



INSTITUTO FEDERAL
Piauí



**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE MATERIAIS
DISSERTAÇÃO DE MESTRADO**

JOSIMAR HENDRIO FERRAZ BORGES

**CLASSIFICAÇÃO DE DEFEITOS NA PINTURA DE PEÇAS METÁLICAS NO
PROCESSO INDUSTRIAL UTILIZANDO ALGORITMOS DE INTELIGÊNCIA
ARTIFICIAL**

TERESINA

2025

JOSIMAR HENDRIO FERRAZ BORGES

**CLASSIFICAÇÃO DE DEFEITOS NA PINTURA DE PEÇAS METÁLICAS NO
PROCESSO INDUSTRIAL UTILIZANDO ALGORITMOS DE INTELIGÊNCIA
ARTIFICIAL**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia de Materiais do Instituto Federal do Piauí, como parte integrante dos requisitos para a obtenção do título de Mestre em Engenharia de Materiais.

Área de concentração: Inteligência Artificial.

Orientador: Prof. Dr. Otílio Paulo da Silva Neto

**TERESINA
2025**

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

Borges, Josimar Hendrio Ferraz

B732c Classificação de defeitos na pintura de peças metálicas no processo industrial utilizando algoritmos de inteligência artificial / Josimar Hendrio Ferraz Borges. - 2025.
86 f.: il. color.

Dissertação (Mestrado em Engenharia de Materiais) - Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Teresina Central, 2025.

Orientador : Prof Dr. Otílio Paulo da Silva Neto.

1. Algoritmos. 2. Inteligência artificial. 3. Classificação. 4. Identificação de defeitos. I. Título.

CDD - 620.1

Elaborado por Maria Rosismar Farias CRB 3/631

JOSIMAR HENDRIO FERRAZ BORGES

**CLASSIFICAÇÃO DE DEFEITOS NA PINTURA DE PEÇAS METÁLICAS NO
PROCESSO INDUSTRIAL UTILIZANDO ALGORITMOS DE INTELIGÊNCIA
ARTIFICIAL**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia de Materiais do Instituto Federal do Piauí, como parte integrante dos requisitos para a obtenção do título de Mestre em Engenharia de Materiais.

Aprovada em: 21/08/2025.

BANCA EXAMINADORA

Prof. Dr. Otílio Paulo da Silva Neto (Orientador)
Instituto Federal do Piauí (IFPI)

Prof. Dr. Vicente Galber Freitas Viana
Instituto Federal do Piauí (IFPI)

Prof. Dr. Gilvan Moreira da Paz
Instituto Federal do Piauí (IFPI)

Prof. Dr. Francisco Adelson Alves Ribeiro
Instituto Federal do Maranhão (IFMA)

A Deus,
À minha família.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por estar sempre presente em minha vida e me abençoando.

A minha esposa Isadora Maria de Moura Rocha por toda sua dedicação e companheirismo em todos os momentos.

A minha filha Júlia de Moura Rocha Ferraz Borges, que trouxe um novo sentido para minha vida.

Aos meus pais João da Mata Borges e Ana Elisa Mendes Ferraz Borges e irmãos Josiane Ferraz Borges, Joane Ferraz Borges e João Manoel Ferraz Borges por sempre terem me apoiado e acreditado em mim.

Ao professor Dr. Otilio Paulo da Silva Neto pelas orientações, ensinamentos e tempo, a mim concedidos durante a realização do trabalho.

Aos meus amigos de curso, em especial a Osmar Leite Ferreira Neto e Rejane Alves de Melo pelas experiências vividas e ensinamentos compartilhados, que foram essenciais para o desenvolvimento da minha pesquisa.

Aos professores participantes da Banca Examinadora Prof. Dr. Vicente Galber Farias Viana e Prof. Dr. Francisco Adelson Alves Ribeiro por sua dedicação do tempo, sugestões e colaborações.

Ao Instituto Federal de Educação, Ciência e Tecnologia do Piauí – IFPI e ao Programa de Pós Graduação em Engenharia de Materiais – PPGEM, pelo apoio a pesquisa e pela estrutura fornecida, que possibilitou o desenvolvimento e conclusão da minha pesquisa.

“Com paciência e perseverança muito se alcança.”

