

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE
MINAS GERAIS - *CAMPUS* BETIM
BACHARELADO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

Breno Bathemarque Teodoro

**VALIDAÇÃO DE PEÇAS COM FUROS:
IMPLEMENTAÇÃO DE UM SISTEMA BASEADO EM VISÃO
COMPUTACIONAL**

Betim
2024

BRENO BATHEMARQUE TEODORO

**VALIDAÇÃO DE PEÇAS COM FUROS:
IMPLEMENTAÇÃO DE UM SISTEMA BASEADO EM VISÃO
COMPUTACIONAL**

Trabalho de Conclusão de Curso apresentado à banca examinadora do curso de Engenharia de Controle e Automação do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais *Campus* Betim, como parte dos requisitos para obtenção do título de Bacharel em Engenharia de Controle e Automação.

Orientador: Prof. Esp. Maurício Monteiro da Silva

Betim
2024

FICHA CATALOGRÁFICA

T314v Teodoro, Breno Bathemarque

Validação de peças com furos: implementação de um sistema baseado em visão computacional / Breno Bathemarque Teodoro. – 2024.

61 f.: il.

Trabalho de conclusão de curso (Bacharelado em Engenharia de Controle e Automação) - Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais, Campus Betim, 2024.

Orientação: Esp. Maurício Monteiro da Silva

1. Visão Computacional. 2. Processamento de sinais. 3. Furos circulares. 4. Impressão 3D. 5. Engenharia de Controle e Automação. I. Teodoro, Breno Bathemarque. II. Título.

CDU: 681.5

Breno Bathemarque Teodoro


**VALIDAÇÃO DE PEÇAS COM FUROS:
IMPLEMENTAÇÃO DE UM SISTEMA BASEADO EM VISÃO
COMPUTACIONAL**

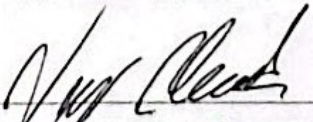
Trabalho de Conclusão de Curso apresentado à banca examinadora do curso de Engenharia de Controle e Automação do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais *Campus* Betim, como parte dos requisitos para obtenção do título de Bacharel em Engenharia de Controle e Automação.

Aprovado em: 12 / 12 / 2024 pela banca examinadora:

Prof. Maurício Monteiro da Silva
SIAPE 2526510
IFMG CAMPUS BETIM

Prof. Esp. Maurício Monteiro da Silva (Orientador) - IFMG


Prof. Dr. Arthur Hermano Rezende Rosa - IFMG


Prof. Me. Virgil Del Duca Almeida - IFMG

Este trabalho é dedicado a todos aqueles que estiveram comigo durante todo o tempo apoiando e incentivando a cada desafio.

AGRADECIMENTOS

Agradeço primeiramente a Deus, cuja presença e orientação foram fundamentais em cada etapa deste trabalho. Sua sabedoria divina iluminou meu caminho e sua graça sustentou-me nos momentos de desafio. Com humildade, reconheço a importância de colocá-lo em primeiro lugar e agradeço-lhe por Sua constante provisão e orientação ao longo desta jornada.

Agradeço profundamente ao professor Maurício pela dedicada orientação durante a elaboração deste trabalho. Sua expertise e paciência foram fundamentais para a conclusão bem-sucedida deste TCC. Seus valiosos *insights* e críticas construtivas contribuíram significativamente para o aprimoramento deste estudo.

Também agradeço aos meus amigos e familiares, que sempre me apoiaram e encorajaram durante toda a minha jornada acadêmica. O amor, apoio e incentivo que recebi de vocês foram fundamentais para manter-me motivado e focado ao longo deste processo.

Expresso minha gratidão aos professores e funcionários do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais, que estiveram disponíveis para tirar minhas dúvidas e fornecer orientações adicionais quando necessário. Seu comprometimento com o ensino e aprendizado é uma inspiração para mim.

“O sucesso é a soma de pequenos esforços repetidos dia após dia.”

Robert Collier

RESUMO

Este estudo apresenta o desenvolvimento de um sistema de visão computacional automatizado para a inspeção de peças com furos circulares fabricadas por impressão 3D, abordando desafios relacionados à inspeção manual e à complexidade das peças. Com o uso de técnicas avançadas de processamento de sinais e imagens, como segmentação, aplicação de filtros, detecção de bordas e a Transformada de Hough, o sistema visa identificar falhas de fabricação por meio da comparação objetiva entre imagens das peças inspecionadas e imagens padrão de referência. Essa abordagem inovadora melhora a precisão e eficiência dos processos de inspeção, reduzindo custos e tempo de produção, contribuindo para a automação industrial e otimização da manufatura aditiva. Com funções desenvolvidas para verificar quantidade, posição e dimensões de furos, o sistema foi eficaz na análise posicional e dimensional, mas apresentou erros na identificação da quantidade de furos, atribuídos à Transformada de Hough, que gerou falsos positivos em formas geométricas quadradas, destacando a necessidade de aprimorar algoritmos para diferenciar melhor formas não circulares.

Palavras-chave: Visão Computacional; Processamento de imagens; Detecção de defeitos; Furos circulares; Impressão 3D.

ABSTRACT

This study presents the development of an automated computer vision system for the inspection of 3D-printed parts with circular holes, addressing challenges related to manual inspection and the complexity of the parts. By employing advanced signal and image processing techniques, such as segmentation, filtering, edge detection, and the Hough Transform, the system aims to identify manufacturing defects through an objective comparison between images of the inspected parts and reference standard images. This innovative approach improves the precision and efficiency of inspection processes, reducing costs and production time, while contributing to industrial automation and the optimization of additive manufacturing. With functions developed to verify the quantity, position, and dimensions of holes, the system proved effective in positional and dimensional analysis but showed errors in identifying the quantity of holes, attributed to the Hough Transform, which generated false positives in square geometric shapes. These results underscore the need to improve algorithms to better differentiate non-circular shapes.

Keywords: Computer vision; Image processing; Defect detection; Circular holes; 3D Printing.

LISTA DE ILUSTRAÇÕES

1	Sistema de visão.	17
2	Etapas de um sistema de Visão Computacional.	18
3	Elementos de um sistema de PDI.	19
4	Visão esquemática de uma câmera CCD.	20
5	Métodos de Limiarização.	22
6	Exemplos de operações lógicas em imagens binárias.	23
7	Exemplo de Histograma.	24
8	Segmentação de Imagens.	25
9	Exemplo da aplicação do algoritmo Canny.	27
10	Transformada de Hough circular.	29
11	Mapa Conceitual.	31
12	Conjunto de peças de impressão 3D.	34
13	Conjunto de peças desenhadas no Autocad.	35
14	Caixa de testes.	35
15	Etapas do Pré-processamento.	36
16	Seleção das imagens.	38
17	Parâmetros padrão.	38
18	Configuração: Passo 1.	39
19	Configuração: Passo 2.	39
20	Configuração: Passo 3.	40
21	Configuração: Passo 4.	41
22	Valor do parâmetro param2 baixo.	41
23	Valor do parâmetro param2 alto.	42
24	Valor do parâmetro min_dist alto.	42
25	Valor do parâmetro min_dist baixo.	43
26	Peça de referência - Grupo 1.	47
27	Peça de referência - Grupo 2.	48
28	Falso positivo na peça do Teste 3.	49
29	Peça de referência - Grupo 3.	50

LISTA DE TABELAS

1	Tabela de materiais.	32
2	Resultados Esperados/Obtidos - Grupo 1	47
3	Resultados Esperados/Obtidos - Grupo 2	49
4	Resultados Esperados/Obtidos - Grupo 3	51
5	Resumo dos Resultados	52

LISTA DE SÍMBOLOS

<i>CDD</i>	<i>Charge Coupled Device</i>
<i>PDI</i>	<i>Processamento Digital de Imagens</i>
<i>TH</i>	<i>Transformada de Hough</i>

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Justificativa	15
1.2	Objetivos	16
1.3	Organização do Texto	16
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	Visão Computacional	17
2.2	Processamento Digital de Imagens	18
2.2.1	<i>Introdução</i>	18
2.2.2	<i>Aquisição e Digitalização de Imagens</i>	19
2.3	Pré-processamento de Imagens	21
2.3.1	<i>Limiarização</i>	21
2.3.2	<i>Operações Lógicas com Imagens</i>	22
2.3.3	<i>Histograma</i>	23
2.4	Segmentação de Imagens	24
2.4.1	<i>Python e a Biblioteca OpenCV</i>	26
2.4.2	<i>Detector de Bordas de Canny</i>	26
2.4.3	<i>Transformada de Hough Circular</i>	28
3	METODOLOGIA	31
3.1	Software e Materiais Utilizados	32
3.1.1	<i>Software</i>	32
3.1.2	<i>Peças de Impressão 3D</i>	33
3.2	Aquisição das Imagens	33
3.3	Pré-processamento	35
3.4	Calibração dos Parâmetros da Transformada de Hough	37
3.5	Seleção da Imagem de Teste	41
3.6	Comparação das Imagens	43
3.6.1	<i>Critério 1: Conformidade Quantitativa de Furos</i>	43
3.6.2	<i>Critério 2: Posicionamento dos Furos</i>	43
3.6.3	<i>Critério 3: Verificação das Especificações Dimensionais</i>	44

3.7	Geração do Relatório	44
4	RESULTADOS	46
4.1	Grupo 1	46
4.2	Grupo 2	48
4.3	Grupo 3	50
4.4	Resumo dos Resultados	51
5	CONCLUSÃO	53
5.1	Trabalhos Futuros	53
	REFERÊNCIAS	55
	APÊNDICE A – EXEMPLO 1	56

1 INTRODUÇÃO

No contexto atual da indústria de manufatura, a impressão 3D surge como uma força disruptiva, permitindo a criação de peças com complexidades geométricas inovadoras e personalização sem precedentes. A qualidade dessas peças, particularmente aquelas com elementos críticos como furos, representa um desafio significativo. Segundo (GIBSON; ROSEN; STUCKER, 2015), em *Additive Manufacturing Technologies* a impressão 3D não apenas revoluciona a fabricação de peças complexas, mas também oferece uma flexibilidade sem precedentes na personalização de produtos. A implementação de sistemas de visão computacional se mostra crucial em diversos setores industriais, como automotivo, aeroespacial e eletrônico, onde a precisão e a qualidade são essenciais. No contexto da impressão 3D, esses sistemas não apenas detectam a ausência de furos e variações no diâmetro, mas também desalinhamentos, oferecendo um método de inspeção mais confiável e menos propenso a erros do que as abordagens manuais. Além disso, a adoção de tecnologia de visão computacional traz benefícios tangíveis em termos de redução de custos e tempos de produção. A *Level 3 Inspection LLC (L3I)* implementou um sistema de Inspeção Assistida por Computador (CAI) para melhorar a qualidade de peças na indústria aeroespacial. Com a estação automatizada *Smart Inspection Station*, a empresa conseguiu realizar cerca de 5.000 inspeções de componentes, como peças de motores a jato, comparando diretamente as peças fabricadas com modelos CAD 3D. Isso aumentou a precisão das inspeções, reduziu custos operacionais e acelerou a entrega de peças conforme especificações rigorosas.

Os sistemas de visão computacional são utilizados para monitorar a qualidade durante todo o processo de impressão, garantindo que cada camada seja depositada corretamente e que a peça final atenda às especificações necessárias. Isso não apenas melhora a qualidade das peças produzidas, mas também proporciona um *feedback* em tempo real, permitindo ajustes imediatos no processo de fabricação, o que é especialmente valioso em operações de impressão 3D em larga escala. No entanto, a implementação de sistemas de visão computacional não está isenta de desafios. (SZELISKI, 2010), em *Computer Vision: Algorithms and Applications*, enfatiza que a integração de software avançado e hardware de alta precisão é crucial, assim como a formação de pessoal para operar e manter essas tecnologias. Além disso, a adaptação dos processos de produção existentes para incorporar essa nova etapa de verificação pode requerer investimentos significativos iniciais e uma curva de aprendizado para otimizar a eficácia do sistema.

Apesar dos desafios, os benefícios da adoção de sistemas de visão computacional para a validação de peças impressas em 3D são indiscutíveis. Esses sistemas não apenas melhoram a qualidade das peças produzidas e garantem a conformidade com as especificações técnicas, mas também eliminam a necessidade de inspeções manuais, que são demoradas e suscetíveis a erros. A introdução de um método objetivo e consistente de controle de qualidade, conforme discutido por (GIBSON; ROSEN; STUCKER, 2015) e (SZELISKI, 2010), representa um avanço significativo na manufatura aditiva, promovendo maior confiabilidade e eficiência na produção de componentes complexos.

Em suma, enquanto os sistemas de visão computacional apresentam desafios relacionados à integração tecnológica e ao treinamento de pessoal, os benefícios em termos de melhoria da qualidade da produção e eficiência operacional superam significativamente essas barreiras. A implementação bem-sucedida desses sistemas pode definir um novo padrão de excelência na manufatura aditiva, alinhando-se com as demandas por inovação tecnológica e competitividade no mercado global.

