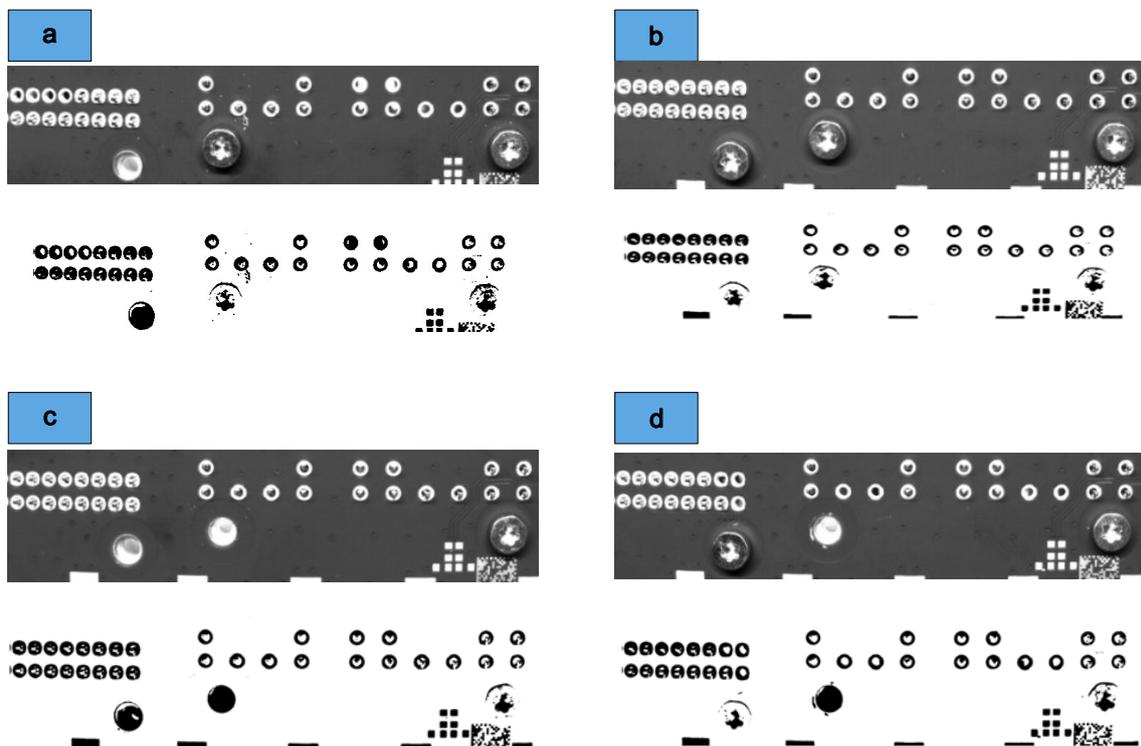


Figura 3.7: Área de interesse segmentada.

3.4.1 Extração e descrição de características

A extração e comparação de características são fundamentais para diversos problemas na área de visão computacional, como detecção e identificação de objetos [11]. Entre os principais algoritmos utilizados para extração e descrição de características o (ORB do inglês *oriented fast and rotated brief*) se destaca por sua eficiência em aplicações em tempo real, a escolha do algoritmo ORB foi selecionado devido ao seu custo computacional significativamente inferior em comparação com outros algoritmos de correspondência de imagens como (SIFT do inglês *scale invariant features transform*) e (SURF do inglês *speeded-up robust featuers*) [29].

Segundo [11], a extração de características ocorre após a segmentação e fornece dados essenciais para as etapas subsequentes, como classificação e análise. Com base nos objetos identificados durante a segmentação, é possível extrair diversas características da uma imagem como contorno, textura e área.

O algoritmo (ORB do inglês *oriented fast and rotated brief*) utiliza o descritor (BRIEF do inglês *binary robust independent elementary features*) e o detector de pontos-chave (FAST do inglês *features from accelerated segment test*) para a extração de características de imagens [29].

A Figura 3.8 ilustra a extração de características, da área de interesse da ausência de terminais e de um parafuso. Após o processo de extração, o BRIEF obtém todos as áreas importantes da imagem identificados pelo FAST e os transforma em vetores de características.

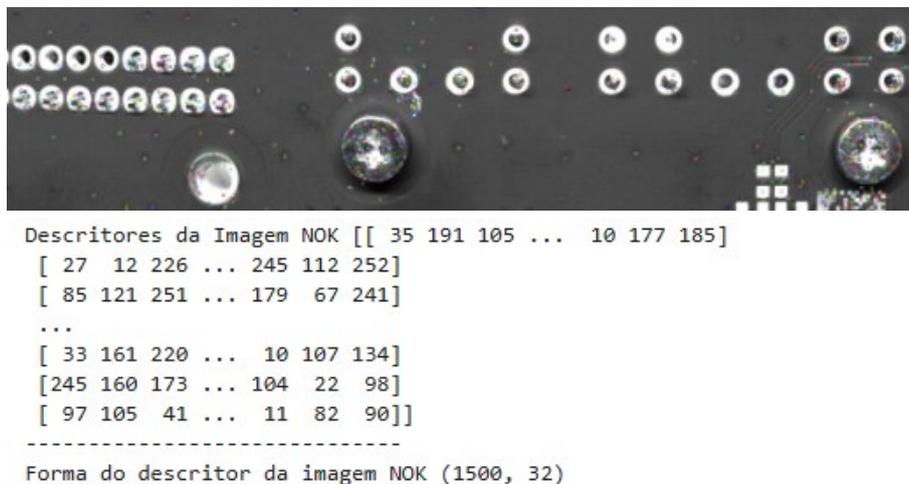


Figura 3.8: Extração de característica da ausência de terminais e um parafuso.

A Figura 3.9 mostra o processo de extração de características, da área de interesse ilustrando à presença dos terminais e dos parafusos. Após o processo de extração, o BRIEF obtém todos as áreas importantes da imagem identificados pelo FAST e os transforma em vetores de características.

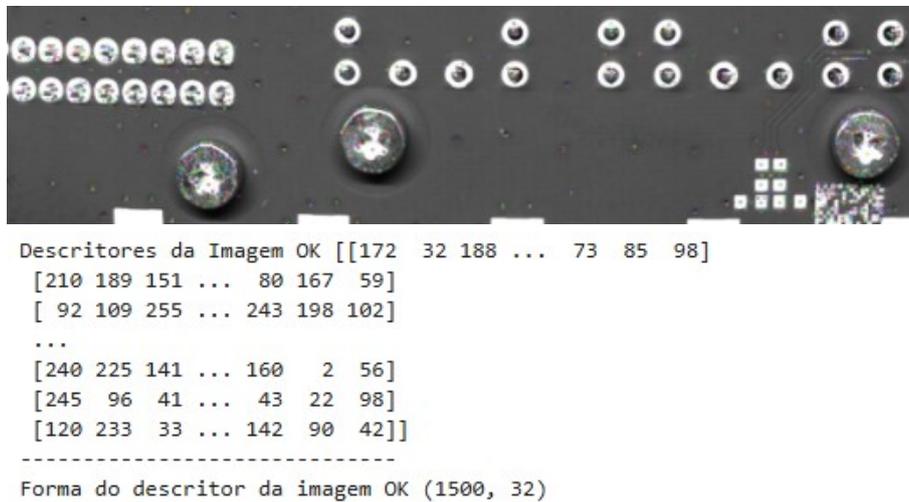


Figura 3.9: Extração de característica terminais e parafusos presentes.

A Figura 3.10 mostra o processo de extração de características, da área de interesse ilustrando à ausência dos parafusos. Após o processo de extração, o BRIEF obtém todos as áreas importantes da imagem identificados pelo FAST e os transforma em vetores de características.

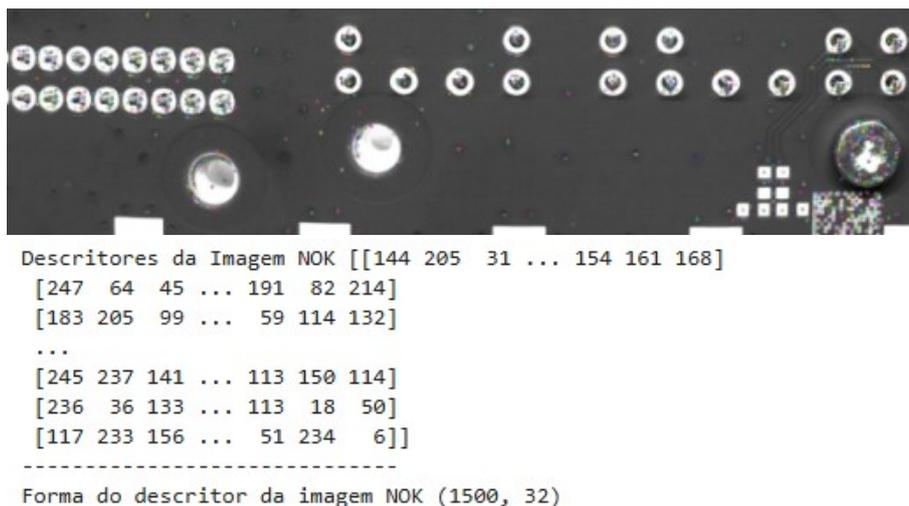


Figura 3.10: Extração de característica terminais e parafusos presentes.