Theophile Gautier

RESUMO

Os revestimentos de superfície por pintura vêm sendo utilizados há milhares de anos com um aumento gradual de seu consumo. A pintura tem por objetivo depositar um filme de tinta sobre uma superfície metálica ou não metálica, possuindo as mais diversas finalidades como proteção anticorrosiva, estética, segurança, entre outros. Os processos de pintura industrial envolvem diversas etapas que podem incluir a preparação da superfície, a aplicação da tinta e a secagem. Nos últimos anos houve um aumento exponencial no uso de algoritmos de inteligência artificial nos processos industriais. Este trabalho sugere, analisa e classifica a aplicação destes algoritmos na classificação de defeitos na pintura de peças metálicas em indústrias utilizando algoritmos de inteligência artificial. No trabalho em questão, foi desenvolvido um modelo de inteligência artificial baseado em redes neurais convolucionais (CNN) para identificar de forma automática peças que estejam dentro e fora dos padrões estipulados pela indústria onde foi aplicada a pesquisa. O modelo foi treinado com um banco de dados de imagens fornecido pela própria indústria, onde temos um acervo de peças defeituosas. Para as peças dentro dos padrões foi criado um banco de imagens capturadas pelo próprio autor. Essas imagens passaram por um pré-processamento, para que fosse destacado os principais defeitos nas peças e também fosse reduzida a carga computacional, pois foi aplicado um filtro de escala cinza. Após o treinamento com 50 épocas e utilizando métricas como acurácia, precisão, recall e F1-score, o modelo apresentou acurácia de 88,86%, precisão de 88,18%, recall de 88,86% e um F1-escore de 91,39%, com excelente desempenho na identificação das peças defeituosas. Após a validação de um modelo preditivo, um aplicativo móvel denominado AÇO_CHECK foi concebido para coletar dados em campo, permitindo a validação empírica do modelo. Este aplicativo emprega um modelo de aprendizado de máquina, desenvolvido com a biblioteca Keras (integrada ao TensorFlow), que executa análises de imagens submetidas pelos usuários, realizando inferências a partir dos dados visuais.

Palavras-chave: algoritmos; inteligência artificial; classificação; identificação de defeitos; pintura industrial.

ABSTRACT

Surface coatings have been used for thousands of years, with their consumption gradually increasing. Painting aims to deposit a film of paint on a metallic or non-metallic surface, serving a wide range of purposes, including corrosion protection, aesthetics, safety, and more. Industrial painting processes involve several steps, including surface preparation, paint application, and drying. In recent years, there has been an exponential increase in the use of artificial intelligence algorithms in industrial processes. This work suggests, analyzes, and classifies the application of these algorithms to classify defects in the painting of metal parts in industries using artificial intelligence algorithms. In this work, an artificial intelligence model based on convolutional neural networks (CNN) was developed to automatically identify parts that meet and do not meet the standards stipulated by the industry where the research was conducted. The model was trained using an image database provided by the industry itself, which contains a collection of defective parts. For parts that meet the standards, a database of images captured by the author himself was created. These images underwent preprocessing to highlight the main defects in the parts and reduce the computational load by applying a grayscale filter. After training for 50 epochs and using metrics such as accuracy, precision, recall, and F1-score, the model achieved 88.86% accuracy, 88.18% precision, 88.86% recall, and an F1-score of 91.39%, demonstrating excellent performance in identifying defective parts. After validating a predictive model, a mobile application called AÇO_CHECK was designed to collect field data, enabling empirical validation of the model. This application uses a machine learning model developed with the Keras library (integrated with TensorFlow), which analyzes user-submitted images and draws inferences from the visual data.

Keywords: algorithms; artificial intelligence; classification; defect identification; industrial painting.