1.1 Justificativa

A detecção de defeitos em peças impressas em 3D, como furos ausentes, desalinhados ou com variação de diâmetro, está intimamente ligada à precisão dimensional e à repetibilidade do processo de impressão. Estudos como o de (POPESCU *et al.*, 2023) indicam que parâmetros de impressão, como temperatura de extrusão e velocidade de impressão, afetam de forma significativa a qualidade final da peça. A falta de controle adequado desses fatores pode levar a desalinhamentos de camadas e variações indesejadas nas dimensões dos furos, impactando diretamente a conformidade da peça com as especificações do projeto.

Outro ponto crítico é o controle da extrusão de filamento, que, quando desregulado, pode causar superextrusão ou subextrusão, resultando em peças com dimensões imprecisas. Segundo (POPESCU *et al.*, 2023), variações na pressão do bico durante a impressão, especialmente em curvas, podem aumentar a largura das linhas impressas, o que afeta a precisão dimensional. Problemas comuns, como o "pé de elefante" (primeira camada mais larga) e a má adesão à mesa de impressão, também são influenciados por esse controle inadequado da extrusão.

Os sistemas de visão computacional oferecem uma solução automatizada superior às metodologias tradicionais de inspeção manual, que são laboriosas, suscetíveis a erros e inviáveis em grandes escalas de produção. Com precisão, rapidez e repetibilidade, esses sistemas identificam de forma eficiente discrepâncias dimensionais e de posicionamento, otimizando significativamente o controle de qualidade. A automação permite a detecção precoce de defeitos, possibilitando correções imediatas e reduzindo o volume de peças rejeitadas. Isso resulta em economias substanciais de tempo e recursos materiais, tornando o processo produtivo mais eficiente e sustentável.

Por fim, a utilização de sistemas de visão computacional para a inspeção de peças impressas em 3D oferece uma solução automatizada e precisa, superando as limitações dos métodos tradicionais de inspeção manual. Esses sistemas permitem a detecção precoce de defeitos, contribuindo para a redução das taxas de rejeição e o aumento da eficiência do controle de qualidade. Como resultado, há uma melhoria na qualidade final das peças e uma economia de recursos, o que impacta diretamente na lucratividade e competitividade das operações de impressão 3D.

1.2 Objetivos

Este trabalho desenvolve um sistema de visão computacional para validar automaticamente furos em peças 3D. O objetivo é garantir que as peças atendam às especificações técnicas, mantendo sua integridade estrutural e otimizando a fabricação. Para isso, foram estabelecidos três objetivos específicos:

1. Verificar a quantidade de furos.
2. Inspeccionar a posição dos furos.
3. Avaliar a dimensão dos furos.

1.3 Organização do Texto

Este trabalho está organizado da seguinte forma:

(a) Capítulo 1 - Introdução

Breve contextualização sobre a importância do controle de qualidade na produção de peças feitas com impressão 3D e a utilização da visão computacional para a detecção de falhas em furações circulares. Apresentação dos objetivos do trabalho.

(b) Capítulo 2 - Referencial Teórico

Abordagem dos principais conceitos relacionados à visão computacional e técnicas de Processamento Digital de Imagem (PDI) utilizadas na detecção de falhas em furações circulares.

(c) Capítulo 3 - Metodologia

Descrição dos equipamentos e software utilizados na implementação do sistema de detecção de falhas. Apresentação da metodologia empregada na coleta e análise das imagens.

(d) Capítulo 4 - Resultados e Discussões

Exibição dos resultados obtidos utilizando o sistema de visão computacional implementado. Discussão dos resultados e análise de possíveis melhorias no sistema.

(e) Capítulo 5 - Conclusão

Síntese dos resultados obtidos e dos principais achados do trabalho. Apresentação das limitações encontradas e sugestões para trabalhos futuros.


2 FUNDAMENTAÇÃO TEÓRICA

2.1 Visão Computacional

De acordo com (SZELISKI, 2010), os sistemas de visão computacional são uma das tecnologias mais promissoras no campo da automação industrial, oferecendo soluções avançadas para inspeção, medição e controle de qualidade em processos de fabricação. Esses sistemas têm a vantagem de auxiliar a percepção visual humana, superando limitações como fadiga e inconsistências. Ao contrário dos humanos, computadores podem ser usados continuamente, analisando grandes quantidades de dados de forma precisa e eficiente em um contexto controlado.

A Figura 1 apresenta uma arquitetura simplificada para a execução de um sistema de visão aplicado na indústria. O processo de navegação segue o fluxo da linha de produção, com um dispositivo responsável pela aquisição de imagens da peça em questão. Em seguida, a imagem é transmitida para o sistema de processamento, onde um software é utilizado para analisar e identificar possíveis defeitos na peça. Caso alguma não conformidade seja identificada, o sistema de processamento utiliza sinais digitais para controlar dispositivos atuadores que possam remover as peças defeituosas ou gerar notificações para o administrador do sistema.

Figura 1 – Sistema de visão.

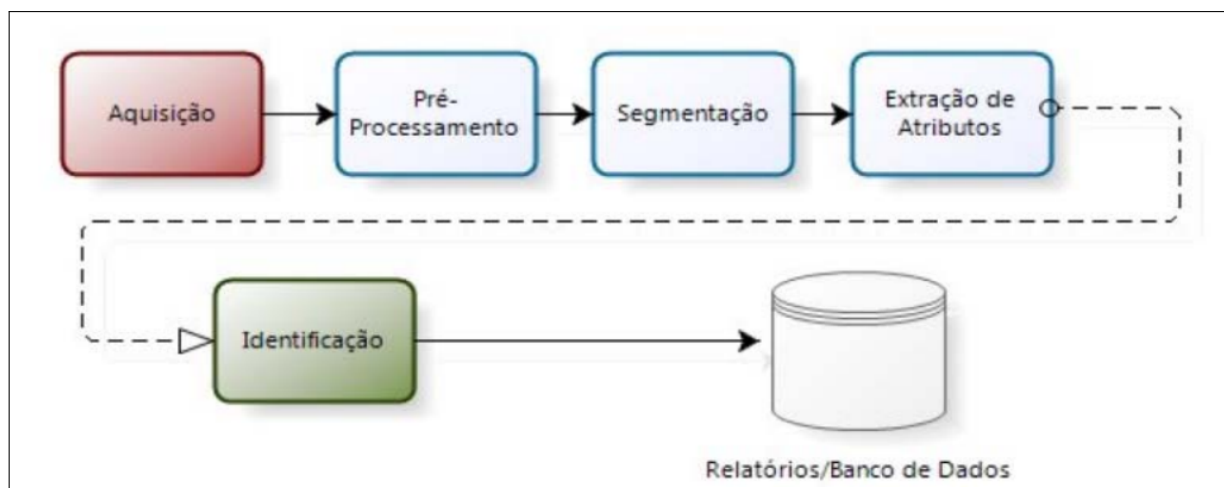


Fonte: SANDOVAL *et al.*, 2017.

É importante ressaltar que, segundo (SZELISKI, 2022), o uso de sistemas de visão computacional na indústria pode trazer uma série de benefícios, como a redução de custos e o aumento da eficiência dos processos produtivos. No entanto, é fundamental que os sistemas sejam projetados e implementados de forma adequada, levando em consideração as necessidades específicas de cada empresa e setor industrial. Além disso, é preciso garantir a segurança e a confiabilidade das informações e dados gerados pelos sistemas de visão computacional, garantindo a qualidade do processo produtivo.

A Figura 2 ilustra as principais etapas de um sistema de visão computacional, que serão detalhadas nas próximas seções. Serão abordados desde a aquisição da imagem até a interpretação dos dados por meio de algoritmos específicos, visando a extração de informações relevantes.

Figura 2 – Etapas de um sistema de Visão Computacional.



Fonte: NETO *et al.*, 2015.

2.2 Processamento Digital de Imagens

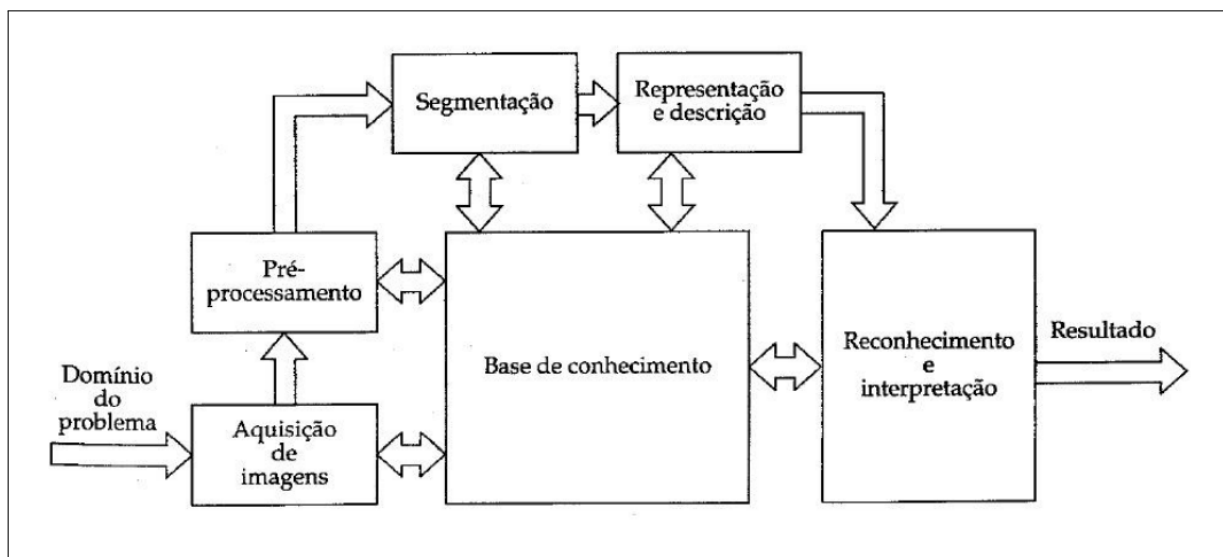
2.2.1 Introdução

O Processamento Digital de Imagens (PDI) é uma área importante da computação com diversas aplicações nos setores da indústria, comércio, saúde. Com a possibilidade de aplicar filtros simples a operações complexas, como restauração de imagens, o PDI possui ferramentas poderosas que auxiliam na resolução de problemas do mundo real e permitem o desenvolvimento de aplicações robustas e eficazes.

O PDI envolve um conjunto de etapas bem definidas que trabalham em conjunto para produzir o resultado desejado. Cada etapa afeta diretamente as etapas seguintes e a interação entre elas é fundamental para o sucesso do processamento. Conforme descrito por (GONZALEZ; WOODS, 2007), as etapas básicas do processamento digital de imagens são: aquisição de imagem, pré-processamento, segmentação, descrição, reconhecimento e interpretação. A Figura 3 ilustra o fluxo dessas etapas.

O PDI é uma sequência de etapas que trabalham juntas para produzir um resultado final. O pré-processamento é a primeira etapa e envolve operações para aumentar contrastes, remover ruídos e suavizar regiões. Essas operações são consideradas de baixo nível, pois trabalham diretamente com valores de intensidade de *pixel*, sem levar em conta informações relacionadas

Figura 3 – Elementos de um sistema de PDI.



Fonte: GONZALEZ; WOODS, 2007.

ao domínio do problema. A imagem resultante é uma versão digitalizada de melhor qualidade da imagem original.

A etapa de segmentação é onde a imagem de entrada é dividida em partes ou objetos constituintes. A segmentação automática é uma tarefa difícil no processamento de imagens digitais, e um processo de segmentação robusto é crítico para uma solução bem-sucedida do problema de imagem. A saída da segmentação consiste em *pixels* contendo informações sobre uma região e sua borda, e a escolha entre representar o resultado por borda ou por região depende do interesse nas características da imagem.

Na etapa de representação e descrição, o objetivo é extrair características que resultem em informações de interesse para o domínio do problema. Essas características são usadas nas etapas posteriores do PDI. O reconhecimento, por outro lado, busca atribuir um rótulo a um objeto com base nas informações fornecidas pelo descritor, e a interpretação atribui um significado a um conjunto de objetos reconhecidos.

O conhecimento sobre o domínio do problema é codificado em um sistema de PDI na forma de uma base de conhecimento. Essa base pode ser simples ou complexa, dependendo do domínio do problema, e é composta por características específicas do problema que podem ser exploradas para auxiliar nas etapas de processamento.

2.2.2 Aquisição e Digitalização de Imagens


Atualmente, a câmera CDD (*Charge Coupled Device*) é um dispositivo eletrônico utilizado para capturar imagens. Ela é composta por uma matriz de células semicondutoras fotossensíveis, que atuam como pequenos capacitores, armazenando a carga elétrica que é gerada pela

energia luminosa incidente.

Quando a luz atinge a célula fotossensível, ela gera uma carga elétrica que é proporcional à intensidade da luz. Essas cargas elétricas geradas em cada célula são então transferidas para um registrador de deslocamento, que funciona como uma espécie de "esteira rolante" para transportar as cargas elétricas de uma célula para outra.

Ao final do processo de transferência, as cargas elétricas armazenadas nas células são convertidas em um sinal analógico de vídeo monocromático. Esse sinal pode ser condicionado e processado por circuitos eletrônicos especializados, permitindo a geração de imagens de alta qualidade. A Figura 4 mostra uma visão simplificada da aquisição de imagens com câmera CCD.

Figura 4 – Visão esquemática de uma câmera CCD.