A Figura 3.11 mostra o processo de extração de características, da área de interesse ilustrando à ausência de terminais e de um parafuso. Após o processo de

extração, o BRIEF obtém todos as áreas importantes da imagem identificados pelo FAST e os transformar em vetores de características.

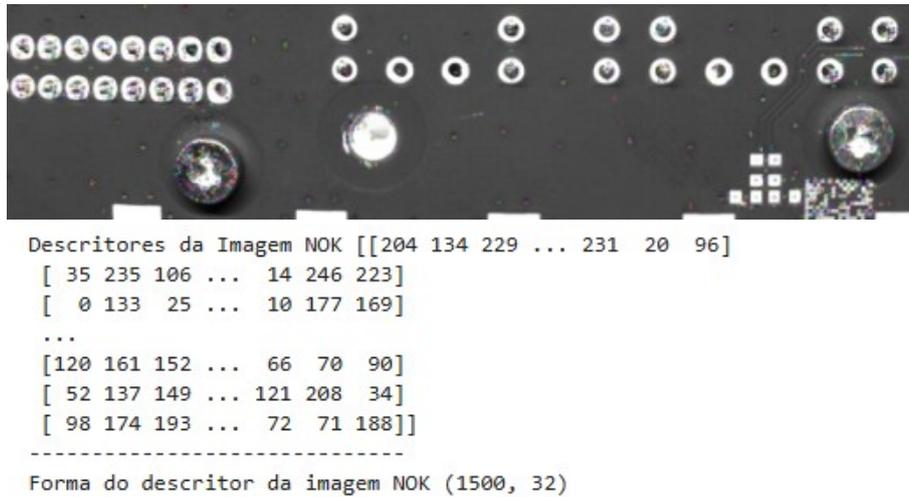


Figura 3.11: Extração de característica terminais e parafusos presentes.

3.4.2 Divisão dos dados em conjuntos de treino, validação e teste

A divisão de dados para classificação de imagens é um processo fundamental no treinamento de modelos de aprendizado de máquina, especialmente quando se trata de tarefas de classificação de imagens. Esse processo envolve separar um conjunto de imagens em diferentes subconjuntos para garantir que o modelo possa aprender de maneira eficaz e generalizar bem para novos dados [32].

O dataset foi criado usando uma janela deslizante com o tamanho de 2100×470 pixels sobre as imagens da PCI com 2590×1942 pixels. A janela é sobreposta sobre a área de interesse para posteriormente ser recortada e salva no dataset, a Figura 3.12 ilustra 4 imagens salvas no dataset após o processo de recorte da imagem.

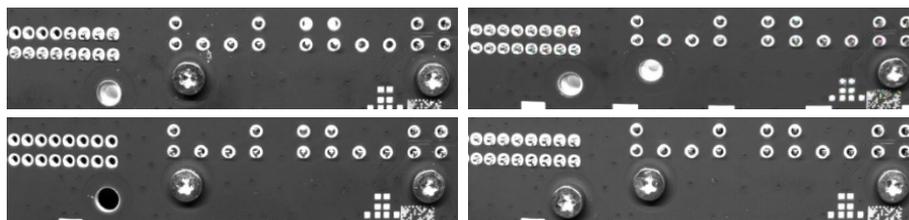


Figura 3.12: Imagens do dataset.

O conjunto de validação e o conjunto de treinamento foram divididos aleato-

riamente. A Tabela 3.1 ilustra o conjunto de dados de cada modo de falhas.

Tabela 3.1: Conjunto de dados - Fonte o autor.

Tipos de defeitos	Treinamento	Validação	Teste
Pino(s) e parafuso(s) ausente(s)	535	105	59
Parafuso ausente	535	105	59
Pino, parafuso e conector ausente	535	105	59
Pino ausente	535	105	59
Ok	765	150	85
Total	2907	570	323

Foram capturadas ao todo 3800 imagens de PCIs, divididos da seguinte forma, pinos e parafuso ausente(s): 535 imagens para treinamento, 105 para validação e 59 para teste, parafuso ausente: 535 imagens para treinamento, 105 para validação e 59 para teste, pino(s), parafuso(s) e conector(es) ausente(s): 535 imagens para treinamento, 105 para validação e 59 para teste, pino ausente: 535 imagens para treinamento, 105 para validação e 59 para teste, e 765 imagens sem defeitos, 150 para validação e 85 para teste. O conjunto de dados foi definido em 75% para treino, 15% do conjunto para validação e 10% para teste.

Para a detecção dos modos de falhas, considerou-se em criar apenas duas classes, as PCIs com modos de falhas serão representadas como classe NOK e OK para representar as PCIs sem defeito. A Tabela 3.2 ilustra as duas classes, e o quantitativo de imagens para treino, teste e validação dos classificadores.

Tabela 3.2: Definição das classes para treinamento do modelo – Fonte o autor.

Tipos de defeitos	Treinamento	Validação	Teste
Nok	2142	420	238
Ok	765	150	85
Total	2850	570	380

3.5 Escolha e Implementação do Modelo de Aprendizado de Máquina

Foram avaliados três algoritmos de aprendizado de máquina, com ênfase em SVM, KNN e árvore de decisão, devido à sua eficácia em tarefas de classificação de

imagens. O treinamento do modelo foi realizado com divisão do conjunto de dados em treino (70%), validação (15%) e teste (10%).

3.6 Diagrama de bloco do treinamento do modelo

No contexto desta pesquisa, o treinamento de modelos voltados à inspeção visual automática de modo de falhas nos terminais de conectores PTH e parafusos é representado por um diagrama dividido em cinco blocos principais: escolha do modelo, ajuste de hiper parâmetros, treinamento e validação do modelo, teste do modelo e deploy do modelo. A Figura 3.13 ilustra o diagrama de bloco.



Figura 3.13: Diagrama de bloco do treinamento de aprendizado de máquina.

3.7 Escolha do modelo

Nesta seção será fornecida uma breve contextualização das principais técnicas que serão aplicadas neste trabalho, como máquina de vetor de suporte (SVM do inglês *support vector machine*), K vizinhos mais próximos (KNN do inglês *k-nearest neighbors*) e árvore de decisão (do inglês *decision tree*). A escolha do modelo é uma etapa essencial no processo de treinamento do modelo, a escolha do modelo influencia diretamente no desempenho do modelo e sua capacidade de generalizar para novos dados [33].

3.7.1 SVM

As SVMs são definidas como uma técnica de aprendizado de máquina empregada em problemas de classificação e regressão [34]. Segundo [35], as SVMs consistem em encontrar um hiperplano ótimo que seja capaz de separar um conjunto de dados. Originalmente só era possível realizar apenas métodos de separação linear [36]. Conforme [4], é possível realizar a separação de classes não lineares, por meio da transferência dos dados com maior dimensão para serem separados linearmente.

O funcionamento de uma SVM pode ser descrito desta forma, dadas duas classes e um conjunto de pontos que pertençam a essas classes, a SVM irá determinar o hiperplano que irá separá-las de modo que os pontos pertençam a mesma classe, durante a maximização da distância de cada classe a esse hiperplano, a menor distância entre os pontos de cada classe e denominada de margem de separação [4]. A geração do hiperplano é determinada pelos subconjuntos dos pontos que forma as classes, que geram os chamados vetores de suporte [4].

3.7.2 Árvore de Decisão

As árvores de decisão são modelos não paramétricos baseados em paradigmas de aprendizagem supervisionado para classificação e previsão de dados [37]. Segundo [38] as árvores de decisão utilizam a estratégia de divisão, ou seja, o conjunto de dados de treino é decomposto em vários subconjuntos menores, até que um dos subconjuntos pertençam a mesma classe ou até que a classe seja a preponderante.