LISTA DE ILUSTRAÇÕES

Figura 1- Funcionamento da pintura eletrostática.....	17
Figura 2- Processo produtivo da indústria local.....	22
Figura 3 – Esteira de pintura da peças metálicas.....	22
Figura 4- Densidade de defeitos na pintura industrial.	23
Figura 5 - Exemplo de defeito em pintura por baixa fluidização.....	24
Figura 6- Exemplo de defeito em pintura por falta de aderência.....	25
Figura 7- Exemplo de defeito em pintura por conta de golfada de pó.....	25
Figura 8- Exemplo de defeito em pintura por conta de gancheira suja.....	25
Figura 9- Exemplo de defeito em pintura por conta de pontos salientes...	26
Figura 10- Exemplo de defeito em pintura por falha no leque.....	26
Figura 11- Linhas de pensamento da Inteligência Artificial.....	30
Figura 12 - Robôs humanóides trabalhando numa indústria.....	32
Figura 13- Representação esquemática da arquitetura de uma CNN.....	36
Figura 14- Exemplo de extração de característica – Detecção de borda vertical.....	37
Figura 15 – Exemplo de aplicação do <i>padding</i> com tamanho 1.....	38
Figura 16 – Representação gráfica da função de ativação ReLU.....	39
Figura 17 - Exemplo de Max-Pooling com filtro 2×2 e stride igual a 2.....	40
Figura 18- Processamento de uma camada totalmente conectada.....	41
Figura 19- Etapas de um Sistema de Visão Artificial.....	42
Figura 20- Ilustração da Transformada de Hough para círculos.....	50
Figura 21 – Imagem em escala de cinza e a convenção utilizada para o sistema de coordenadas (x,y).....	52
Figura 22 – Representação matricial de uma imagem.....	52
Figura 23 – Esquema em cubo de cores RGB.....	53
Figura 24 – Representação de cor nos modelos RGB e HSV.....	54
Figura 25 – Comparativo da decomposição de uma imagem nos modelos HSV e RGB.....	53
Figura 26 – Esteira de pintura das peças metálicas.....	50
Figura 27 – Etapas de um sistema de Visão Computacional típico.....	60

Figura 28 – Imagem de peça não conforme.	61
Figura 29 – Imagem de peça não conforme.....	61
Figura 30 – Imagem de peça conforme.....	62
Figura 31 – Imagem de peça antes e após a preparação.....	62
Figura 32 – Imagem do aplicativo desenvolvido.....	70
Figura 33 – Tela inicial do aplicativo.....	71
Figura 34 – Tela inicial do aplicativo.....	72
Figura 35 - Precisão por época de treinamento e validação do modelo....	73
Figura 36 – Matriz de Confusão plotada pelo código.....	74
Figura 37 – Exemplo de análise real do aplicativo.....	75
Figura 38 – Exemplo de análise real do aplicativo.....	76
Figura 39 – Exemplo de análise real do aplicativo.....	76

LISTA DE TABELAS

Tabela 1 - Distribuição de imagens em conjuntos de treinamento, validação e teste antes do aumento dos dados	66
Tabela 2 - Resumo da Exatidão, Precisão, Recordação e Pontuação F1 por Classe	74

LISTA DE QUADROS

Quadro 1- Resultados de classificações possíveis.	56
Quadro 2 - Matriz de confusão.	58
Quadro 3 - Resumo estrutural e paramétrico da rede neural convolucional	69

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVO GERAL	17
1.2	OBJETIVOS ESPECÍFICOS	17
1.3	ESTRUTURA DA DISSERTAÇÃO.....	17
2	REVISÃO DA LITERATURA	19
2.1	PINTURA INDUSTRIAL DE PEÇAS METÁLICAS.....	19
2.2	DEFEITOS NA PINTURA	23
2.2.1	Defeitos na pintura industrial.....	23
2.3	CONTROLE DE QUALIDADE.....	26
3	INTELIGÊNCIA ARTIFICIAL.....	28
3.1	BREVE HISTÓRICO DA INTELIGÊNCIA ARTIFICIAL.....	28
3.2	USO DA IA NA INDÚSTRIA.....	30
3.2.1	A IA nos métodos avaliativos de qualidade na indústria: Acurácia, F1 score e recall.....	32
3.3	VISÃO COMPUTACIONAL.....	33
3.3.1	Estrutura da Visão Computacional.....	34
3.3.2	Aplicações de Visão Computacional em Diferentes Setores.....	35
3.4	REDES NEURAIS CONVOLUCIONAIS.....	35
3.4.1	Arquitetura de uma CNN.....	36
3.4.2	Emprego em Reconhecimento de Padrões.....	41
3.4.3	Uso no Setor Industrial.....	42
3.4.4	Aplicações em Reconhecimento de Imagens.....	43
3.4.5	Inspeções automatizadas.....	44
3.4.6	Processamento Digital de Imagens.....	45