Fonte: FILHO; NETO, 1999.

O próximo passo é a digitalização da imagem, segundo (GONZALEZ; WOODS, 2017), ela é o processo de converter uma imagem analógica em uma representação digital, ou seja, uma imagem composta por *pixels* em uma matriz de números.

Durante o processo de digitalização, é necessário considerar a resolução espacial da imagem, que é a densidade de *pixels* por unidade de área, e a profundidade de *bits*, que determina a quantidade de informações tonais que podem ser representadas por *pixel*. Uma vez digitalizada, a imagem pode ser processada por meio de algoritmos de PDI, como filtragem, segmentação e reconhecimento de padrões.

2.3 Pré-processamento de Imagens

O pré-processamento de imagens é uma etapa fundamental no PDI que envolve a aplicação de técnicas para melhorar a qualidade da imagem e prepará-la para as etapas subsequentes de processamento. Essas técnicas são aplicadas para corrigir distorções geométricas, ajustar o contraste, reduzir o ruído e remover artefatos indesejados na imagem.

O pré-processamento pode incluir operações como a correção de brilho e contraste, a normalização de intensidade, a equalização de histograma, a filtragem espacial para redução de ruído e a eliminação de artefatos, como manchas e marcas indesejadas na imagem. Também pode envolver a remoção de fundos e objetos indesejados na imagem, a correção de distorções geométricas e a normalização da orientação ou escala da imagem.

O seu objetivo será melhorar a qualidade da imagem para facilitar a detecção, análise e interpretação das informações contidas na imagem das peças. Essa etapa é especialmente importante em aplicações de visão computacional e reconhecimento de padrões, onde a qualidade da imagem pode afetar significativamente o desempenho do sistema.

A seguir, serão apresentadas algumas técnicas fundamentais para o processamento digital de imagens, incluindo limiarização, operadores morfológicos, operações lógicas e análise de histogramas.

2.3.1 Limiarização

A limiarização é uma técnica muito utilizada em processamento digital de imagens que tem como objetivo dividir a imagem em duas partes distintas: *pixels* com intensidade acima do limiar e *pixels* abaixo do limiar. Ela é eficaz para destacar objetos de interesse e remover o fundo ou ruído de fundo da imagem.

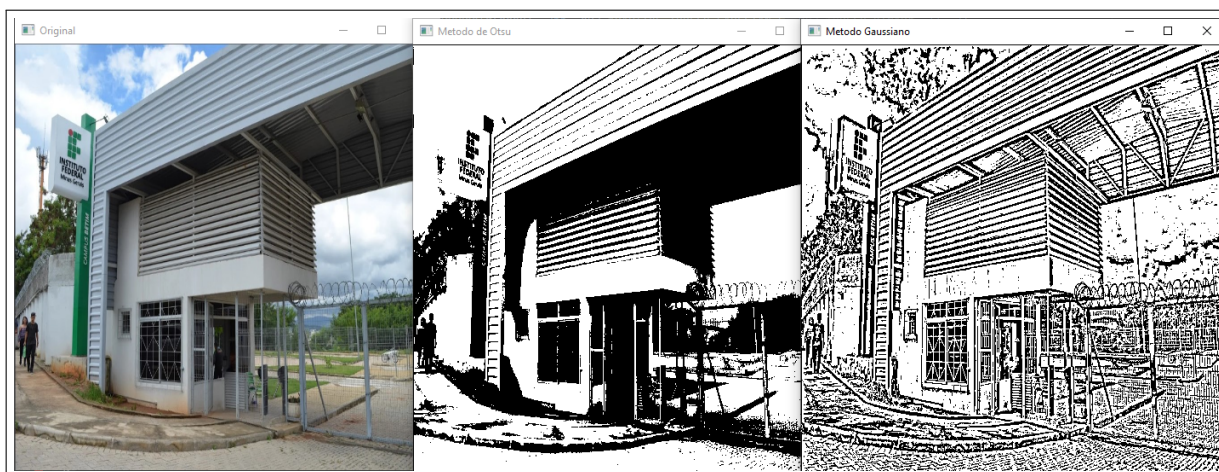
Segundo (GONZALEZ; WOODS, 2017), a limiarização é uma técnica simples e comum que consiste em determinar um limiar apropriado para dividir os *pixels* da imagem em duas classes, com base na intensidade dos *pixels*. Técnicas podem ser utilizadas para essa escolha, como o método de Otsu, e o modelo Gaussiano, que serão apresentados abaixo.

O método de Otsu é um algoritmo de limiarização, proposto por Nobuyuki Otsu. Segundo (OTSU *et al.*, 1975), seu objetivo é, a partir de uma imagem em tons de cinza, determinar o valor ideal de um *threshold* que separe os elementos do fundo e da frente da imagem em dois *clusters*, atribuindo a cor branca ou preta para cada um deles. Esse modelo é muito útil quando a distribuição de intensidades dos *pixels* é bimodal, o que significa que existem dois picos distintos na distribuição de suas intensidades na imagem.

Além disso, um modelo comum de distribuição de intensidades de *pixels* em uma imagem é por meio de um modelo gaussiano. Esse modelo assume que a distribuição de intensidades de

pixels segue uma distribuição normal, que é caracterizada por sua média e desvio padrão. Ele é frequentemente usado em técnicas de limiarização e segmentação de imagem para estimar o limiar de separação de duas classes de *pixels*. Na Figura 5 é possível ver um exemplo da aplicação desses dois métodos de limiarização, na figura central é apresentado modelo de Otsu e na direita é apresentado o modelo Gaussiano.

Figura 5 – Métodos de Limiarização.



Fonte: nicelocal.com, adaptações feitas pelo autor.

2.3.2 Operações Lógicas com Imagens

As operações lógicas se destacam por permitir a combinação de informações de diferentes imagens em uma só, utilizando as operações booleanas conhecidas, como AND, OR, XOR e NOT, por exemplo.

É importante destacar que as operações lógicas podem ser realizadas em imagens com qualquer número de níveis de cinza, mas sua compreensão é melhor visualizada em imagens binárias. A Figura 6 ilustra um exemplo de aplicação das operações lógicas em duas imagens binárias. As imagens resultantes das operações lógicas podem ser utilizadas para segmentação de objetos em uma imagem, detecção de regiões de interesse, entre outras aplicações.

Uma das aplicações mais interessantes dessas técnicas é em métodos de comparação de imagens. Por meio delas, é possível identificar diferenças e semelhanças entre duas imagens.

Um exemplo de utilização é a diferença absoluta. Nessa técnica, cada *pixel* das duas imagens é comparado e é calculada a diferença absoluta entre eles. Se a diferença entre dois *pixels* é maior que um determinado limite, o *pixel* na imagem resultante será marcado como diferente. Essa técnica é útil para detectar diferenças sutis entre duas imagens.


Outra estratégia que pode ser adotada é a operação XOR. Nesse caso, cada *pixel* das duas imagens é comparado e, se eles forem diferentes, o *pixel* na imagem resultante será marcado

como branco. Se eles forem iguais, o *pixel* será marcado como preto. Essa abordagem é útil para detectar semelhanças entre as imagens.

Além desses procedimentos, outras formas de comparação de imagens que utilizam operações lógicas incluem o uso de filtros e máscaras de convolução, bem como o uso de histogramas cumulativos, que serão explicados mais detalhadamente na subseção 2.3.3.

Em suma, as operações lógicas são técnicas valiosas no processamento de imagens, especialmente para a comparação e análise entre imagens. Quando utilizadas em conjunto com outras técnicas de PDI, como segmentação, filtragem e análise morfológica, tornam-se ferramentas poderosas para a detecção de diferenças e semelhanças em imagens. Essas técnicas são amplamente aplicáveis em diversas áreas, como segurança da informação, para validação de dados visuais; visão computacional, em sistemas de inspeção automatizada; e reconhecimento de padrões, para identificação e classificação de objetos ou características específicas em cenários complexos.

Figura 6 – Exemplos de operações lógicas em imagens binárias.



Fonte: FILHO; NETO, 1999.


2.3.3 Histograma

Em seu livro "Processamento de Imagens Digitais", (GONZALEZ; WOODS, 2017) afirmam que "o histograma é uma ferramenta poderosa para a compreensão das estatísticas de intensidade em uma imagem". Com base nessa afirmação, é possível destacar a importância de seu uso na análise e descrição de características visuais das imagens. O histograma de uma

imagem, como pode ser observado na Figura 7 é um gráfico que representa a frequência de ocorrência de cada valor de intensidade de cor em uma imagem. Essa informação pode ser usada para comparações entre imagens, como identificação de semelhanças e diferenças.

Para utilizar o histograma em comparações de imagens, primeiramente é necessário calculá-lo para cada imagem. Isso pode ser feito separadamente para cada canal de cor (vermelho, verde e azul) ou para a imagem em escala de cinza. A partir dessa informação, pode-se obter estatísticas como média, desvio padrão e mediana que descrevem a distribuição dos valores de intensidade na imagem.

Figura 7 – Exemplo de Histograma.



Fonte: BRADSKI; KAEHLER, 2008.

Para comparar o histograma de duas imagens, há métricas de similaridade disponíveis, como a correlação, e a distância euclidiana. A métrica de correlação, em particular, é comumente utilizada por retornar valores entre -1 e 1, em que valores próximos a 1 indicam maior similaridade entre os histogramas.


Essa técnica pode ser aplicada em diversas áreas, incluindo reconhecimento de objetos, detecção de cópias de imagens e recuperação de informações visuais. Além disso, a comparação de histogramas é uma alternativa eficaz e relativamente simples para comparar imagens, sem a necessidade de algoritmos complexos de PDI.

2.4 Segmentação de Imagens

A análise de imagens é uma área de pesquisa que tem como objetivo extrair informações relevantes a partir de imagens. No PDI, um passo importante é a identificação das regiões de interesse na imagem, o que pode ser feito através da técnica conhecida como segmentação. De acordo com (GONZALEZ; WOODS, 2017), a segmentação consiste em dividir a imagem em

regiões ou objetos com características semelhantes, tornando possível a identificação e análise dessas regiões de forma mais precisa. A Figura 8 apresenta um exemplo de como ficaria essa divisão.

Figura 8 – Segmentação de Imagens.



Fonte: MINAEE et al., 2022.

Além disso, a segmentação pode ser realizada através de diferentes técnicas, como baseadas em limiarização, segmentação por crescimento de regiões, segmentação baseada em bordas, entre outras. A escolha da técnica adequada depende das características da imagem e das informações que se desejam extrair.

Em resumo, a segmentação é uma etapa essencial no PDI, permitindo a identificação e análise de regiões de interesse dentro de uma imagem. A escolha da técnica de segmentação depende das características específicas da imagem a ser processada. No presente estudo, utilizo técnicas avançadas para aprimorar a segmentação e a análise das imagens das peças inspecionadas. O detector de bordas de *Canny* foi empregado para detectar as bordas das imagens com alta precisão, destacando os contornos das formas e facilitando a separação das regiões de interesse. Além disso, a Transformada de *Hough* Circular foi aplicada para identificar e validar a quantidade, posição e dimensões dos furos circulares nas peças, uma etapa crucial para a verificação da qualidade das peças fabricadas. Essas técnicas, quando combinadas, oferecem uma abordagem

robusta e eficaz para a análise de imagens, proporcionando resultados precisos e eficientes no contexto de inspeção automatizada.

2.4.1 Python e a Biblioteca OpenCV

Python é uma linguagem de programação amplamente utilizada devido à sua simplicidade, versatilidade e grande comunidade de desenvolvedores. Caracteriza-se por ser uma linguagem de alto nível, de propósito geral e com uma curva de aprendizado relativamente baixa, o que a torna ideal para projetos que demandam rapidez no desenvolvimento e fácil manutenção. No contexto da visão computacional, *Python* destaca-se pela disponibilidade de bibliotecas especializadas, como o *OpenCV*, que oferecem ferramentas robustas para processamento e análise de imagens.

OpenCV (Open Source Computer Vision Library) é uma biblioteca de código aberto projetada especificamente para a aplicação em visão computacional e aprendizado de máquina. Lançada inicialmente pela Intel, a biblioteca suporta diversas linguagens de programação, sendo *Python* uma das mais utilizadas devido à sua sintaxe clara e integração com outras bibliotecas, como *NumPy*, para operações matemáticas. O *OpenCV* oferece funcionalidades como detecção de bordas, reconhecimento de padrões, segmentação de objetos, calibração de câmeras e manipulação de imagens, tornando-se um recurso essencial para aplicações como a desenvolvida neste trabalho.


Neste projeto, a biblioteca *OpenCV* foi utilizada para implementar o sistema de visão computacional, permitindo o processamento e a análise das imagens das peças. As funções disponíveis na biblioteca, como detecção de contornos e medição de dimensões, foram fundamentais para verificar a quantidade, a posição e a dimensão dos furos presentes nas peças avaliadas.

2.4.2 Detector de Bordas de Canny

O Detector de bordas de Canny é um algoritmo de detecção de bordas em imagens desenvolvido por John Canny em 1986. Ele é considerado um dos algoritmos mais precisos e eficientes para detecção de bordas em imagens. Segundo o artigo "*A Computational Approach to Edge Detection*" de (CANNY, 1986), a técnica utiliza um filtro Gaussiano para suavizar a imagem e reduzir o ruído. Em seguida, é aplicado um operador de Sobel para calcular a magnitude do gradiente em cada ponto da imagem. A magnitude é usada para identificar as bordas da imagem, através da aplicação de um limiar, que remove as bordas indesejadas e mantém as bordas mais fortes.