Os diversos subconjuntos obtidos da divisão resultam a construção da árvore de decisão por meio dos dados organizados de forma compacta utilizados para classificação de novos exemplos de forma recursiva que geram uma estrutura de dados [37], que corresponde um nó ou folha como uma classe ou um nó de decisão que pode realizar um teste sobre diversos atributos. Onde cada resultado cria uma aresta para uma nova subárvore [38].

3.7.3 KNN

O classificador KNN é um algoritmo de classificação clássico, que utiliza métodos de classificação não paramétricos, tendo como ideia básica a determinação de rótulos para as classes com base em seus k vizinhos mais próximos [39]. Que utiliza os K s pontos do conjunto de treinamento mais próximos a serem classificados que localiza K elementos do conjunto que tenham a menor distância.

3.7.3.1 Ajuste dos hiper parâmetros

Neste trabalho, foi utilizado o Grid Search para ajustar os hiper parâmetros do modelo, visando identificar de maneira eficiente, rápida e confiável a combinação ideal desses hiper parâmetros [33]. De acordo com [40], esse método é amplamente

utilizado na otimização de hiper parâmetros, avaliando diversas combinações para determinar quais parâmetros proporcionam os melhores resultados para o modelo. Esse processo é longo e requer um grande consumo de recursos computacionais. O conjunto de hiper parâmetros utilizados no treinamento do modelo são ilustrados na Tabela 3.3.

Tabela 3.3: Valores dos hiper parâmetros usados para treinar os modelos – Fonte o autor.

Modelo	Hiper parâmetros	Valores dos hiper parâmetros testados	Melhor hiper parâmetro
SVM	Kernel	rbf, linear, poly e sigmoid	rbf
	C	0.1, 1, 10, 100	0.1
	gama	0.0001, 0.001, 0.1, 1	0.0001
KNN	n-neighbors	De 1 à 50	16
Decision Tree	criterior: gini e entropy	[gini, entropy]	entropy
	max-depth: (1 - 10)	1, 10, 1	max-depth: 5

3.8 Treinamento do modelo

O treinamento de modelos de aprendizado de máquina é essencial para sistemas que usam inteligência artificial. Esse processo envolve o uso de um conjunto de dados para treinar o modelo de aprendizado de máquina [41]. A eficácia e a precisão do modelo estão relacionadas ao processo de treinamento [42]. De acordo com [41], o sucesso de um modelo não depende apenas da escolha do algoritmo adequado, mas também dos ajustes nos parâmetros que visam minimizar a função de custo durante a fase de treinamento, de modo a otimizar o desempenho do modelo e garantir sua capacidade de generalizar para novos dados.

3.8.1 Validação do modelo

Na fase de validação do modelo foi adotada a validação cruzada (do inglês *k-fold cross validation*), dividindo o conjunto de dados para treinar o modelo e ajustar seus parâmetros baseados nos dados de entrada, esse conjunto foi usado para avaliar o modelo durante a fase de treinamento, o uso do conjunto de validação permitiu que o modelo seja ajustado e otimizado antes da fase de teste do modelo. O conjunto de teste foi mantido separado dos outros conjuntos para garantir a imparcialidade da

predição do modelo. Os conjuntos de treinamento e validação são frequentemente usados de forma de validação cruzada [40]. A Figura 3.14 ilustra a separação do conjunto de dados.

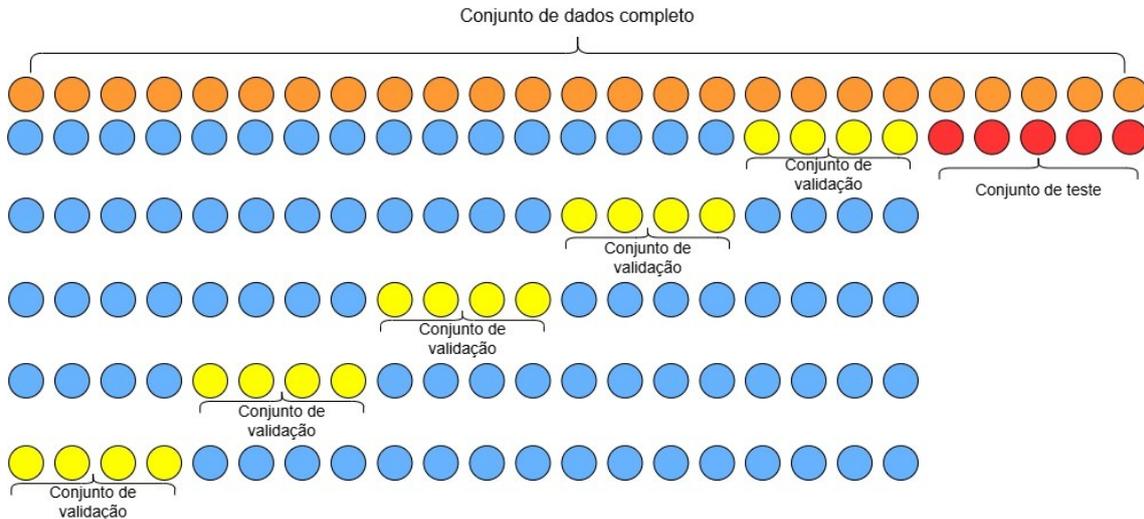


Figura 3.14: Divisão do conjunto de dados em treinamento, validação e teste.

3.8.1.1 Teste do modelo

O teste dos modelos de aprendizado de máquina são fundamentais na fase de criação do modelo, pois é por meio deste teste que se avalia a capacidade do modelo de generalizar para novos dados, ou seja, o teste realiza a predição do modelo por meio do conjunto de dados nunca visto em nenhuma fase da criação do modelo [43]. O objetivo principal do teste é verificar se o modelo aprendeu padrões relevantes durante o treinamento sem ter se ajustado excessivamente a detalhes específicos dos dados de treino, evitando o overfitting.

Conforme [43]. O conjunto de teste é um subconjunto do conjunto de dados original que não é utilizado na fase de treinamento do modelo. Seu principal objetivo é monitorar o desempenho e ajustar os hiper parâmetros do modelo. Essa etapa é essencial para o controle do sobre ajuste (overfitting), garantindo que o modelo tenha uma boa capacidade de generalização para novos dados.

A avaliação de desempenho no conjunto de validação pode ser realizada utilizando várias métricas, dependendo do tipo de problema e do modelo [43]. Segundo [43], a matriz de confusão é um dos métodos mais utilizados para avaliar métricas de algoritmos de aprendizado de máquina, assim como acurácia, preci-

são, recall e F1-Score, cujos valores são encontrados por meio da matriz de confusão [30] [43]. Ilustrada na Tabela 3.4.

Tabela 3.4: Matriz de confusão - Fonte o autor.

		Tem modo de falhas na imagem?	
		Sim	Não
modo de falhas foi detectado na imagem, pelo algoritmo?	Sim	Verdadeiro Negativos [TN] Inspeção OK	Falso Positivo [FP] Inspeção NOK
	Não	Falso Negativo [FN] Inspeção NOK	Verdadeiro Positivo [TP] Inspeção OK

Uma matriz de confusão permite realizar avaliação de modelos de classificação. Cada linha da matriz corresponde a uma classe real, enquanto cada coluna representa as previsões feitas pelo modelo para essas classes definidas no modelo. Por meio da matriz de confusão, podemos identificar não apenas a quantidade de acertos, mas também os de erros cometidos pelo classificador.

Na primeira linha da matriz de confusão, são representadas as classes negativas, ou seja, imagens que não pertencem à classe "OK". Representando as imagens classificadas corretamente como "NOK", sendo classificadas como verdadeiros negativos. No entanto, a variável FP classifica as imagens erroneamente classificadas como pertencentes à classe "OK", representando os falsos positivos. Esses erros indicam que o modelo classificou incorretamente como "OK" imagens que não pertencem a essa classe.

Na segunda linha, são representadas as classes positivas, ou seja, as imagens que realmente pertencem à classe "OK". A variável FN , representa as imagens classificadas incorretamente como "NOK", sendo chamadas de falsos negativos, que mostra uma falha do modelo em reconhecer a classe "OK". Já a variável TP representa as imagens que foram corretamente classificadas como "OK", representando os verdadeiros positivos.

Idealmente, um classificador perfeito apresentaria uma matriz de confusão com valores diferentes de zero apenas na diagonal principal, que vai do canto superior esquerdo ao inferior direito. Essa diagonal indicaria a quantidade de previsões corretas tanto para a classe negativa quanto para a classe positiva.