3.4.6.1	Sistema de Visão Artificial.....	46
3.4.6.2	Aquisição.....	46
3.4.6.3	Pré-processamento.....	47
3.4.6.4	Segmentação.....	48
3.4.6.5	Extração de Características.....	49
3.4.6.6	Reconhecimento e Interpretação.....	50
3.5	MODELOS DE CORES.....	50
3.5.1	Escala de Cinza- Imagem Monocromática.....	50
3.5.2	Modelos RGB e HSV.....	53
3.6	TREINAMENTO DO MODELO.....	55
3.7	MÉTRICAS DE AVALIAÇÃO.....	55
4	MATERIAL E MÉTODOS	58
4.1	MATERIAL.....	58
4.2	MÉTODOS.....	58
4.2.1	Aquisição das imagens.....	58
4.2.2	Segmentação.....	59
4.2.3	Extração das características.....	63
4.2.3.1	Redes Neurais.....	63
4.2.4	Modelo da rede neural.....	65
4.2.5	Composição de conjuntos de treinamento, validação e teste....	65
4.3	Aplicação do modelo em um aplicativo de celular.....	68
5	RESULTADOS E DISCUÇÕES	72
6	CONCLUSÃO	76
6.1	CONTRIBUIÇÕES DA PESQUISA	76
6.2	LIMITAÇÕES E TRABALHOS FUTUROS	77
	REFERÊNCIAS.....	78

1 INTRODUÇÃO

A necessidade de produzir ferramentas que facilitassem o trabalho do homem contribuiu para que ele se utilizasse de diversos materiais até fabricar o que melhor lhe atendesse. Assim, consoante a descoberta do metal, inicialmente, eles não eram fundidos, pois os povos primitivos ainda não tinham descoberto esse processo através das altas temperaturas, o que só ocorreu no ano 4000 a.C, os objetos eram adquiridos com aquecimento e golpeadas. Após a sua descoberta, houve uma grande mudança na fabricação e funcionalidade de diversos utensílios (Tâmega, 2017).

Com o passar do tempo, descobriu-se a produção do ferro através da extração do minério de ferro pelas altas temperatura (Idem). Ademais, ainda nos primórdios, o seu manuseio/descoberta era algo empírico e transmitido de pai para filho ou de mestre para aprendiz, ou seja, a transmissão desse conhecimento se restringia a pequenos círculos sociais. A maneira de obter os metais e de lhes dar formas era adquirida a olho nu e através da prática contínua (Kitice, Garlipp, Pereira, 1960).

Os autores supracitados presumem que a descoberta do metal se deu do uso de pedras para a construção de fornos, visto que elas eram um tipo de minério, ou seja, por acaso e que somente no século XVIII houve a descoberta do primeiro aço como se é conhecido (*idem*).

Por conseguinte, houve a descoberta do ferro-gusa através da junção do minério de ferro com o carvão mineral e calcário (Tâmega, 2017). Esse mesmo autor ainda declara que os produtos siderúrgicos não são apenas versáteis e viáveis economicamente do ponto de vista prático e funcional. Eles também são o material mais reciclado do mundo. [...] Ou seja, é um processo que promove a sustentabilidade. [...] A siderurgia também possui produção de energia com geração própria. Os gases gerados no processo de produção são utilizados na geração de energia (Tâmega, 2017, p. 14).

Diante da afirmação exposta, observa-se a consolidação da posição dos produtos siderúrgicos como pilares de uma indústria moderna que conjuga viabilidade econômica com responsabilidade ambiental. Essa premissa é fundamental para desconstruir a visão tradicional de indústria pesada como inevitavelmente poluente.

Ademais, o trecho salienta um avanço paradigmático no setor: a otimização energética por meio da recuperação de subprodutos. A prática de aproveitar os gases do processo para geração de energia própria configura um caso de simbiose

industrial, onde um resíduo é transformado em insumo, o reduz a dependência energética externa e a pegada de carbono da produção, minimizando a emissão de poluentes que, de outra forma, seriam liberados na atmosfera ou demandariam tratamento. Adiante, tem-se o aperfeiçoamento do manuseio do ferro e do aço e seu uso, que culminou no desenvolvimento de técnicas metalúrgicas mais sofisticadas durante a Revolução Industrial.