O algoritmo de Canny é conhecido por sua habilidade em identificar bordas finas e detalhadas, tornando-o uma escolha popular para muitas aplicações de PDI, como reconhecimento de objetos, reconhecimento de caracteres, entre outras. Além disso, a técnica também é conhecida por sua capacidade em reduzir o ruído presente nos dados da imagem, resultando em bordas mais precisas e bem definidas.

Figura 9 – Exemplo da aplicação do algoritmo Canny.



Fonte: Elaborado pelo autor, 2024.

A Figura 9 mostra duas moedas: a Figura 9a é a imagem da moeda original e a Figura 9b mostra o resultado após a aplicação da função `cv2.Canny()`, da biblioteca *OpenCV*.

```
Syntax: cv2.Canny(image, T_lower, T_upper, aperture_size, L2Gradient)
```

Essa função recebe vários parâmetros, incluindo a imagem de entrada, dois valores de limiar, um tamanho de abertura e um indicador de gradiente L2. O resultado é uma imagem binária que indica onde as bordas foram encontradas.

O primeiro parâmetro, `image`, é a imagem de entrada que será processada pela função. Os próximos dois parâmetros, `T_lower` e `T_upper`, são os limiares inferior e superior que serão usados na detecção de bordas. Os gradientes abaixo do limiar inferior são descartados, enquanto os acima do limiar superior são considerados bordas. Aqueles conectados a valores acima do limiar superior e com gradientes entre os dois limiares também são considerados bordas.

O parâmetro `aperture_size` é o tamanho da máscara utilizada para o cálculo do gradiente. Ele deve ser um número ímpar, geralmente escolhido entre 3 e 7. O último parâmetro, `L2Gradient`, é um parâmetro booleano que indica se deve ser usado o cálculo da norma L2 do gradiente.

Na Figura 9b, as bordas encontradas pela função são exibidas em branco e o resto da imagem é exibido em preto.

2.4.3 Transformada de Hough Circular

A Transformada de Hough (TH) é uma técnica importante na área de visão computacional para detectar formas e linhas em imagens. O princípio básico da transformada é a representação das linhas na forma de pontos em um espaço de parâmetros, onde cada ponto representa uma linha possível na imagem original. Ela é particularmente útil para a detecção de linhas em imagens com ruído ou bordas difusas, onde outros métodos de detecção de bordas, como o operador Sobel, podem falhar.

A TH aplicada a círculos é uma técnica de PDI que permite detectar círculos em uma imagem. Assim como na Transformada de Hough aplicada a linhas, o princípio básico é a representação dos círculos em um espaço de parâmetros.

Para aplicar a transformada a círculos, é preciso definir uma função que descreva a equação de um círculo na imagem. Essa equação é dada por:

$$(x - a)^2 + (y - b)^2 = r^2 \quad (2.1)$$

onde (a, b) é o centro do círculo e r é o raio.

O método de TH é utilizado para analisar formas em uma imagem, relacionando pontos de borda a possíveis valores de parâmetros da forma procurada. Para cada ponto de borda, votos são acumulados para todas as combinações de parâmetros que satisfaçam a restrição. Esses votos são armazenados em um *array* chamado de *array* acumulador, que representa discretamente o espaço de parâmetros. Os pontos de borda são adicionados de forma coerente ao contador acumulador mais próximo dos parâmetros da forma. Ao final do processo, os elementos do *array* com um grande número de votos indicam fortes evidências da presença da forma com os parâmetros correspondentes. No contexto da Transformada de Hough, um bin no *array* acumulador representa uma região específica no espaço de parâmetros onde os votos são acumulados. A detecção de picos é uma etapa importante da TH, onde métodos são aplicados para identificar os picos no *array* acumulador.

A função `cv2.HoughCircles`, da biblioteca *OpenCV*, é utilizada para detectar círculos em imagens utilizando a Transformada de Hough, um algoritmo que mapeia bordas detectadas para um espaço de parâmetros, permitindo identificar formas circulares.

A sintaxe básica da função é a seguinte:

```
Syntax: cv2.HoughCircles(edges, minDist, param2, minRadius, maxRadius)
```

Onde os parâmetros são descritos da seguinte maneira:

`edges`: A imagem de entrada, que deve ser uma imagem binária. Geralmente, antes de aplicar a função `HoughCircles`, utiliza-se um detector de bordas, como o Canny, para gerar essa imagem. As bordas detectadas são essenciais para encontrar os círculos.

`minDist`: A distância mínima entre os centros dos círculos detectados. Esse parâmetro é crucial para evitar a detecção de círculos próximos demais, que poderiam ser erroneamente interpretados como um único círculo. O valor deve ser ajustado dependendo da resolução da imagem e do tamanho dos círculos que se deseja detectar.

`param2`: O limiar que define a sensibilidade para a detecção de círculos. Quanto menor o valor de `param2`, mais círculos serão detectados, incluindo os falsos positivos. Um valor maior pode resultar em menos detecções, mas com maior precisão.


`minRadius`: O raio mínimo dos círculos a serem detectados. Esse parâmetro ajuda a limitar a detecção a círculos de um tamanho específico. Pode ser útil para focar apenas em círculos que atendam a um critério de tamanho mínimo.

`maxRadius`: O raio máximo dos círculos a serem detectados. Similar ao `minRadius`, esse parâmetro permite restringir a detecção a círculos dentro de um intervalo específico de tamanho.

Esses parâmetros permitem a `cv2.HoughCircles` identificar círculos de forma eficiente em imagens com bordas claras, facilitando sua aplicação em diversas áreas, como inspeção de qualidade e análise de formas geométricas em imagens industriais ou científicas.

No caso específico da detecção de círculos, o TH foi inicialmente proposto por (DUDA; HART, 1972). A equação de restrição relaciona as coordenadas do centro do círculo (a, b) e seu raio r com os pontos de borda (x, y) que compõem o círculo. Essa equação indica que qualquer ponto de borda pode ser parte de um círculo cujos parâmetros estão na superfície de um cone circular no espaço de parâmetros (a, b, r) . Se vários pontos de borda se interceptarem em um único ponto, isso indica que todos os pontos da imagem estão no círculo definido pelos parâmetros, como pode ser observado na Figura 10.

Figura 10 – Transformada de Hough circular.



Fonte: BALLARD, 1981.

A Transformada de Hough para detecção de círculos se baseia em uma abordagem matemática onde a busca por círculos é realizada em um espaço de parâmetros. Nesse espaço, cada ponto de borda em uma imagem é representado como um segmento de um "cone circular", e a detecção de círculos é feita ao buscar pelos parâmetros do círculo que melhor se ajustam a esses pontos. O centro do círculo e seu raio são os parâmetros principais, e, para cada borda, esses parâmetros são "votados" no espaço de Hough.

No entanto, a eficiência desse processo pode ser aumentada ao considerar a direção do gradiente de cada ponto de borda. O gradiente de uma imagem representa a taxa de variação da intensidade de pixel em uma direção específica e é fundamental para identificar bordas. Na detecção de círculos, essa direção de gradiente é usada para restringir a busca de parâmetros. Especificamente, o centro de um círculo deve estar ao longo da direção do máximo gradiente de nível de cinza dos pontos de borda.

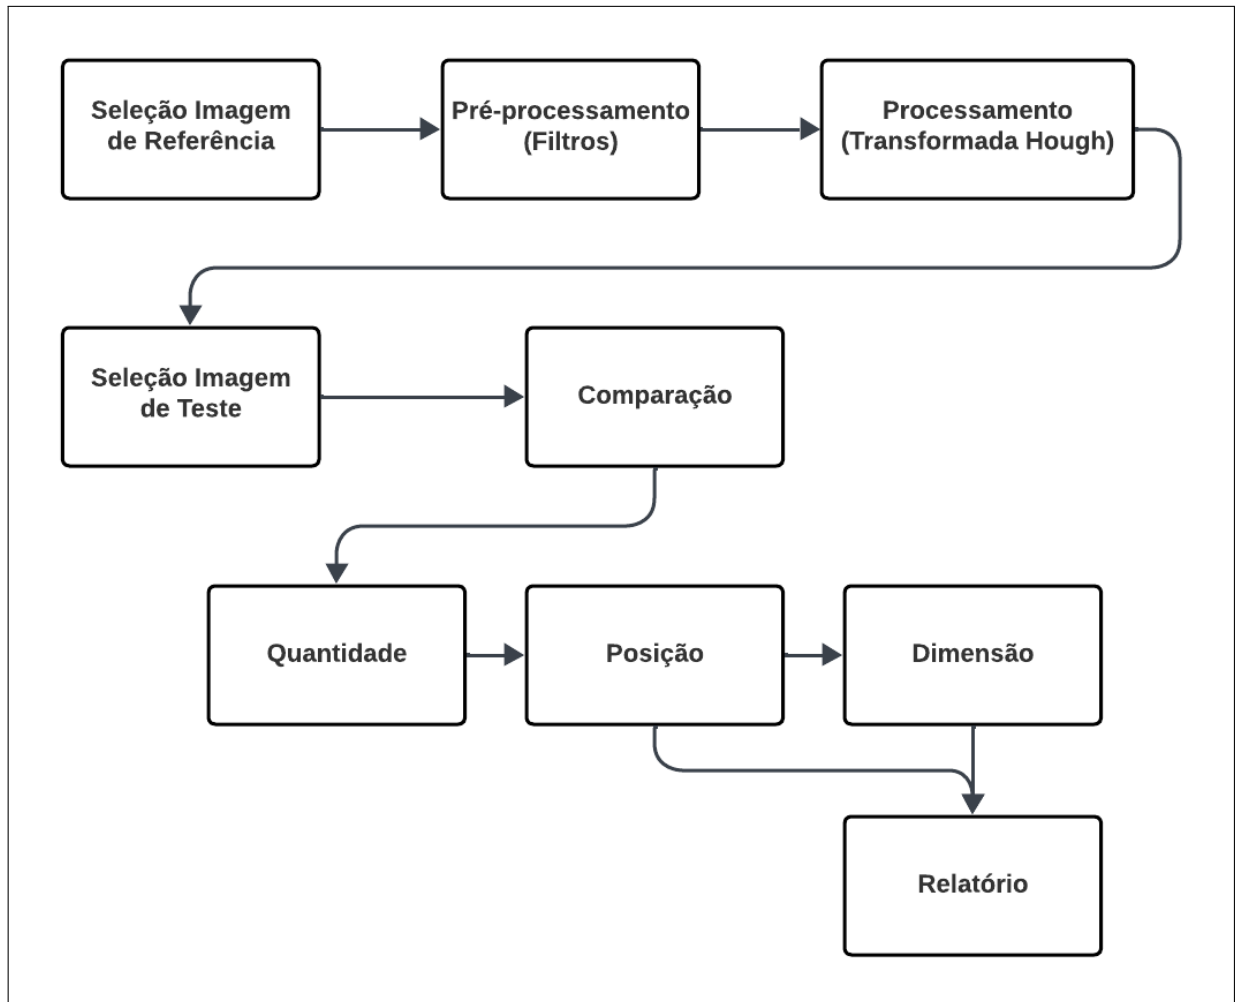
Esse conceito é importante porque, ao invés de verificar o espaço de Hough de forma indiscriminada, podemos focar em segmentos específicos do cone circular, o que reduz significativamente o número de parâmetros a serem avaliados. Ao usar a direção do gradiente, a função de Hough pode realizar uma busca mais direcionada e eficiente, garantindo que apenas as partes mais relevantes do espaço de Hough sejam incrementadas. Isso é especialmente útil para reduzir o tempo computacional e aumentar a precisão da detecção de círculos.

De forma geral, a detecção de círculos usando a Transformada de Hough com gradiente é muito eficiente porque limita a busca ao longo da direção mais provável, ou seja, ao longo da linha de maior variação de intensidade da borda, o que faz com que a detecção de círculos seja mais rápida e precisa.

3 METODOLOGIA

Para atingir os objetivos propostos, apresenta-se a metodologia adotada para o desenvolvimento do trabalho, na qual é representada pelo mapa conceitual na Figura 11.

Figura 11 – Mapa Conceitual.



Fonte: Elaborado pelo autor, 2024.

O mapa conceitual descreve o funcionamento do sistema de visão, desenvolvido em Python, para detectar e comparar círculos em imagens de referência e de teste. O processo inicia-se com a seleção da imagem de referência, que passa por um pré-processamento (aplicação do filtro Gaussiano, correção de brilho e contraste). Em seguida, utiliza-se a transformada de Hough para detectar círculos. Com a imagem de teste, aplica-se o mesmo método de detecção. A comparação das imagens é feita com base em três critérios: quantidade, posição e dimensão dos círculos.

Primeiramente, o sistema realiza a verificação da quantidade de círculos presentes na peça. Se a quantidade corresponder à especificada na peça de referência, o resultado é classificado como OK; caso contrário, como NOK.