Para obter as métricas do desempenho dos classificadores foi utilizada as métricas de precisão, recall e pontuação F_1 . A precisão do modelo corresponde ao número de amostras positivas e negativas corretas, ilustrada na equação (3.1).

$$precisão = \left(\frac{TP}{TP+FP} \right) \quad (3.1)$$

O Recall, também conhecido como sensibilidade, mede a proporção de exemplos positivos que foram corretamente identificados pelo modelo, ilustrada na equação (3.2)

$$recall = \left(\frac{TP}{TP+FN} \right) \quad (3.2)$$

O F1-Score é a média harmônica entre a precisão e o recall, criando um equilíbrio entre essas duas métricas. Sendo muito útil quando se deseja levar em consideração tanto os valores falsos positivos quanto os falsos negativos, ilustrada na equação (3.3).

$$F_1 - Score = 2 \times \frac{precisão \times recall}{precisão + recall} = \frac{2TP}{2TP+FP+FN} \quad (3.3)$$

As métricas para o modelo KNN tiveram os seguintes resultados, 58 amostras da classe OK classificadas corretamente e 1 amostra classificada erroneamente, 46 amostras da classe NOK classificadas corretamente e 8 classificadas erroneamente, a matriz de confusão do modelo KNN é ilustrado na Figura 3.15.

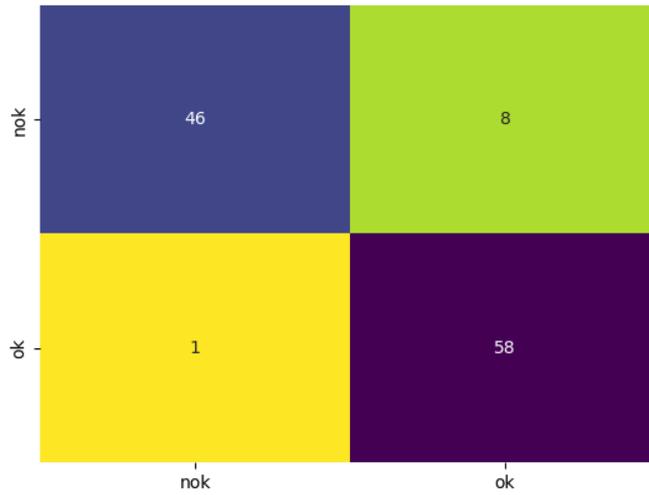


Figura 3.15: Matriz de confusão do modelo KNN.

As métricas para o modelo SVM tiveram os seguintes resultados, 59 amostras da classe OK classificadas corretamente e nenhuma amostra classificadas erroneamente, 50 amostras da classe NOK foram classificadas corretamente e 4 foram classificadas erroneamente, a matriz de confusão do modelo é ilustrado na Figura 3.16.

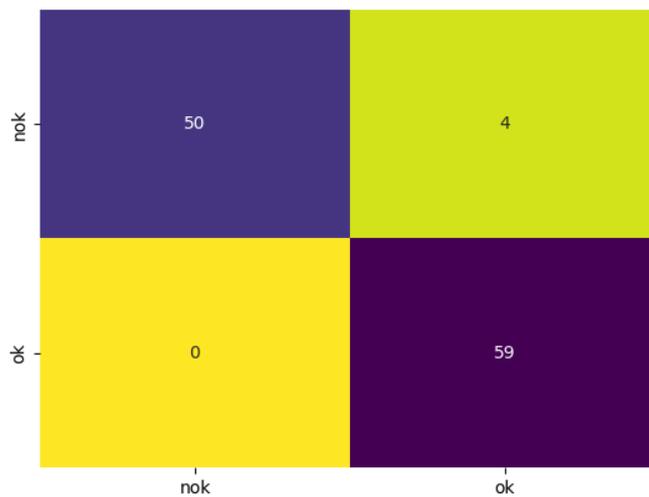


Figura 3.16: Matriz de confusão do modelo SVM.

As métricas para o modelo de árvore de decisão tiveram os seguintes resultados, 59 amostras da classe OK classificadas corretamente e nenhum classificada

erroneamente, 50 amostras da classe NOK foram classificadas corretamente e 4 classificadas erroneamente, a matriz de confusão do modelo é ilustrado na Figura 3.17.

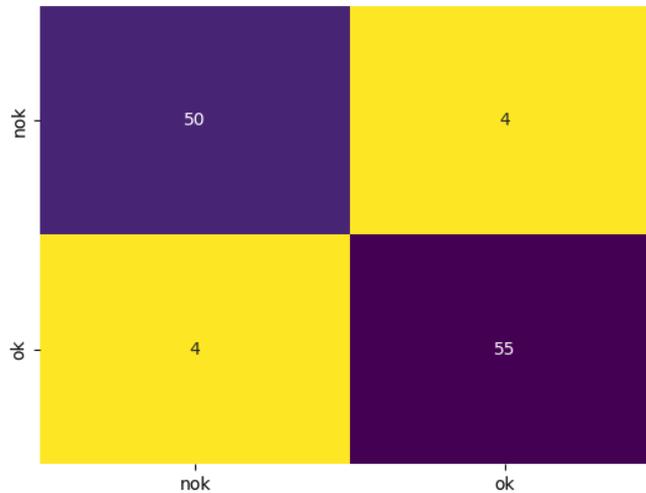


Figura 3.17: Matriz de confusão do modelo de árvore de decisão.

3.8.1.2 Métricas do modelo

Os resultados das métricas da precisão dos modelos de aprendizado de máquina são ilustrados na Tabela 3.5. Observa-se que o algoritmo SVM alcançou os melhores resultados de precisão na classificação dos modos de falhas, destacando-se em relação aos demais. Embora os classificadores KNN e árvore de decisão também tenham demonstrado desempenho satisfatório, com boa precisão na identificação dos modos de falha, a superioridade do SVM foi determinante para a sua seleção como modelo a ser implementado na linha de produção real em uma fábrica situada no polo industrial de Manaus.

Tabela 3.5: Métricas de classificação dos modelos de aprendizado de máquina.

Modelo	Precisão	RECALL	F1-score	Pontuação do conjunto de testes
SVM	0.99	0.99	0.99	0.98
KNN	0.92	0.91	0.91	0.91
Decision Tree	0.95	0.95	0.95	0.95

3.9 Deploy

O planejamento adequado da fase de implantação do deploy de modelos de aprendizado de máquina é uma etapa crítica em ambientes de produção real. A escolha da arquitetura impacta diretamente na performance, escalabilidade, latência e viabilidade operacional do sistema. Conforme discutido por [44], as duas arquiteturas de deploy mais comumente utilizadas são o offline e o online. A decisão entre uma e outra é guiada, sobretudo, pela natureza da aplicação e pela forma como as predições serão realizadas.

A implantação do deploy foi realizada de forma local, o que possibilita a execução direta do modelo na linha de produção real conectando os dispositivos industriais instalados no conveyor, garantindo seu uso em tempo real e a integração direta com o sistema de inspeção automatizada da linha de produção. Essa decisão foi tomada pela necessidade de baixa latência, controle do ambiente operacional e independência de conexões ou infraestrutura em *cloud*.

A implantação de modelos de aprendizado de máquina, em ambientes industriais, envolve a serialização do modelo criado, ou seja, a conversão de sua estrutura e parâmetros em um formato binário, foi utilizado o módulo pickle da linguagem Python. O pickle permite a transformação de modelos de aprendizado de máquina, vetores e pipelines em formato binário, para posteriormente armazená-los em disco, possibilitando que todo o fluxo de inferência seja preservado viabilizando que o modelo tenha portabilidade entre diferentes plataformas. Dessa forma o modelo poderá ser carregado e executado em um ambiente de produção, sem que seja necessário a reprodução do ambiente de desenvolvimento. Essa abordagem tornou o deploy mais modular e portátil. Com isso, tornou-se possível a aplicação prática do modelo treinado diretamente na linha de produção, possibilitando a automação do processo de inspeção e baixo custo computacional.

Capítulo 4

Procedimento Experimental

Neste capítulo, são apresentados os experimentos realizados e os resultados obtidos ao longo do desenvolvimento deste trabalho. Foram realizadas comparações entre os algoritmos de aprendizado de máquina utilizados nesse trabalho, considerando, critérios de acurácia e tempo de execução, visando avaliar sua predição para a classificação de dados de modos de falha da ausência de terminais dos conectores e parafusos.

4.1 Experimento

Nos experimentos, buscou-se desenvolver e avaliar um modelo de aprendizado de máquina para a detecção automática de falhas, com foco na ausência de terminais dos conectores PTHs e de parafusos. O principal objetivo foi avaliar a capacidade do modelo em generalizar a detecção de falhas por meio da análise de imagens em diferentes formatos e em escala de cores e em tonalidade cinza.