Também é importante salientar que a introdução de altos-fornos mais eficientes permitiram a produção em massa de aço de qualidade superior a um custo drasticamente reduzido. Esse avanço não apenas democratizou o acesso a um material estrutural fundamental, mas também catalisou inovações em setores-chave como os transportes (ferrovias e navios a vapor), a construção civil (edifícios e pontes de grande porte) e a indústria de máquinas.

Todavia, é enfatizar que as peças metálicas estão suscetíveis a algumas danificações, por isso, é salutar o investimento em técnicas que prolonguem a vida útil delas, minorando, ao máximo, as suas ocorrências e, por conseguinte, o seu colapso parcial ou total. Para onde a metodologia será aplicada. Desta forma, no decorrer desta investigação, será falado um pouco sobre o processo de pintura que é utilizado e também onde os possíveis defeitos que podem ser encontrados.

A pintura eletrostática é o método utilizado para pintura das peças que serão analisadas. Ela é uma técnica usada para aplicação de tinta em superfícies e equipamentos que conduzem eletricidade. Santos *et al.* (2023) asseguram que esse tipo de pintura é uma solução promissora e que ganhou destaque devido à capacidade de fornecer proteção duradoura às peças expostas a ambientes hostis. Esses autores também explicam que isso se dá pela aplicação da tinta em pó por meio de um processo eletrostático onde suas “partículas carregadas eletricamente aderem às peças de aço de forma uniforme” (Santos *et al.*, 2023, p. 24617). Por isso, objetos metálicos e ferrosos são os mais indicados para receber esse tipo de intervenção.

É importante salientar que no método de pintura eletrostática há o envolvimento de cargas elétricas conforme mostra a Figura 1 (funcionamento da pintura eletrostática). A tinta é eletrizada na pistola (negativamente – elétrons), enquanto que a peça está aterrada, conseqüentemente ocorre uma atração que faz a tinta deslocar-se para a peça, forçando a uma maior quantidade de tinta aderir a mesma. Em geral, o procedimento pode ser realizado por pulverização convencional a ar comprimido, por alimentação através de bombas hidráulicas (*airless*) entre outras técnicas.

Figura 1- Funcionamento da pintura eletrostática.



Fonte: GNECCO; MARIANO; FERNANDES (2003, p. 13)

1.1 OBJETIVO GERAL

Criar uma ferramenta computacional que seja capaz de realizar a identificação de defeitos na pintura de peças metálicas, dentro do processo industrial, por meio de visão computacional, auxiliando na melhoria da inspeção de qualidade do processo.

1.2 OBJETIVOS ESPECÍFICOS

- Construir um protótipo para aquisição de imagens de peças metálicas;
- Criar um dataset de imagens de peças metálicas com e sem defeitos na pintura;
- Projetar e implementar uma rede neural capaz de identificar os defeitos na pintura de peças metálicas;
- Avaliar o desempenho do modelo através das métricas de validação mais adequadas ao processo;
- Desenvolver um aplicativo que possa realizar a identificação dos defeitos na pintura das peças em tempo real.

1.3 ESTRUTURA DA DISSERTAÇÃO

A dissertação está estruturada em seis capítulos, com o resumo de cada um deles apresentado a seguir:

Capítulo I - Apresenta a introdução do trabalho, com a justificativa da sua realização, a importância, os objetivos e sua estrutura.

Capítulo II - são apresentados os fundamentos teóricos sobre o processo de pintura industrial, IA, Visão Computacional, CNNs e suas aplicações na indústria.

Capítulo III – detalha a metodologia empregada, abrangendo desde a aquisição de imagens, elaboração do *dataset*, preparação de dados, arquitetura da *CNN*, treinamento e avaliação do modelo.

Capítulo IV – são discutidos os resultados obtidos, com ênfase em uma análise crítica e comparação com estudos anteriores.

Capítulo V – apresenta as considerações finais, limitações e sugestões para trabalhos futuros.