Em seguida, é analisada a posição dos círculos. Cada círculo é comparado com as posições de referência, e, se todos estiverem dentro dos limites tolerados, o resultado para este critério também será OK. Caso contrário, o sistema classifica o critério como NOK.

Por fim, para as peças que obtiveram OK no critério de posição, realiza-se a avaliação da dimensão dos círculos. Se os diâmetros estiverem dentro das tolerâncias especificadas, o critério de dimensão recebe o status OK; caso contrário, NOK.

Ao término de todas as análises, o sistema compila os resultados de cada critério e gera um relatório em PDF, que apresenta o status final da peça avaliada, detalhando os critérios aprovados ou reprovados.

As próximas seções descrevem melhor como foi realizada cada atividade elencada acima, bem como apresentam o que foi produzido em cada uma.

3.1 Software e Materiais Utilizados

Durante a execução deste trabalho, foram utilizados diversos materiais e ferramentas para o desenvolvimento do sistema de visão proposto. Abaixo, apresenta-se uma Tabela 1 com os itens empregados, suas respectivas descrições, quantidades:

Tabela 1 – Tabela de materiais.

Quantidade	Item	Descrição
15	Peças impressas em 3D	PLA branco
1	Suporte para celular impresso em 3D	PLA branco
1	Caixa	Papelão
1	Celular	iPhone 15
1	Aplicativo em Python	-

Fonte: Elaborado pelo autor, 2024.

3.1.1 Software

Neste estudo, a linguagem de programação *Python* e a biblioteca OpenCV foram utilizadas para criar um sistema de inspeção automática, focado na detecção, localização e avaliação da qualidade de círculos em peças de impressão 3D. A escolha do *Python* foi motivada pela sua simplicidade, ampla gama de bibliotecas e suporte da comunidade, o que facilita o desenvolvimento ágil do projeto. Já a OpenCV, conhecida por sua vasta coleção de algoritmos para visão computacional, é crucial para manipular e processar as imagens, destacando-se na detecção de círculos através da transformada de Hough circular, mesmo sob variações de iluminação, tamanho e orientação.

A implementação deste sistema demonstra a eficácia da combinação do *Python* com a *OpenCV* na realização de tarefas complexas de visão computacional, como a inspeção de qualidade em manufatura aditiva. Utilizando algoritmos específicos, o software desenvolvido é capaz de analisar minuciosamente cada círculo detectado, avaliando aspectos como diâmetro e posição, o que possibilita a identificação precisa de defeitos. Assim, este trabalho contribui para a automação e otimização do controle de qualidade na produção de peças impressas em 3D.

3.1.2 Peças de Impressão 3D

A implementação de peças produzidas por impressão 3D como material de teste no desenvolvimento de sistemas de visão computacional representa um avanço notável, especialmente no contexto da inspeção de qualidade. Neste estudo, a abordagem metodológica envolveu a criação de quinze peças distribuídas em três grupos distintos, como pode ser visto na Figura 12. Cada grupo incluía uma peça de referência, desenhada com um número específico de círculos para servir como padrão, e outras quatro peças de teste que apresentavam variações tanto na quantidade quanto no posicionamento desses círculos. Este design experimental permitiu uma avaliação rigorosa da capacidade do sistema de visão em detectar diferenças sutis entre as peças de referência e de teste, essencial para a validação da precisão e da eficácia do sistema.

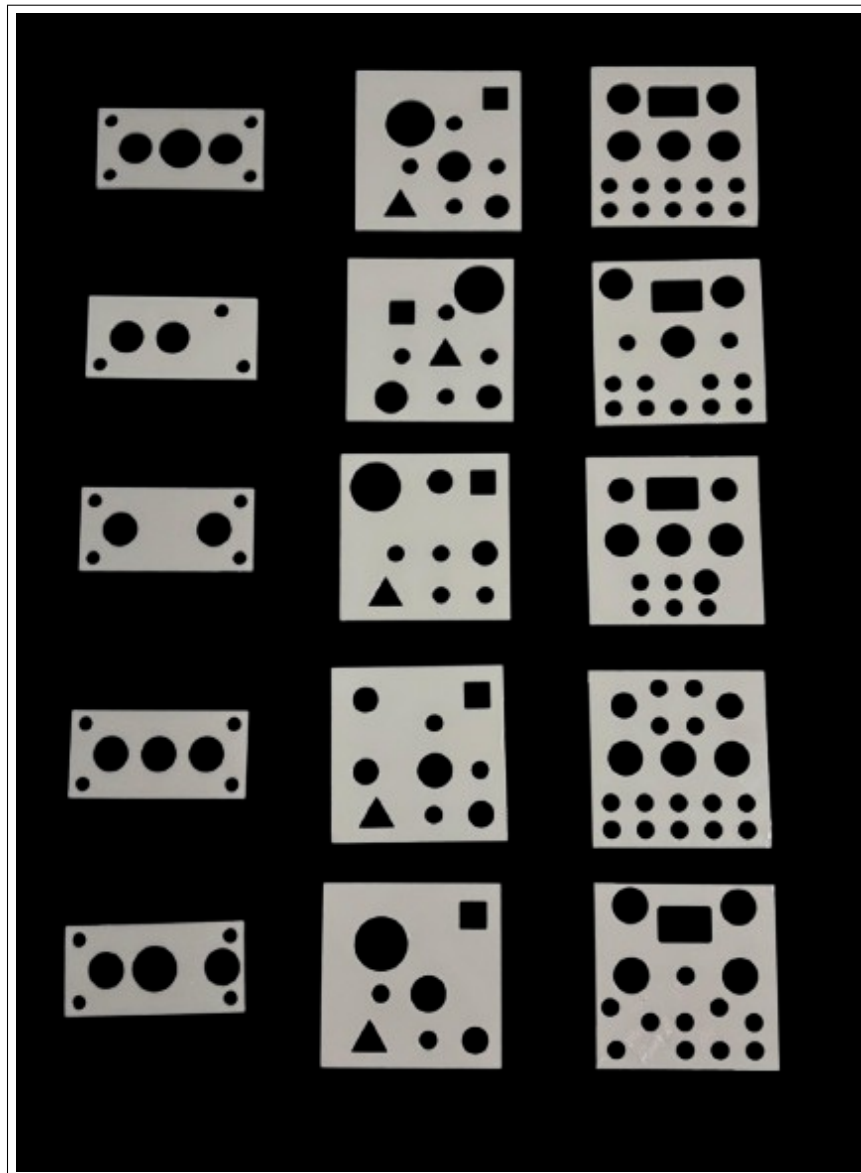
Além disso, a estratégia de alterar a orientação das peças durante os testes enriqueceu significativamente o conjunto de dados disponível para análise, simulando uma gama mais ampla de possíveis desvios de fabricação. Também foram utilizadas imagens dos desenhos feitos no *Autocad*, como pode ser observado na Figura 13. A utilização da impressão 3D para produzir peças com características detalhadamente controladas ilustrou a sinergia entre manufatura aditiva e visão computacional, destacando o valor desta tecnologia na customização de materiais de teste. Através deste procedimento, foi possível não apenas testar a eficácia do sistema de visão em condições variáveis, mas também enfatizar a contribuição significativa da impressão 3D na evolução dos métodos de inspeção automatizada de qualidade, demonstrando sua capacidade de produzir componentes complexos que atendem às exigências específicas de pesquisa e desenvolvimento na área.

3.2 Aquisição das Imagens

Dentro do escopo deste projeto, a escolha das imagens representa o pilar central do sistema de visão computacional, atuando como um padrão ideal para a avaliação subsequente das peças fabricadas. Essas imagens funcionam como modelos exemplares, servindo de base para a comparação e análise detalhada das características geométricas das peças inspecionadas.

A captura dessas imagens cruciais foi realizada utilizando a câmera do iPhone 15, que se destaca por seu sensor de 48 megapixels. Para assegurar a uniformidade e a precisão nas

Figura 12 – Conjunto de peças de impressão 3D.




Fonte: Elaborado pelo autor, 2024.

imagens capturadas, desenvolveu-se um protocolo de captura controlado, incluindo a construção de uma caixa customizada que funciona como um estúdio fotográfico, como pode ser observado na Figura 14. Essa estrutura foi projetada para garantir uma iluminação homogênea, minimizando qualquer influência de reflexos ou sombras que pudessem obstruir a clareza das características visuais. No interior desta caixa, um gabarito de posicionamento foi empregado para fixar cada peça em um alinhamento padronizado, assegurando a estabilidade e a consistência na orientação das peças.

Este procedimento de captura de imagens cria uma base sólida para o processo de inspeção subsequente, minimizando discrepâncias não associadas às propriedades intrínsecas das peças, como variações na posição dos elementos ou nas dimensões devido a alterações na distância focal ou ângulo de captura. Assim, a estratégia empregada na seleção das imagens sublinha o

Figura 13 – Conjunto de peças desenhadas no Autocad.



Fonte: Elaborado pelo autor, 2024.

Figura 14 – Caixa de testes.



Fonte: Elaborado pelo autor, 2024.


compromisso com a precisão e a fiabilidade indispensáveis ao sucesso dos sistemas de visão computacional na verificação da qualidade em processos de manufatura.

3.3 Pré-processamento

Dentro deste projeto, o pré-processamento das imagens emerge como uma fase crítica, estabelecendo a fundação para a análise precisa das peças por meio do sistema de visão computacional. Este processo primordial de tratamento digital visa otimizar as imagens capturadas, aprimorando sua qualidade e, conseqüentemente, a acuidade na detecção das características

específicas das peças. Inicialmente, as imagens passam por um redimensionamento para uma resolução estabelecida, garantindo a uniformidade da escala e a consistência do tamanho dos *pixels* - um passo crucial para assegurar a comparação precisa das características nas análises subsequentes.

Figura 15 – Etapas do Pré-processamento.



Fonte: Elaborado pelo autor, 2024.

Segue-se a conversão das imagens para escala de cinza, simplificando a análise ao reduzir as imagens a um único canal de cor, o que diminui a complexidade computacional e aprimora a eficiência dos algoritmos de visão computacional na detecção de formas e contornos. Esta etapa é estratégica, pois as nuances de cores são muitas vezes desnecessárias quando o objetivo é focar na detecção de estruturas específicas dentro das imagens. Além disso, a filtragem de ruído através de uma técnica Gaussiana é aplicada para refinar a qualidade das imagens, removendo variações aleatórias de *pixel* que não correspondem às características reais das peças inspecionadas e preservando as bordas necessárias para uma identificação clara. Na Figura 15, é possível observar os processos pelos quais a imagem passa.

Por fim, o algoritmo de realce de borda Canny é empregado para identificar com precisão as bordas dentro das imagens. Este método é amplamente reconhecido por sua capacidade de minimizar falsos positivos, graças a um processo cuidadoso que inclui a suavização da imagem de escala de cinza e a detecção de gradientes de intensidade, culminando na aplicação de uma histerese de dois limiares para discernir as verdadeiras bordas. Este conjunto de etapas, desde o redimensionamento até o realce de borda, prepara as imagens para uma inspeção detalhada,

reforçando a confiabilidade do sistema de visão computacional na avaliação metódica das peças fabricadas, estabelecendo assim uma base sólida para o sucesso do processo de inspeção.

3.4 Calibração dos Parâmetros da Transformada de Hough

A calibração dos parâmetros da Transformada de Hough constitui um passo crítico para o sucesso do sistema de visão computacional proposto. A Transformada de Hough, sendo um método padrão para a detecção de formas geométricas, é particularmente adaptada para a identificação de círculos em imagens, que é essencial para a nossa aplicação de inspeção de qualidade em peças manufaturadas. O processo de calibração garante que o sistema não apenas detecte os círculos com precisão, mas também que minimize falsos positivos e negativos.

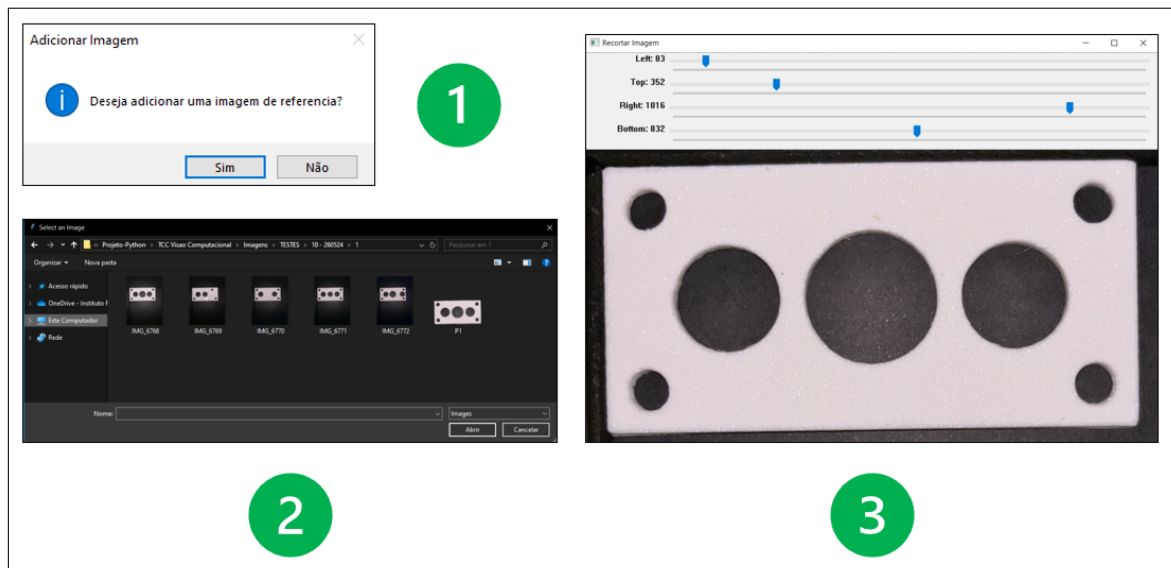
No sistema desenvolvido, proporciona-se ao usuário a liberdade de calibrar quatro parâmetros principais:

1. **min_dist:** Este parâmetro controla a distância mínima entre os centros dos círculos detectados. Configurar esse valor adequadamente evita múltiplas detecções do mesmo círculo e a detecção de círculos próximos como se fossem um único.
2. **param2:** Esse parâmetro é usado pelo detector de círculos para definir o limiar de votação no acumulador de Hough. Um valor mais alto diminui a sensibilidade, evitando a detecção de círculos falsos, enquanto um valor mais baixo pode detectar mais círculos, mas também pode aumentar o número de falsos positivos.
3. **min_radius** e **max_radius:** Estes parâmetros definem o raio mínimo e máximo dos círculos a serem detectados. Ao ajustá-los, o usuário pode restringir a detecção aos círculos dentro de um intervalo de tamanho esperado.