Foram utilizadas imagens de PCIs aleatórias para testar o modelo. A primeira imagem ilustrada na Figura 4.1(a), em escala de cinza, possui a ausência de alguns terminais, caracterizando uma placa com modo de falhas. A segunda imagem ilustrada na Figura 4.1(b), também em escala de cinza, representa uma PCI sem falhas, caracterizando uma placa sem modo de falhas. A terceira imagem ilustrada na Figura 4.1(c), colorida, possui a ausência de alguns terminais, caracterizando uma placa com modo de falhas. Por fim, a quarta imagem ilustrada na Figura 4.1(d), colorida, caracterizando uma placa sem modo de falhas.

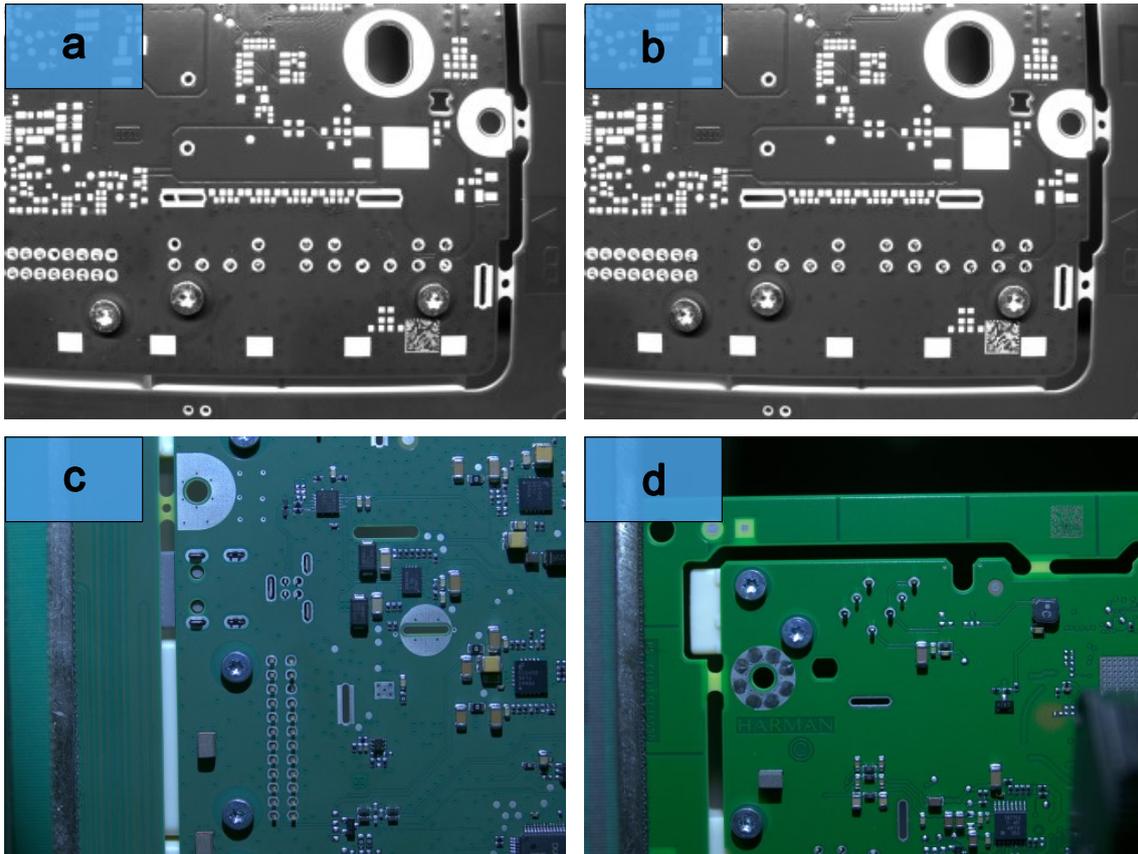


Figura 4.1: Imagens utilizadas para testar a predição do modelo.

4.1.1 Experimento de predição do modelo

Foi realizado o experimento para a detecção automatizada de modos de falhas de terminais e de parafusos de fixação. A falha em questão consiste na montagem incompleta da PCI, na qual um ou mais parafusos, ou terminais dos conectores, não são inseridos na montagem manual. A ausência compromete o correto posicionamento para a fixação da PCI no chassi da central multimídia, bem como seu funcionamento, além de representar riscos à confiabilidade do produto final.

Os experimentos foram conduzidos com base no modelo de classificação proposto na Seção 3.8.1.2, visando avaliar a eficiência da predição do modelo de modo de falhas. A principal finalidade desses experimentos é verificar a precisão do modelo quanto à capacidade de detectar corretamente diferentes tipos de modos de falhas. Ao término dos experimentos, será realizada uma análise comparativa dos resultados, com ênfase nas métricas de precisão, a fim de aferir a aplicação no ambiente de produção real.

- (i) O primeiro experimento foi baseado nos resultados obtidos durante o processo de predição. Observa-se que a precisão do modelo atingiu 0.9900734436119464% com predição para amostra de PCI defeituosas e 0,009926556388053636% de precisão para PCI sem defeitos. Esses valores indicam que o modelo possui alta capacidade de detecção correta dos modos de falhas para ausência de parafusos. A imagem avaliada, conforme previsto pelo classificador, foi rotulada como pertencente à classe NOK, reforçando a eficácia do modelo na detecção de anomalias em ambientes produtivos. A Figura 4.2(a) ilustra o resultado da predição do modelo;
- (ii) O segundo experimento foi baseado nos resultados obtidos durante o processo de predição. Observa-se que a precisão do modelo atingiu 0.9899952041561323% com predição para amostra de PCI defeituosas e 0.009926556388053636% de precisão para PCI sem defeitos. Esses valores indicam que o modelo possui alta capacidade de detecção correta dos modos de falhas para ausência de terminais dos conectores e parafuso. A imagem avaliada, conforme previsto pelo classificador, foi rotulada como pertencente à classe NOK, reforçando a eficácia do modelo na detecção de anomalias em ambientes produtivos. A Figura 4.2(b) ilustra o resultado da predição do modelo;
- (iii) No terceiro experimento, foi baseado nos resultados obtidos durante o processo de predição. Observa-se que a precisão do modelo atingiu 0.9906972456725405% com predição para amostra de PCI defeituosas e 0.00930275432745977% de precisão para PCI sem defeitos. Esses valores indicam que o modelo possui alta capacidade de detecção correta dos modos de falhas para a ausência só de terminais dos conectores. A imagem avaliada, conforme previsto pelo classificador, foi rotulada como pertencente à classe NOK, reforçando a eficácia do modelo na detecção de anomalias em ambientes produtivos. A Figura 4.2(c) ilustra o resultado da predição do modelo;
- (iv) No quarto experimento, foi baseado nos resultados obtidos durante o processo de predição. Observa-se que a precisão do modelo atingiu 0.9899998993471286% com predição para amostra de PCI defeituosas e 0.01000010065287164% de precisão para PCI sem defeitos. Esses valores indicam que o modelo possui alta

capacidade de detecção correta dos modos de falhas para a ausência de terminais dos conectores. A imagem avaliada, conforme previsto pelo classificador, foi rotulada como pertencente à classe NOK, reforçando a eficácia do modelo na detecção de anomalias em ambientes produtivos. A Figura 4.2(d) ilustra o resultado da predição do modelo.