2 REVISÃO DA LITERATURA

Durante muito tempo, as tintas exerciam um papel apenas estético, todavia, ao migrarem para os países do norte da América e da Europa, por conta da sua condição climática, elas passaram a exercer também uma função protetiva do objeto (DT-16..., [20–]). Ou seja, a pintura vai muito além de uma função estética; ela desempenha um papel essencial como barreira protetiva, especialmente na construção civil, na indústria e até mesmo em objetos do dia a dia, atuando como uma camada isolante que protege contra os efeitos do tempo, da umidade, da exposição solar, de produtos químicos e de outros agentes agressivos.

Nesse ínterim, vale ressaltar que conforme consta no DT-16: Análise de falhas e defeitos, publicado pela Weg Tintas ([20–]), “as tintas são usadas para proteger e dar cor a objetos ou superfícies [...] e aplica-se a praticamente qualquer tipo de objetos”. Dessa forma, no que tange a estruturas metálicas, a pintura é fundamental para evitar a corrosão, que compromete a integridade do material com o tempo. Por essa razão, a ABRACO (2020) salienta a importância de se reconhecer as falhas na pintura, bem como a compreensão da causa e a sua correção a tempo com vistas a também reduzir os custos de sua manutenção.

Em ambientes industriais, ela é aplicada de forma técnica, com tintas específicas, para resistir a altas temperaturas, produtos corrosivos ou abrasão constante. Além disso, em equipamentos e maquinários, a pintura facilita a limpeza, previne o acúmulo de sujeira e colabora com normas de segurança e higiene. Segundo a ABRACO (2020, p. 04), “[...] para a prevenção da corrosão, [...] a aplicação de revestimento para recobrimento das estruturas, isolando a estrutura do meio corrosivo, é a técnica de maior aplicação prática”.

Diante disso, é importante enfatizar que a pintura não deve ser vista apenas como um acabamento visual, mas como uma etapa estratégica de proteção, que contribui diretamente para a preservação, segurança e durabilidade das superfícies e estruturas em que é aplicada.

2.1 PINTURA INDUSTRIAL DE PEÇAS METÁLICAS

Na indústria, o aço é um dos principais materiais utilizado, todavia, se não houver os cuidados devidos, ele fica suscetível à corrosão. Isto posto,

salienta-se que a pintura industrial metálica serve para proteger materiais e equipamentos contra agentes corrosivos, com a finalidade de cumprir com normas técnicas de qualidade e segurança no setor industrial oferecendo um bom acabamento, e consequentemente a proteção a equipamentos e máquinas, aumentando a resistência, durabilidade e bom acabamento desses equipamentos e materiais, pois, como assevera Santos *et al.* (2023) é natural o processo de corrosão. Por essa razão, é fundamental o investimento em métodos que contribuam para o aumento da sua vida útil.

Acerca dessa importância, Kendig e Mills (2017) ressalta que a barreira anticorrosiva começou a ser utilizada como elemento protetivo pelas civilizações antigas, em que passavam ceras, óleos e resinas naturais para proteger materiais como o ferro, bronze da oxidação. Esses mesmos autores ainda revelam que com a Revolução Industrial, a necessidade de proteger estruturas metálicas (pontes, navios, trilhos) impulsionou o desenvolvimento de tintas especializadas, assim, houve a descoberta do chumbo vermelho, usado desde o século XVIII por sua aderência e propriedades inibidoras, e também do óleo de linhaça, base de muitas tintas protetoras da época.

Kendig e Mills (2017) ainda mencionam que os avanços científicos começaram a surgir a partir do século XIX, com estudos sistemáticos sobre corrosão levaram ao uso de metais sacrificiais (ex.: zinco) em revestimentos, bem como ao desenvolvimento de tintas com zarcão (óxido de chumbo), que se tornaram padrão na proteção de navios e estruturas de ferro. Ainda segundo esses autores, a partir do século XX começaram a surgir tintas sintéticas (ex.: epóxi, poliuretanos), tintas com zinco em pó para proteção catódica e regulamentações contra pigmentos tóxicos (como chumbo).