A aplicação desenvolvida inicia solicitando ao usuário a seleção de uma imagem de referência, como é apresentado na Figura 16. Essa imagem serve como base para as análises subsequentes, sendo essencial para a comparação das peças avaliadas. Após a seleção, a imagem passa por um processo de redimensionamento e recorte, no qual são aplicados ajustes para garantir que somente a peça de interesse permaneça visível na área útil da imagem. Esse procedimento é fundamental para eliminar informações irrelevantes do fundo e assegurar que a análise seja precisa, concentrando-se exclusivamente nos elementos da peça que devem ser avaliados, como quantidade, posição e dimensão dos furos.

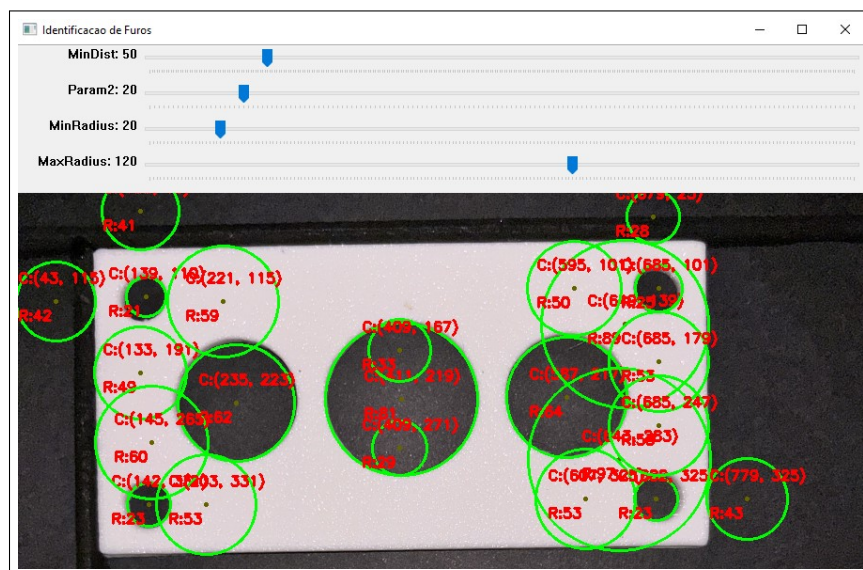
Para auxiliar os usuários na seleção dos parâmetros ideais, segue um guia passo a passo:

Figura 16 – Seleção das imagens.



Fonte: Elaborado pelo autor, 2024.

Figura 17 – Parâmetros padrão.

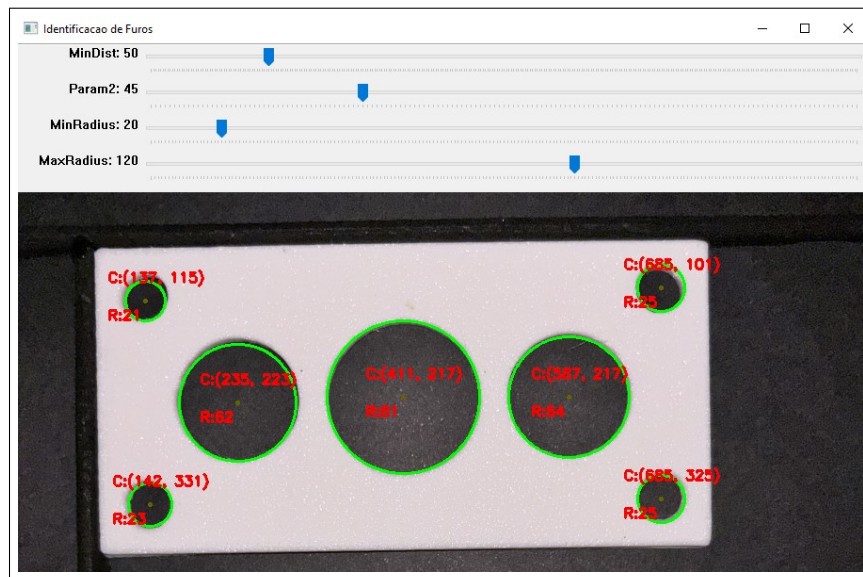


Fonte: Elaborado pelo autor, 2024.

Passo 1: Configuração Inicial - Figura 18

- Comece com valores de ‘param2’ relativamente altos para garantir que apenas os círculos mais evidentes sejam detectados.
- Ajuste ‘min_dist’ para o valor aproximado do diâmetro esperado do maior círculo para prevenir a detecção múltipla de um único círculo.

Figura 18 – Configuração: Passo 1.



Fonte: Elaborado pelo autor, 2024.

Passo 2: Ajuste dos Raios - Figura 19

- Estabeleça 'min_radius' e 'max_radius' baseando-se nos tamanhos de círculo conhecidos da imagem de referência.
- Realize testes iterativos, ajustando os valores de raio para encontrar o equilíbrio que maximize a detecção de círculos verdadeiros e minimize a detecção de artefatos indesejados.

Figura 19 – Configuração: Passo 2.

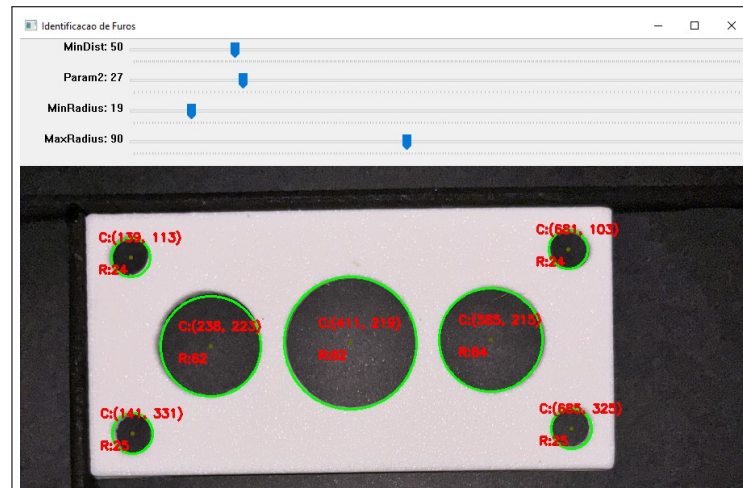


Fonte: Elaborado pelo autor, 2024.

Passo 3: Refinamento de Param2 - Figura 20

- Diminua progressivamente o 'param2' até começar a notar a detecção de círculos falsos, então aumente ligeiramente para manter a precisão.

Figura 20 – Configuração: Passo 3.



Fonte: Elaborado pelo autor, 2024.

Passo 4: Ajuste Final de Min_Dist - Figura 21

- Com os parâmetros de raio e 'param2' configurados, faça ajustes finos em 'min_dist' para otimizar a separação entre círculos próximos, caso esse valor for muito alto, os círculos próximos não serão detectados.

O objetivo desses passos é assegurar que o sistema de visão está afinado para a tarefa de detecção de círculos com a máxima eficiência. Ao capacitar os usuários com a habilidade de ajustar esses parâmetros, o sistema não somente se torna mais flexível e adaptável às condições de produção variáveis, mas também garante que a qualidade da inspeção permaneça consistentemente alta.


Caso os passos de calibração do sistema não sejam seguidos corretamente, podem ocorrer erros significativos durante a detecção dos furos nas peças. Um exemplo comum é a configuração inadequada do parâmetro param2, que pode levar à detecção de falsos furos caso o valor seja muito baixo, como pode ser observado na Figura 22, ou à falha em detectar furos reais se o valor for muito alto, observado na Figura 23. Além disso, um ajuste incorreto de min_dist pode resultar na fusão de furos próximos, fazendo com que o sistema os interprete como um único furo, observado na Figura 24, ou na detecção de múltiplos furos onde deveria haver apenas um, observado na Figura 25. Essas falhas comprometem a precisão da inspeção, levando à reprovação de peças que estão de acordo com as especificações ou à aprovação de peças com defeitos.

Figura 21 – Configuração: Passo 4.



Fonte: Elaborado pelo autor, 2024.

Figura 22 – Valor do parâmetro param2 baixo.




Fonte: Elaborado pelo autor, 2024.

3.5 Seleção da Imagem de Teste

A seleção da imagem de teste segue diretamente a detecção de características circulares na imagem de referência, utilizando os mesmos parâmetros de captura e ambiente controlado, para garantir uma base comparativa coerente. Para tal, as imagens de teste são adquiridas utilizando a mesma câmera, mantendo a uniformidade com o processo de captura da imagem de referência, de modo a eliminar variações resultantes do equipamento ou do ambiente.


Durante a seleção da imagem de teste, o usuário deve assegurar-se de que a peça a ser inspecionada esteja corretamente posicionada no gabarito. Uma vez que a peça está fixada, a câmera captura a imagem sob as mesmas condições da imagem de referência. Esta padronização é vital, pois quaisquer discrepâncias nas condições de captura entre as imagens de referência e de

Figura 23 – Valor do parâmetro param2 alto.



Fonte: Elaborado pelo autor, 2024.

Figura 24 – Valor do parâmetro min_dist alto.



Fonte: Elaborado pelo autor, 2024.

teste podem levar a variações nos resultados da inspeção, afetando a confiabilidade do processo de avaliação.

Após a captura, a imagem de teste é submetida ao mesmo processo de pré-processamento que a imagem de referência. Este procedimento inclui redimensionamento, conversão para escala de cinza, filtragem de ruído e realce de borda. Estes passos asseguram que a imagem de teste está em plena concordância com as condições da imagem de referência, permitindo uma comparação válida e precisa na subsequente etapa de análise pelo sistema de visão.

A consistência na captura de imagens de teste é crítica para a integridade da inspeção visual. Qualquer variação pode comprometer a eficácia do sistema de visão computacional em realizar avaliações confiáveis. Portanto, esta etapa é conduzida com extrema atenção aos detalhes, assegurando que o sistema de visão computacional possa operar com a máxima eficiência e precisão.

Figura 25 – Valor do parâmetro min_dist baixo.



Fonte: Elaborado pelo autor, 2024.

3.6 Comparação das Imagens

A comparação das imagens representa a parte mais importante do sistema de inspeção por visão computacional delineado neste trabalho. Essa fase é crítica, pois é onde se avalia se as peças produzidas estão em conformidade com as especificações técnicas desejadas, tomando como base a imagem de referência pré-estabelecida. Esta comparação é meticulosamente realizada por meio de três critérios distintos, que, conjuntamente, garantem uma avaliação abrangente e detalhada das peças inspecionadas.

3.6.1 Critério 1: Conformidade Quantitativa de Furos

O primeiro critério consiste na comparação quantitativa das características circulares detectadas – especificamente, o número de círculos presentes na imagem de teste é confrontado com o número de círculos na imagem de referência. A correspondência exata no número de círculos é fundamental, visto que uma discrepância nesse aspecto pode indicar a presença de defeitos de fabricação, como furos ausentes ou adicionais, que poderiam comprometer a funcionalidade ou a integridade estrutural da peça.

3.6.2 Critério 2: Posicionamento dos Furos

O segundo critério avalia a posicionamento dos círculos, isto é, se os centros dos círculos detectados na imagem de teste alinham-se adequadamente aos centros correspondentes na imagem de referência. Esse alinhamento é crucial para aplicações que exigem um elevado grau de precisão na montagem e no alinhamento das peças, como nos setores aeroespacial e automotivo.

3.6.3 Critério 3: Verificação das Especificações Dimensionais

Por fim, o terceiro critério aborda a verificação das especificações dimensionais dos círculos. Aqui, o foco é medir e comparar os raios dos círculos detectados com aqueles da imagem de referência. A aderência estrita às dimensões prescritas é indispensável para assegurar que as peças atendam a tolerâncias dimensionais rigorosas, especialmente para componentes usados em contextos críticos de segurança.