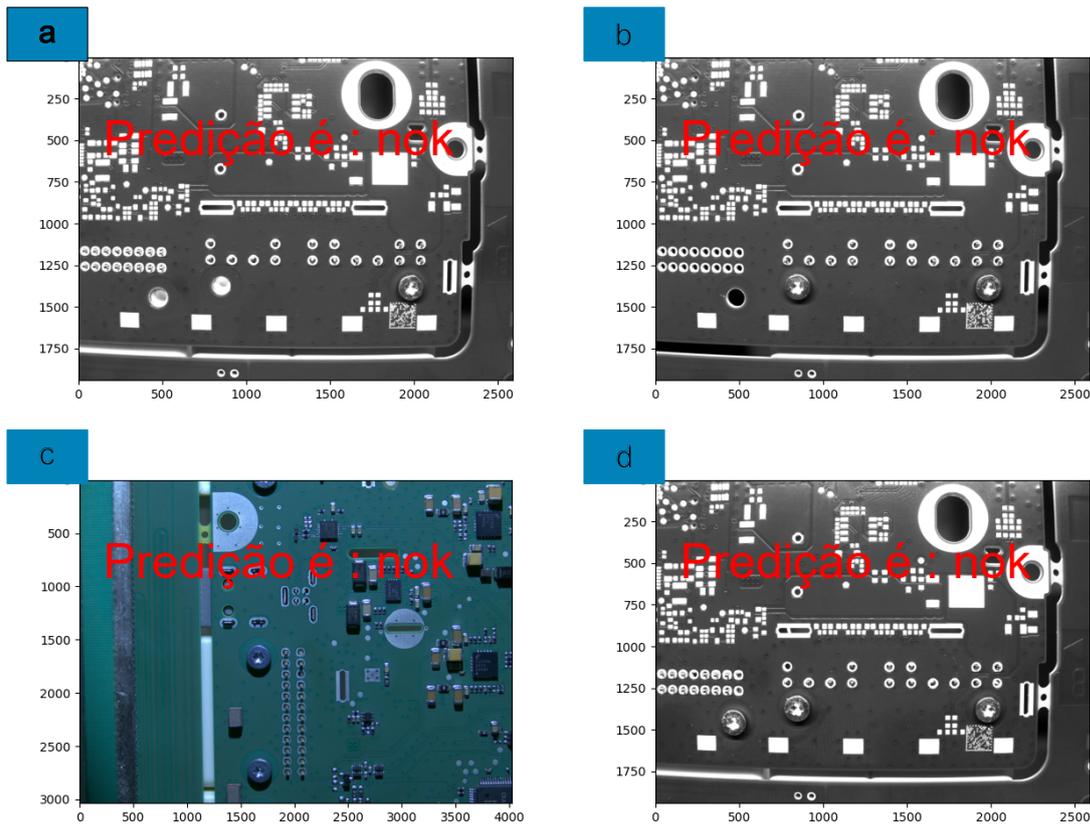


Figura 4.2: PCIs com modo de falhas.

4.1.2 Experimento com PCI em conformidade

Os experimentos realizados contemplaram a predição de imagens de PCIs isentas de defeitos visuais, tais como ausência de parafusos ou terminais. Essas imagens foram classificadas como exemplos de montagem correta, sem falhas aparentes, sendo utilizadas como referência positiva durante o processo de validação do modelo de aprendizado de máquina. Além de servirem como base para os testes, essas imagens desempenharam um papel fundamental como parâmetro de comparação, permitindo avaliar a capacidade do sistema em distinguir corretamente entre PCIs com e sem falhas. A Figura 4.3 ilustra PCI considerada livre de defeitos.

- (i) O primeiro experimento foi baseado nos resultados obtidos durante o processo de predição. Observa-se que a precisão do modelo atingiu 0.8672803890626826% de predição para amostra de PCI sem defeito e 0.13271961093731738% de precisão para PCI com defeito. Esses valores indicam que o modelo possui alta capacidade de detectar corretamente PCIs sem nenhum modo de falhas. A imagem avaliada, conforme previsto pelo classificador, foi rotulada como pertencente à classe OK, reforçando a eficácia do modelo na detecção de PCI em conformidade em ambientes produtivos. A Figura 4.3(a) ilustra o resultado da predição do modelo;
- (ii) O segundo experimento foi baseado nos resultados obtidos durante o processo de predição. Observa-se que a precisão do modelo atingiu 0.9914151072203354% de predição para amostra de PCI sem defeito e 0.008584892779664564% de precisão para PCI com defeito. Esses valores indicam que o modelo possui alta capacidade de detectar corretamente PCIs sem nenhum modo de falhas. A imagem avaliada, conforme previsto pelo classificador, foi rotulada como pertencente à classe OK, reforçando a eficácia do modelo na detecção de PCI em conformidade em ambientes produtivos. A Figura 4.3(b) ilustra o resultado da predição do modelo;
- (iii) No terceiro experimento, foi baseado nos resultados obtidos durante o processo de predição. Observa-se que a precisão do modelo atingiu 0.9668606888079414% de predição para amostra de PCI sem defeito e 0.03313931119205856% de precisão para PCI com defeito. Esses valores indicam que o modelo possui alta capacidade de detectar corretamente PCIs sem nenhum modo de falhas. A imagem avaliada, conforme previsto pelo classificador, foi rotulada como pertencente à classe OK, reforçando a eficácia do modelo na detecção de PCI em conformidade em ambientes produtivos. A Figura 4.3(c) ilustra o resultado da predição do modelo;
- (iv) No quarto experimento, foi baseado nos resultados obtidos durante o processo de predição. Observa-se que a precisão do modelo atingiu 0.976985355289966% de predição para amostra de PCI sem defeito e 0.023014644710033963% de precisão para PCI com defeitos. Esses valores indicam que o modelo possui alta

capacidade de detecção correta PCIs dos modos de falhas para a ausência de terminais dos conectores. A imagem avaliada, conforme previsto pelo classificador, foi rotulada como pertencente à classe OK, reforçando a eficácia do modelo na detecção de PCI em conformidade em ambientes produtivos. A Figura 4.3(d) ilustra o resultado da predição do modelo.

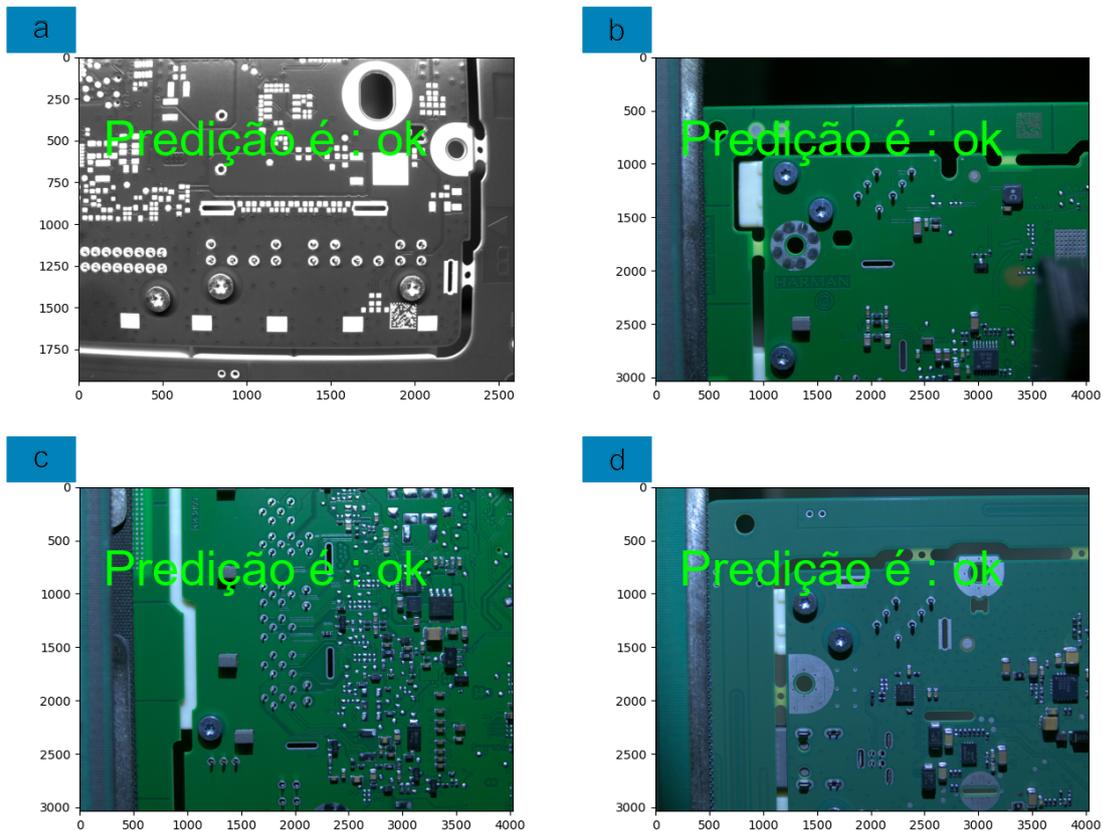


Figura 4.3: PCIs sem falhas.

Nos experimentos relacionados à detecção de modos de falha, foram analisadas 40 PCIs distintas sem falhas, bem como outras 30 contendo diferentes variações de modo de falhas. A Tabela 4.1 apresenta as taxas de acerto obtidas durante os testes.

Tabela 4.1: Taxas de acertos - Fonte o autor.

PCIs analisadas	Quantidade	VP	FN	FP	Precisão
NOK	40	38	0	2	95,0%
OK	30	29	0	1	96,66%
Total	70	67	0	3	95,71%

Conforme apresentado na Tabela 4.1, nos experimentos realizados com um conjunto de 70 PCIs contendo diferentes modos de falha, o modelo de aprendizado de máquina apresentou desempenho satisfatório, classificando corretamente a maioria das amostras. Apenas três PCIs foram erroneamente classificadas, o que representa uma taxa de erro pequena. As falhas na predição podem ser atribuídas à alta similaridade visual entre determinados modos de falha, o que pode ter dificultado a correta distinção por parte do modelo. Esses podem evidenciar a necessidade de estratégias complementares de pré-processamento ou aumento da base de dados para lidar com classes visualmente semelhantes.

Capítulo 5

Conclusão

Nesta dissertação, foram desenvolvidos, implementados e avaliados modelos de aprendizado de máquina para inspeção visual automática, com foco na detecção de falhas críticas em processos industriais eletrônicos, como a ausência de terminais em conectores PTH e parafusos de fixação em placas de circuito impresso. Os algoritmos SVM, KNN e Decision Tree foram analisados, treinados com dados reais coletados em ambiente fabril e comparados quanto a desempenho e aplicabilidade prática.

A abordagem metodológica adotada envolveu a preparação criteriosa dos dados, incluindo pré-processamento de imagens, extração de características relevantes, e divisão rigorosa dos conjuntos de treino e teste para validação robusta dos modelos. Foram aplicados processos de otimização de hiper parâmetros, tais como ajuste do kernel e regularização no SVM, seleção do número ideal de vizinhos no KNN, e entropia para controle de overfitting na árvore de decisão. Além disso, as métricas utilizadas para avaliação acurácia, precisão, recall e F1-score permitiram uma análise do desempenho dos classificadores, assegurando resultados confiáveis e relevantes para o ambiente industrial.

Os resultados evidenciam que o modelo SVM apresentou superioridade técnica, o modelo SVM. Em testes reais com inspeção automática de placas, o SVM alcançou uma acurácia média de 99%, com precisão de 99.5%, recall de 99% e F1-Score de 99,5%. O tempo médio para classificação foi de aproximadamente 35 ms por imagem, compatível com a velocidade exigida em linhas de montagem industriais.

K-Nearest Neighbors (KNN), apresentou acurácia média de 91%, precisão de

92%, recall de 91% e F1-Score de 91%. Contudo, devido à necessidade de calcular distâncias em tempo real, o tempo médio de inferência foi maior, cerca de 40 ms, o que pode limitar sua aplicação em produção de alta velocidade.

Decision Tree, com boa interpretabilidade, atingiu acurácia de 95%, precisão e recall ambos com 95%, e F1-Score de 95%. O modelo efetuou predições em cerca de 37 ms, combinando rapidez com facilidade para análise dos critérios de decisão.

A implementação desses modelos em ambiente industrial real, evidenciada pelos testes na linha de produção de uma fábrica de centrais multimídia localizada no polo industrial de Manaus, demonstrou a viabilidade técnica e operacional do sistema, evidenciando ganhos na padronização e confiabilidade da inspeção visual, além da redução do esforço humano e dos custos associados a retrabalhos e rejeições.

Esta dissertação contribui substancialmente para o avanço da automação industrial dentro do escopo da Indústria 4.0, mostrando como técnicas de aprendizado de máquina podem ser integradas a processos produtivos para garantir qualidade e responder às demandas de produtividade e flexibilidade.

Como perspectivas futuras, destaca-se a aplicação de redes neurais convolucionais (CNNs) e técnicas avançadas de aprendizado profundo para aprimorar ainda mais a acurácia e robustez na detecção de falhas, especialmente em componentes SMD cada vez mais miniaturizados e complexos. A integração desses modelos com sensores multissensoriais e a ampliação das bases de dados industriais são essenciais para o treinamento eficaz e adaptações específicas dos sistemas, garantindo escalabilidade e aderência a diferentes cenários produtivos.

Por fim, ressalta-se que a consolidação dessas tecnologias representa um avanço estratégico para a indústria eletrônica, promovendo maior competitividade, eficiência operacional e elevado padrão de qualidade, aspectos imprescindíveis para o crescimento sustentável no mercado globalizado.

5.1 Trabalhos Futuros

Os componentes SMD são elementos eletrônicos fixados diretamente sobre a superfície das placas de circuito impresso, eliminando a necessidade dos tradicionais furos característicos da montagem PTH. Essa evolução tecnológica possibilitou a

miniaturização dos circuitos, o aumento da densidade de componentes nas placas e a automação das linhas de produção, favorecendo a fabricação de dispositivos eletrônicos mais compactos. Diferentemente dos componentes PTH, os SMD possuem terminais curtos denominados pads que são soldados diretamente sobre a superfície da placa. Tal característica economiza etapas no processo de fabricação, pois elimina a necessidade de perfuração, além de reduzir efeitos indutivos e resistivos, melhorando o desempenho elétrico dos circuitos, especialmente em frequências elevadas. A diversidade dos componentes SMD é ampla e cobre resistores, capacitores cerâmicos e eletrolíticos, diodos, transistores bipolares, encapsulados em diferentes formatos como SOIC e BGA, entre outros. Essa variedade exige processos de montagem altamente controlados, que incluem a aplicação precisa de pasta de solda, posicionamento automático do componente e soldagem por refluxo térmico.

Dentro dos componentes SMD, destacam-se as bobinas, peças essenciais para funções como filtragem e ajuste de frequência, e a pasta térmica, aplicada especialmente sobre processadores para otimizar a dissipação do calor e garantir o desempenho e a durabilidade dos aparelhos. A pasta térmica é aplicada para garantir a eficiente dissipação desse calor, prevenindo o superaquecimento, o que pode comprometer o desempenho e a durabilidade dos dispositivos. A correta aplicação e inspeção da pasta térmica são essenciais para assegurar a integridade térmica e funcional dos equipamentos eletrônicos.

Nesse cenário, os avanços tecnológicos apontam para o uso das Redes Neurais Convolucionais (CNNs) como uma solução avançada para a inspeção automatizada da aplicação da pasta térmica e componentes associados, como bobinas. As CNNs são modelos de aprendizado profundo especializados em analisar imagens complexas, permitindo identificar defeitos como excesso ou falta de pasta, posicionamento incorreto, contaminação e imperfeições que comprometem a qualidade do produto final.

Assim, a incorporação das CNNs na inspeção de pasta térmica em componentes SMD representa uma fronteira estratégica para garantir a qualidade, confiabilidade e eficiência na fabricação de dispositivos eletrônicos modernos, refletindo-se em avanços tecnológicos e maior competitividade industrial.

Referências Bibliográficas

- [1] CASTELLANI, M., OTRI, S., PHAM, D. T., “Printed circuit board assembly time minimisation using a novel Bees Algorithm”, *Computers & Industrial Engineering*, v. 133, pp. 186–194, July 2019.
- [2] LIU, Z., QU, B., “Machine vision based online detection of PCB defect”, *Microprocessors and Microsystems*, v. 82, pp. 103807, April 2021.
- [3] AHMAD, H. M., RAHIMI, A., “Deep learning methods for object detection in smart manufacturing: A survey”, *Journal of Manufacturing Systems*, v. 64, pp. 181–196, 2022.
- [4] CERVANTES, J., GARCIA-LAMONT, F., RODRÍGUEZ-MAZAHUA, L., et al., “A comprehensive survey on support vector machine classification: Applications, challenges and trends”, *Neurocomputing*, v. 408, pp. 189–215, Sept. 2020.
- [5] KUSIAK, A., “From digital to universal manufacturing”, *International Journal of Production Research*, v. 60, n. 1, pp. 349–360, Jan. 2022.
- [6] ADRIANA VENTURA CARVALHO, DAISY VALLE ENRIQUE, AMAL CHOUCHENE, et al., “Quality 4.0: An Overview”, *Procedia Computer Science*, v. 181, pp. 341–346, 2021.
- [7] SINGH, S. A., DESAI, K. A., “Automated surface defect detection framework using machine vision and convolutional neural networks”, *Journal of Intelligent Manufacturing*, v. 34, n. 4, pp. 1995–2011, April 2023.
- [8] ZHOU, L., JIANG, Z., GENG, N., et al., “Production and operations management for intelligent manufacturing: a systematic literature review”, *Inter-*

national Journal of Production Research, v. 60, n. 2, pp. 808–846, Jan. 2022.