Cada critério é apoiado por algoritmos que processam as informações extraídas durante a detecção de características circulares. As coordenadas dos centros dos círculos e seus raios são submetidos a um processo analítico que identifica variações e as compara às tolerâncias definidas. No caso de discrepâncias serem detectadas, o sistema procede com a geração de relatórios detalhados que documentam as inconsistências, possibilitando intervenções corretivas no processo de manufatura.

Através deste processo triplice de comparação, o sistema de visão computacional oferece uma garantia de qualidade ímpar. É uma etapa de inspeção que, pela sua precisão e confiabilidade, exemplifica o avanço proporcionado pelas tecnologias de visão computacional na indústria de manufatura moderna.

3.7 Geração do Relatório

A fase de geração do relatório é uma parte integral do processo de inspeção pelo sistema de visão computacional desenvolvido neste estudo. A precisão na documentação e análise dos resultados é vital para a validação da qualidade da manufatura das peças inspecionadas. Os exemplos de relatórios observados nos Apêndice A fornecem uma estrutura sistemática para apresentar as descobertas da inspeção, as quais são discutidas a seguir.

1. Apresentação Visual das Imagens

O relatório começa com a apresentação das imagens de referência e de teste lado a lado. Nestas imagens, os círculos identificados são claramente marcados com etiquetas — letras maiúsculas para a imagem de referência e números para a imagem de teste. Esta representação visual é crucial, pois oferece uma verificação rápida e intuitiva das discrepâncias e conformidades entre as duas imagens.

2. Tabelas de Localização e Dimensões

A seguir, o relatório apresenta tabela detalhada com as localizações (coordenadas x, y) e os raios dos círculos detectados. Estes dados permitem uma comparação quantitativa rigorosa entre os círculos da imagem de referência e os da imagem de teste, além de servirem como registro para controle de qualidade e rastreabilidade.

3. Gráficos de Dispersão e Barras

Um gráfico de dispersão é gerado para mostrar a variação da posição dos furos entre a peça de referência e a peça de teste. As coordenadas X e Y dos furos são comparadas, e as discrepâncias na posição são visíveis como diferenças nos pontos plotados. O gráfico permite identificar se os furos no teste estão alinhados corretamente com os furos de referência ou se há desvios.

Um gráfico de barras é criado para representar as variações nas dimensões dos furos (raios dos círculos) entre a peça de referência e a peça de teste. Cada barra no gráfico compara o raio de um furo da peça de referência com o raio do furo correspondente na peça de teste. Isso é útil para verificar a precisão dos tamanhos dos furos e se eles atendem às especificações.

4. Análise de Resultados

Esta etapa é responsável por gerar o Relatório Resumido que apresenta uma comparação quantitativa e qualitativa entre a peça de referência e a peça de teste com relação à quantidade de furos, posição dos furos e dimensão dos furos. Primeiro, são calculadas as quantidades reais de furos em ambas as peças, sendo o total de furos na peça de referência comparado ao total da peça de teste. Em seguida, são calculados os percentuais de furos aprovados e reprovados para as posições e dimensões, baseados na compatibilidade entre as peças dentro de uma tolerância. Para cada critério, o código avalia se o resultado é "Aprovado" ou "Reprovado" e inclui isso na tabela final. A tabela gerada resume os resultados com colunas que mostram o número de furos aprovados, reprovados, o percentual de aprovação e o status final de cada critério.

4 RESULTADOS

A aplicação desenvolvida inicia solicitando ao usuário a seleção de uma imagem de referência. Essa imagem serve como base para as análises subseqüentes, sendo essencial para a comparação das peças avaliadas. Após a seleção, a imagem passa por um processo de redimensionamento e recorte, no qual são aplicados ajustes para garantir que somente a peça de interesse permaneça visível na área útil da imagem. Esse procedimento é fundamental para eliminar informações irrelevantes do fundo e assegurar que a análise seja precisa, concentrando-se exclusivamente nos elementos da peça que devem ser avaliados, como quantidade, posição e dimensão dos furos.

As peças de teste foram projetadas de forma a possibilitar que o sistema fosse testado e validado para os três critérios de avaliação definidos: verificação da quantidade de furos, análise do posicionamento dos furos e avaliação das suas dimensões. Para isso, as peças foram criadas com furos de quantidades variadas, posições diferentes e dimensões distintas, garantindo a abrangência e robustez dos testes realizados.

Para avaliar o sistema de visão computacional proposto, foram realizados testes com quinze peças impressas em 3D na cor branca. As peças foram organizadas em três grupos, sendo que cada grupo continha uma peça de referência e quatro peças de teste, projetadas para apresentar variações em relação à referência.


As imagens das peças foram capturadas dentro de uma caixa de teste, utilizando uma câmera de 48 MP com resolução de 3024x4032 pixels. A iluminação foi fornecida pelo flash da própria câmera, garantindo a uniformidade da luz e minimizando interferências externas que pudessem afetar o resultado.

Os testes foram analisados com base nos objetivos estabelecidos, avaliando a conformidade das peças quanto à quantidade, posicionamento e dimensões dos furos. Os resultados obtidos demonstraram a eficácia do sistema desenvolvido, validando sua capacidade de alcançar os objetivos propostos.

4.1 Grupo 1

Para facilitar a organização e análise dos resultados, cada grupo de peças foi avaliado individualmente. Uma imagem de referência foi utilizada para cada grupo, servindo de padrão para comparação com as demais peças testadas. Vale destacar que os resultados dos testes podem ser classificados como "NOK", mas isso não significa que o sistema falhou na análise. Essa classificação ocorre devido às modificações propositalmente inseridas nas peças de teste, como variações na quantidade, posição e dimensões dos furos, com o objetivo de avaliar e validar a capacidade do sistema de identificar corretamente as diferenças em relação à referência.

Figura 26 – Peça de referência - Grupo 1.



Fonte: Elaborado pelo autor, 2024.

Tabela 2 – Resultados Esperados/Obtidos - Grupo 1

Testes	Quantidade de furos (OK/NOK)		Posição (OK/NOK)		Dimensão (OK/NOK)	
	Esperados	Obtidos	Esperados	Obtidos	Esperados	Obtidos
Teste 1	NOK	NOK	NOK	NOK	-	-
Teste 2	NOK	NOK	OK	OK	OK	OK
Teste 3	OK	OK	OK	OK	NOK	NOK
Teste 4	OK	OK	NOK	NOK	-	-
Teste 5	OK	OK	OK	OK	OK	OK

Fonte: Elaborado pelo autor, 2024.

O Grupo 1 possui uma peça de referência com 7 furos, distribuídos na superfície da peça, como é mostrado na Figura 26. Esses furos foram analisados com base nos critérios avaliados, servindo como uma referência inicial para o desempenho do sistema em detectar furos de maneira uniforme e precisa.

A Tabela 2 apresenta os resultados esperados e obtidos para o Grupo 1, considerando os critérios de quantidade de furos, posição dos furos e dimensão dos furos. Em cada teste, são indicados os resultados esperados e os valores obtidos, classificados como "OK" para aprovação e "NOK" para reprovação.

No Teste 1, era esperado que os critérios de quantidade e posição apresentassem NOKs, e os resultados confirmaram essa expectativa, com falhas em ambos os critérios. Nesse caso, o critério de dimensão não foi avaliado, pois a posição é um parâmetro que, se não atendido, invalida a verificação da dimensão.

No Teste 2, a quantidade de furos era esperada como incorreta, enquanto a posição e a dimensão deveriam estar corretas. Os resultados obtidos coincidiram com essas expectativas, resultando em aprovação apenas para os critérios de posição e dimensão, mas reprovação geral devido ao NOK na quantidade de furos.

Para o Teste 3, tanto a quantidade quanto a posição dos furos eram esperadas como

corretas, com NOK apenas na dimensão. Os resultados obtidos foram idênticos aos esperados, com aprovação em quantidade e posição, e reprovação no critério de dimensão.

No Teste 4, era esperado que apenas a posição estivesse incorreta, enquanto os critérios de quantidade e dimensão deveriam atender às especificações. Como esperado, o NOK na posição resultou na reprovação do teste, e o critério de dimensão não foi avaliado, devido à falha no critério de posição.


Por fim, no Teste 5, todos os parâmetros estavam corretos tanto nos resultados esperados quanto nos obtidos, resultando em aprovação completa da peça.

Esses dados indicam que o sistema reprova a peça sempre que algum dos critérios apresenta falhas e que a avaliação do critério de dimensão só ocorre se o critério de posição estiver corretamente atendido. Esse processo de avaliação em cascata garante que o critério de posição seja priorizado, uma vez que ele afeta diretamente a funcionalidade e a compatibilidade da peça com as especificações do projeto.

4.2 Grupo 2

O Grupo 2 possui uma peça de referência com 7 furos, além de duas formas geométricas adicionais, um triângulo e um quadrado, como é mostrado na Figura 27. A inclusão dessas formas tem como objetivo aumentar a variedade de peças testadas e verificar se o sistema de visão consegue identificar exclusivamente furos (círculos), sem ser confundido por outras formas geométricas. Essa complexidade extra possibilita uma análise mais aprofundada sobre a eficácia do sistema na diferenciação entre círculos e outras figuras.

Figura 27 – Peça de referência - Grupo 2.



Fonte: Elaborado pelo autor, 2024.

Tabela 3 – Resultados Esperados/Obtidos - Grupo 2


Testes	Quantidade de furos (OK/NOK)		Posição (OK/NOK)		Dimensão (OK/NOK)	
	Esperados	Obtidos	Esperados	Obtidos	Esperados	Obtidos
Teste 1	OK	NOK	NOK	NOK	-	-
Teste 2	OK	OK	NOK	NOK	-	-
Teste 3	OK	NOK	NOK	NOK	-	-
Teste 4	NOK	NOK	OK	OK	OK	OK
Teste 5	OK	OK	OK	OK	OK	OK

Fonte: Elaborado pelo autor, 2024.

A Tabela 3 apresenta os resultados esperados e obtidos para o Grupo 2. Cada teste compara os valores previstos com os obtidos, sendo "OK" utilizado para indicar conformidade e "NOK" para não conformidade.

No Teste 1, esperava-se que a quantidade de furos estivesse correta e a posição incorreta. No entanto, o critério de quantidade falhou, resultando em NOK nos valores obtidos. Ao investigar a causa do problema, foi identificado um falso positivo na detecção dos furos: o sistema confundiu uma forma geométrica quadrada com uma circunferência como pode ser visto na Figura 28.

Figura 28 – Falso positivo na peça do Teste 3.



Fonte: Elaborado pelo autor, 2024.

No Teste 2, apenas o critério de quantidade de furos era esperado como correto, enquanto os critérios de posição e dimensão deveriam apresentar NOK. Os resultados obtidos confirmaram a expectativa, com a posição reprovada e a dimensão não avaliada devido à falha na posição.

Para o Teste 3, esperava-se que apenas a quantidade de furos estivesse correta, com NOK previsto no critério de posição. No entanto, os resultados obtidos apresentaram NOK também na quantidade de furos. Após análise, foi novamente identificado um falso positivo causado pela confusão do sistema entre uma forma geométrica quadrada e uma circunferência.

No Teste 4, era previsto NOK somente no critério de quantidade de furos, enquanto os critérios de posição e dimensão deveriam estar em conformidade. Os resultados obtidos confirmaram essa previsão, resultando em aprovação nos critérios de posição e dimensão, mas reprovação geral devido ao NOK na quantidade de furos.


Por fim, no Teste 5, todos os critérios esperados estavam em conformidade, e os resultados obtidos também atenderam às expectativas, resultando na aprovação total da peça.

Essa análise evidencia a importância de reduzir os falsos positivos no sistema, especialmente quando formas geométricas diferentes podem ser confundidas com furos.

4.3 Grupo 3

O Grupo 3 possui uma peça de referência com um total de 15 furos, acompanhados por uma forma geométrica adicional, um retângulo, como é mostrado na Figura 29. Essa estrutura mais complexa não só amplia o número de furos a serem avaliados como também testa a capacidade do sistema de visão de ignorar formas não circulares e focar na detecção precisa dos furos. A presença do retângulo serve para verificar se outras formas geométricas influenciam ou confundem o sistema na análise.

Figura 29 – Peça de referência - Grupo 3.



Fonte: Elaborado pelo autor, 2024.

A Tabela 4 apresenta os resultados esperados e obtidos para o Grupo 3. Os resultados esperados foram confrontados com os valores obtidos, indicando "OK" para conformidade e "NOK" para não conformidade.

No Teste 1, esperava-se que todos os critérios apresentassem NOK, o que foi confirmado nos resultados obtidos. Como a posição estava incorreta, o critério de dimensão não foi avaliado, seguindo a lógica do sistema de avaliação sequencial.

Tabela 4 – Resultados Esperados/Obtidos - Grupo 3

Testes	Quantidade de furos (OK/NOK)		Posição (OK/NOK)		Dimensão (OK/NOK)	
	Esperados	Obtidos	Esperados	Obtidos	Esperados	Obtidos
Teste 1	NOK	NOK	NOK	NOK	-	-
Teste 2	NOK	NOK	OK	OK	NOK	NOK
Teste 3	NOK	NOK	OK	OK	NOK	NOK
Teste 4	NOK	NOK	NOK	NOK	-	-
Teste 5	OK	OK	OK	OK	OK	OK

Fonte: Elaborado pelo autor, 2024.

No Teste 2, os critérios de quantidade de furos e dimensão deveriam estar incorretos, enquanto a posição deveria estar correta. Os resultados obtidos coincidiram com as expectativas, com NOK em quantidade e dimensão, e aprovação apenas no critério de posição.

Para o Teste 3, como ocorreu no teste 2 os critérios de quantidade de furos e dimensão deveriam estar incorretos, enquanto a posição deveria estar correta. Os resultados obtidos coincidiram com as expectativas, com NOK em quantidade e dimensão, e aprovação apenas no critério de posição.

No Teste 4, esperava-se que todos os critérios apresentassem NOK, o que foi confirmado nos resultados obtidos. Como a posição estava incorreta, o critério de dimensão não foi avaliado, seguindo a lógica do sistema de avaliação sequencial.

Por fim, no Teste 5, todos os critérios deveriam estar em conformidade. Os resultados obtidos atenderam às expectativas, resultando na aprovação completa da peça.

4.4 Resumo dos Resultados

A Tabela 5 a seguir apresenta um resumo dos resultados obtidos durante a realização dos testes. Ela organiza as informações de maneira clara, destacando as comparações entre os valores esperados e os valores obtidos para cada critério analisado: quantidade de furos, posição e dimensão. A estrutura da tabela permite uma visualização eficiente dos resultados de cada grupo e teste, evidenciando as discrepâncias entre os valores esperados e os valores observados em cada caso.

Tabela 5 – Resumo dos Resultados

Grupos	Testes	Quantidade de furos (OK/NOK)		Posição (OK/NOK)		Dimensão (OK/NOK)	
		Esperados	Obtidos	Esperados	Obtidos	Esperados	Obtidos
Grupo 1	Teste 1	NOK	NOK	NOK	NOK	-	-
	Teste 2	NOK	NOK	OK	OK	OK	OK
	Teste 3	OK	OK	OK	OK	NOK	NOK
	Teste 4	OK	OK	NOK	NOK	-	-
	Teste 5	OK	OK	OK	OK	OK	OK
Grupo 2	Teste 1	OK	NOK	NOK	NOK	-	-
	Teste 2	OK	OK	NOK	NOK	-	-
	Teste 3	OK	NOK	NOK	NOK	-	-
	Teste 4	NOK	NOK	OK	OK	OK	OK
	Teste 5	OK	OK	OK	OK	OK	OK
Grupo 3	Teste 1	NOK	NOK	NOK	NOK	-	-
	Teste 2	NOK	NOK	OK	OK	NOK	NOK
	Teste 3	NOK	NOK	OK	OK	NOK	NOK
	Teste 4	NOK	NOK	NOK	NOK	-	-
	Teste 5	OK	OK	OK	OK	OK	OK

Fonte: Elaborado pelo autor, 2024.

5 CONCLUSÃO

Este trabalho propôs a implementação de um sistema de visão computacional para a análise de características posicionais e dimensionais das furações de peças impressas em 3D. A contribuição acadêmica desta pesquisa reside na demonstração de um método eficiente para verificar a precisão e a qualidade das peças produzidas, além de apresentar uma solução automatizada que pode ser amplamente utilizada em processos de fabricação aditiva.

Os objetivos estabelecidos para este estudo foram atingidos de forma satisfatória. O desenvolvimento do sistema, incluindo funções para verificar a quantidade de furos, a posição e as dimensões, foi fundamental para a criação de uma metodologia robusta e prática. Durante os testes, o sistema demonstrou eficácia na análise posicional e dimensional das peças, mesmo que erros tenham sido observados em casos específicos na identificação da quantidade de furos.

Os testes realizados mostraram que o sistema atingiu 87% de precisão na identificação da quantidade de furos, enquanto os critérios de posição e dimensão alcançaram 100% de conformidade com os padrões esperados. Esses resultados reforçam a capacidade do sistema de atender aos objetivos propostos, embora ressaltem a necessidade de ajustes em situações específicas para aprimorar a precisão no critério de quantidade.

Os erros no critério de quantidade foram associados à utilização da Transformada de *Hough* para a identificação de formas circulares. Em particular, situações envolvendo formas geométricas quadradas apresentaram desafios, pois bordas suavizadas ou cantos arredondados (resultantes de ruídos ou artefatos) foram erroneamente interpretados como círculos. Isso ocorre porque a Transformada de *Hough* trabalha com um espaço de parâmetros onde cada pixel de borda contribui com "votos" para possíveis círculos. Mesmo que a borda forme um quadrado, partes dessa borda podem gerar votos suficientes para criar um pico no espaço de parâmetros que se assemelha a um círculo, levando a falsos positivos.

Apesar dessas limitações, os resultados gerais confirmam a eficácia do sistema proposto. As peças analisadas apresentaram conformidade significativa com os padrões esperados, demonstrando que a visão computacional é uma ferramenta promissora para o controle de qualidade em processos de fabricação aditiva. Este estudo não apenas comprova o potencial de melhorar processos de produção, mas também oferece uma base sólida para futuras pesquisas voltadas ao aprimoramento de técnicas de detecção e à ampliação do uso de sistemas de visão computacional em outros setores da engenharia e da manufatura.

5.1 Trabalhos Futuros

Para trabalhos futuros, diversas melhorias podem ser implementadas para aumentar a eficiência e a usabilidade do sistema de visão computacional desenvolvido neste estudo. Primeiramente, é fundamental melhorar a interface de utilização do sistema, tornando-a mais intuitiva para

o usuário. Isso facilitará o manuseio e a interpretação dos resultados, permitindo que operadores com diferentes níveis de conhecimento técnico utilizem a ferramenta com maior facilidade.

Uma proposta para o futuro é expandir a gama de formas que o sistema de visão pode detectar e analisar, incorporando a utilização de inteligência artificial para automatizar esse processo. Essa ampliação não apenas tornará o sistema mais versátil e aplicável em diversos tipos de peças e processos de fabricação, mas também melhorará a precisão da detecção por meio de algoritmos de aprendizado de máquina. Com essa abordagem, o sistema será capaz de identificar formas em condições variadas e complexas, aumentando sua robustez e eficácia em cenários industriais diversos. Essa integração permitirá um controle de qualidade mais abrangente e eficiente, adaptando-se às necessidades dinâmicas do ambiente de manufatura.



Adicionalmente, a conversão das medidas de *pixel* para milímetros (mm) deve ser implementada para facilitar a interpretação dos dados pelo usuário. Essa conversão permitirá uma análise mais precisa e intuitiva das dimensões e posições das características das peças, eliminando a necessidade de cálculos adicionais e reduzindo a margem de erro na interpretação dos resultados.

Além disso, a implementação de um banco de dados para armazenar os resultados obtidos é uma melhoria significativa. Um banco de dados estruturado facilitará a busca e a análise histórica dos resultados, permitindo um monitoramento contínuo da qualidade das peças produzidas. Isso não apenas otimizará o processo de controle de qualidade, mas também fornecerá *insights* valiosos para a melhoria contínua dos processos de fabricação.

Essas propostas de melhorias visam aprimorar a funcionalidade e a usabilidade do sistema de visão computacional, tornando-o uma ferramenta ainda mais poderosa e eficiente para a análise de peças impressas em 3D. A implementação dessas modificações pode contribuir significativamente para a evolução das práticas de controle de qualidade na manufatura aditiva, bem como para a realização de novas pesquisas acadêmicas na área.

REFERÊNCIAS

- BALLARD, D. Generalizing the hough transform to detect arbitrary shapes. **Pattern Recognition**, v. 13,n. 2,p. 111–122, 1981.ISSN0031-3203. Disponível em: www.sciencedirect.com. Acesso em: 25 jun. 2024.
- CANNY, J. A computational approach to edge detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, PAMI-8, n. 6, p. 679–698, 1986.
- DUDA, R. O.; HART, P. E. Use of the hough transformation to detect lines and curves in pictures. **Communications of the ACM**, ACM New York, NY, USA, v. 15, n. 1, p. 11–15, 1972.
- FILHO, O. M.; NETO, H. V. **Processamento Digital de Imagens**. 3. ed. Rio de Janeiro, RJ: Brasport, 1999. ISBN 9788574525621.
- GIBSON, I.; ROSEN, D. W.; STUCKER, B. **Additive Manufacturing Technologies: 3D Printing, Rapid Prototyping, and Direct Digital Manufacturing**. 2. ed. New York: Springer, 2015. ISBN 978-1-4939-2112-6.
- GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. [S.l.]: Pearson education india, 2007.
- _____. **Digital Image Processing, Global Edition**. 4. ed. London, England: Pearson Education, 2017.
- NETO, E. C.; REBOUCAS, E. S.; MORAES, J. L. de; GOMES, S. L.; FILHO, P. P. R. Development control parking access using techniques digital image processing and applied computational intelligence. **IEEE Latin America Transactions**, IEEE, v. 13, n. 1, p. 272–276, 2015.
- OTSU, N. *et al.* A threshold selection method from gray-level histograms. **Automatica**, v. 11, n. 285-296, p. 23–27, 1975.
- POPESCU, D.; AMZA, C. G.; MARINESCU, R.; IACOB, M. C.; CăRUȚĂȘU, N. L. Investigations on factors affecting 3d-printed holes dimensional accuracy and repeatability. **Applied Sciences**, v. 13, n. 1, 2023. ISSN 2076-3417. Disponível em: www.mdpi.com. Acesso em: 15 mai. 2024.
- SANDOVAL, E. M.; ROSAS, M. E. M.; SANDOVAL, J. R. M.; VELASCO, M. M. M.; ÁVILA, H. C. D. Machine vision systems – a tool for automatic color analysis in agriculture. In: HUSSMANN, S. (Ed.). **Automation in Agriculture**. Rijeka: IntechOpen, 2017.
- SZELISKI, R. **Computer Vision: Algorithms and Applications**. [S.l.]: Springer Science and Business Media, 2010. ISBN 9781848829343.
- _____. **Computer vision: algorithms and applications**. [S.l.]: Springer Nature, 2022.

APÊNDICE A – EXEMPLO 1**IMAGEM DE REFERÊNCIA****IMAGEM DE TESTE**

INFORMAÇÕES DOS FUROS - REFERÊNCIA

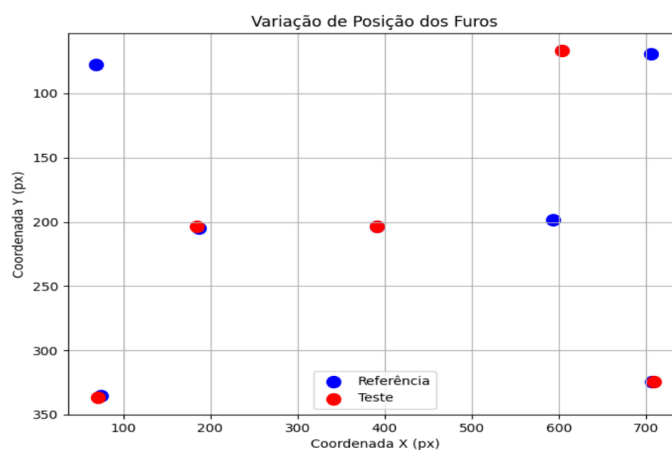
ID	Coordenadas (px)	Raio (px)
A:	(390.60, 203.40)	94.28
B:	(186.60, 204.60)	74.00
C:	(593.40, 198.60)	74.84
D:	(706.20, 324.60)	27.56
E:	(705.00, 69.00)	28.52
F:	(69.00, 77.40)	28.88
G:	(75.00, 335.40)	26.36

INFORMAÇÕES DOS FUROS - TESTE

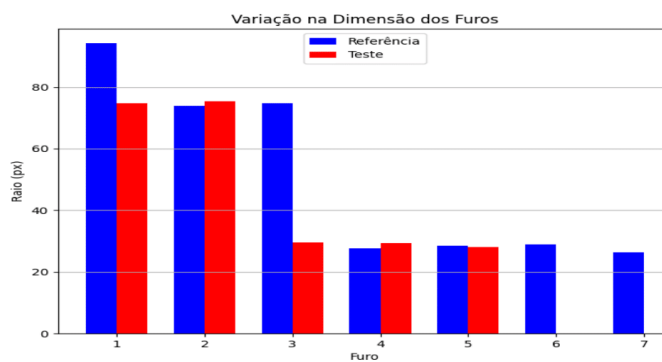
ID	Coordenadas (px)	Raio (px)
1:	(184.20, 203.40)	74.72
2:	(390.60, 203.40)	75.44
3:	(603.00, 66.60)	29.60
4:	(71.40, 336.60)	29.36
5:	(708.60, 324.60)	28.04

GRÁFICOS DE VARIAÇÃO

Variação na Posição dos Furos



Variação na Dimensão dos Furos



Fonte: Elaborado pelo autor, 2024.

RESUMO DOS RESULTADOS

Critério	Total Aprovados	Total Reprovados	Percentual Aprovados (%)	Resultado Final
Quantidade de Furos	5	2	71.43%	Reprovado
Posição dos Furos	4	3	57.14%	Reprovado
Dimensão dos Furos	3	4	42.86%	Reprovado

Fonte: Elaborado pelo autor, 2024.