- [9] DEBEVEC, M., SIMIC, M., JOVANOVIĆ, V., et al., “Virtual factory as a useful tool for improving production processes”, *Journal of Manufacturing Systems*, v. 57, pp. 379–389, Oct. 2020.
- [10] ANDREAS MAYR, FRANZISKA SCHÄFER, REINHARDT SEIDEL, et al., “Machine Learning in Production – Potentials, Challenges and Exemplary Applications”, *Procedia CIRP*, v. 86, pp. 49–54, 2019.
- [11] EBAYYEH, A. A. R. M. A., MOUSAVI, A., “A Review and Analysis of Automatic Optical Inspection and Quality Monitoring Methods in Electronics Industry”, *IEEE Access*, v. 8, pp. 183192–183271, 2020.
- [12] YOUSAF, M. U., AIZED, T., SHABBIR, A., et al., “Automobile rear axle housing design and production process improvement using Failure Mode and Effects Analysis (FMEA)”, *Engineering Failure Analysis*, v. 154, pp. 107649, 2023.
- [13] FILZ, M.-A., GELLRICH, S., LANG, F., et al., “Data-driven Analysis of Product Property Propagation to Support Process-integrated Quality Management in Manufacturing Systems”, *Procedia CIRP*, v. 104, pp. 900–905, 2021.
- [14] REN, X., ZHAO, N., “Research on digital twin framework for customized product manual assembly systems”, *Journal of Manufacturing Systems*, v. 71, pp. 527–545, 2023.
- [15] SEIDEL, R., KÄSTLE, C., OCKEL, M., et al., “Impact of THT-hole dimensioning on manufacturability in selective wave soldering”, *Microelectronics Reliability*, v. 137, pp. 114773, Oct. 2022.
- [16] MALLAIYAN SATHIASEELAN, M. A., PARADIS, O. P., TAHERI, S., et al., “Why Is Deep Learning Challenging for Printed Circuit Board (PCB) Component Recognition and How Can We Address It?” *Cryptography*, v. 5, n. 1, pp. 9, March 2021.

- [17] SHAMKHALICHENAR, H., BUECHE, C. J., CHOI, J.-W., “Printed Circuit Board (PCB) Technology for Electrochemical Sensors and Sensing Platforms”, *Biosensors*, v. 10, n. 11, pp. 159, Oct. 2020.
- [18] SOBOLEWSKI, M., WOJEWODA-BUDKA, J., HUBER, Z., et al., “Solder joints reliability of through hole assemblies with various land and hole design”, *Microelectronics Reliability*, v. 125, pp. 114368, 2021.
- [19] HU, B., WANG, J., “Detection of PCB Surface Defects With Improved Faster-RCNN and Feature Pyramid Network”, *IEEE Access*, v. 8, pp. 108335–108345, 2020.
- [20] ISHAK, M. H. H., ABDUL AZIZ, M. S., ISMAIL, F., et al., “Effect of filling level and fillet profile on pin-through-hole solder joint”, *The International Journal of Advanced Manufacturing Technology*, v. 102, n. 5-8, pp. 1467–1485, June 2019.
- [21] GONZALEZ, R., WOODS, R., *Processamento digital de imagens (3a. ed.)*. Pearson Educación, 2009.
- [22] ALVES, V., DOS SANTOS, J. M., PINTO, E., et al., “Digital image processing combined with machine learning: A new strategy for brown sugar classification”, *Microchemical Journal*, v. 196, pp. 109604, 2024.
- [23] JANG, S. G., YOO, S. J., “Quantization-based distributed design strategy for adaptive consensus tracking of asynchronously switched nonlinear multi-agent systems”, *Nonlinear Analysis: Hybrid Systems*, v. 53, pp. 101488, 2024.
- [24] ZOU, G., SHE, J., PENG, S., et al., “Two-dimensional SEM image-based analysis of coal porosity and its pore structure”, *International Journal of Coal Science & Technology*, v. 7, n. 2, pp. 350–361, June 2020.
- [25] WU, R., LIU, H., LI, J.-B., “Adaptive gradients and weight projection based on quantized neural networks for efficient image classification”, *Computer Vision and Image Understanding*, v. 223, pp. 103516, 2022.

- [26] PAN, K. F., SIQUEIRA, J. A. C., SOUZA, S. N. M. D., et al., “Evaluation of broiler dark house illumination systems, with and without thermal insulation”, *Research, Society and Development*, v. 10, n. 12, pp. e170101220155, Sept. 2021.
- [27] YU, Y., WANG, C., FU, Q., et al., “Techniques and Challenges of Image Segmentation: A Review”, *Electronics*, v. 12, n. 5, pp. 1199, March 2023.
- [28] LI, B., YAO, C., SU, C.-T., et al., “Detection of skin defects on mangoes based on hyperspectral imaging combined with band ratio and improved Otsu method”, *Microchemical Journal*, v. 197, pp. 109718, 2024.
- [29] PAVITHRA, S., SHREYASHWINI, N. K., BHAVANA, H. S., et al., “Hand-Drawn Electronic Component Recognition Using ORB”, *Procedia Computer Science*, v. 218, pp. 504–513, 2023.
- [30] QUEK, G., WIENOLD, J., KHANIE, M. S., et al., “Comparing performance of discomfort glare metrics in high and low adaptation levels”, *Building and Environment*, v. 206, pp. 108335, Dec. 2021.
- [31] MA, X., LUO, Q., ZHOU, Y., et al., “A wide-field-of-view metalens array for CMOS image sensors’ conical light focusing”, *Results in Physics*, v. 59, pp. 107583, April 2024.
- [32] WU, P.-Y., SANDELS, C., MJÖRNELL, K., et al., “Predicting the presence of hazardous materials in buildings using machine learning”, *Building and Environment*, v. 213, pp. 108894, April 2022.
- [33] MASUD, G. H. A., SHANTO, R. I., SAKIN, I., et al., “Effective depression detection and interpretation: Integrating machine learning, deep learning, language models, and explainable AI”, *Array*, v. 25, pp. 100375, March 2025.
- [34] LUIZ F. CARBONERA FILHO, MARIA G. F. COUTINHO, MARCELO A. C. FERNANDES, “Proposta de Implementação em Hardware de SVM multi-kernel para Aplicações em IoT”. In: *XV Simpósio Brasileiro de Automação Inteligente*, p. 8, Online, 2021.

- [35] BADUGE, S. K., THILAKARATHNA, S., PERERA, J. S., et al., “Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications”, *Automation in Construction*, v. 141, pp. 104440, Sept. 2022.
- [36] CORTES, C., VAPNIK, V., “Support-vector networks”, *Machine Learning*, v. 20, n. 3, pp. 273–297, Sept. 1995.
- [37] COSCIA, A., DENTAMARO, V., GALANTUCCI, S., et al., “Automatic decision tree-based NIDPS ruleset generation for DoS/DDoS attacks”, *Journal of Information Security and Applications*, v. 82, pp. 103736, May 2024.
- [38] COLLEDANI, D., ANSELMINI, P., ROBUSTO, E., “Machine learning-decision tree classifiers in psychiatric assessment: An application to the diagnosis of major depressive disorder”, *Psychiatry Research*, v. 322, pp. 115127, April 2023.
- [39] ZHANG, S., “Challenges in KNN Classification”, *IEEE Transactions on Knowledge and Data Engineering*, v. 34, n. 10, pp. 4663–4675, Oct. 2022.
- [40] SHEBL, A., ABRIHA, D., DAWOUD, M., et al., “PRISMA vs. Landsat 9 in lithological mapping – a K-fold Cross-Validation implementation with Random Forest”, *The Egyptian Journal of Remote Sensing and Space Sciences*, v. 27, n. 3, pp. 577–596, Sept. 2024.
- [41] VERBRAEKEN, J., WOLTING, M., KATZY, J., et al., “A Survey on Distributed Machine Learning”, *ACM Computing Surveys*, v. 53, n. 2, pp. 1–33, March 2021.
- [42] VAROQUAUX, G., COLLIOT, O., “Evaluating Machine Learning Models and Their Diagnostic Value”, In: *Machine Learning for Brain Disorders*, v. 197, chap. 1, pp. 601–630, Springer US: New York, NY, 2023, Series Title: Neuromethods.
- [43] ÇAKIR, M., YILMAZ, M., ORAL, M. A., et al., “Accuracy assessment of RFerns, NB, SVM, and kNN machine learning classifiers in aquaculture”,

Journal of King Saud University - Science, v. 35, n. 6, pp. 102754, Aug. 2023.

- [44] KARAMITSOS, I., ALBARHAMI, S., APOSTOLOPOULOS, C., “Applying DevOps Practices of Continuous Automation for Machine Learning”, *Information*, v. 11, n. 7, pp. 363, July 2020.