No que tange ao fator protetivo da peça, o documento DT-16: Análise de falhas e defeitos, publicado pela Weg Tintas ([20–], Prefácio) enfatiza que:

[...]aproximadamente 30% do aço produzido no mundo é utilizado para reposição de peças e partes de equipamentos e instalações deterioradas pela corrosão, estima-se um valor de 3,5% do Produto Interno Bruto o gasto com problemas de corrosão em países industrializados. Desse modo, as tintas têm a missão de retardar esse processo, por meio de proteção catódica, por barreira e proteção anódica.

Consoante ao conceito de corrosão, Silva (2016, p. 02) menciona que é

o “desgaste, ataque, deterioração de materiais, como peças ou equipamentos (tanques, dutos, estruturas metálicas etc.) pela ação química ou eletroquímica do meio”. Diante do exposto, a NBR 15575/2013 trouxe uma série de mudanças com requisitos mínimos com vistas a assegurar qualidade, durabilidade, segurança e melhor desempenho das construções.

Por isso, salienta-se que a pintura metálica funciona como barreira contra a ação de agentes corrosivos, como: atmosfera, solos, água do mar, produtos químicos e águas de rios, lagos e solos. É essencial ter a ciência de fatores relacionados ao ambiente, como: umidade, salinidade e acidez. A esse respeito, Leal Júnior (2023) afirma que a corrosão faz parte do ciclo de vida útil do metal. Entretanto, investir em produtos anticorrosivos é também uma atitude econômica que contribui para a durabilidade dos materiais.

Por se tratar de uma técnica essencial que traz mais segurança para a engenharia e usando constantemente o aço que é um dos materiais mais importantes na engenharia, a pintura industrial está presente em chapas, tubos, cabos, barras, perfis, telhas metálicas, entre outros materiais usados com frequência em obras.

Dentre os benefícios já mencionados neste trabalho, também podem ser citados:

- proteção anticorrosão em estruturas metálicas;
- aplicação de tintas e cores claras refletivas, reduzindo a perda por evaporação de líquidos voláteis;
- melhoria na estética do ambiente industrial;
- possibilidade de sinalização através da variação de cores na pintura;
- reduz a aderência de partículas na estrutura metálica;
- impermeabilização;
- fácil manutenção.

A fim de assegurar maior qualidade da pintura, a NBR 7348/2017, salienta a importância de se preparar a superfície para o recebimento da tinta e revestimentos protetivos, removendo os contaminantes, revestimentos antigos e também a corrosão.

Na pesquisa desenvolvida, foi utilizado uma indústria local como base para a aplicação da solução proposta. A indústria é especialista na fabricação de móveis em aço e sistemas de armazenagem para distribuidoras, supermercados, farmácias, conveniências e outros segmentos. Também produz bebedouros industriais, móveis escolares, móveis para escritórios e equipamentos para padarias, restaurantes e lanchonetes.

Figura 2- Processo produtivo da indústria local.



Fonte: Próprio autor (2025).

Figura 3 – Esteira de pintura da peças metálicas.



Fonte: Próprio autor.

Toda essa produção envolve diferentes tipos de pintura de peças

metálicas, onde essas peças passam por um processo de controle de qualidade feito de forma visual.


2.2 DEFEITOS NA PINTURA

Durante a pintura, vários defeitos podem surgir, como por exemplo: escorrimento da tinta, espessura irregular, mancha, pulverização seca, porosidade, sangramento, cratera, impregnação de materiais impróprios, tais como: terra, pelos, poeira, por exemplo; aparecimento de bolhas, bem como de possível aparecimento de rugas.

2.2.1 Defeitos na pintura industrial

Na definição de pintura industrial, pode haver defeitos na película de tinta. De acordo com a ABNT NBR 15156:2004 os defeitos nas pinturas podem ser classificados pela densidade de defeito (frequência e/ou distribuição do defeito sobre a superfície), ou pela intensidade do defeito (tamanho específico do defeito) (Weg Tintas, ([20–])). A intensidade dos defeitos pode ser subdivida em: pouca incidência, média incidência, generalizada ou diversificada. A figura 4 (Densidade de defeitos na pintura industrial) demonstra as classificações de densidade.

Figura 4- Densidade de defeitos na pintura industrial.



Fonte: Weg Tintas ([20–])

Outrossim, é importante salientar que as áreas onde há estagnação de

água com parafusos e porcas, de arestas e cantos vivos, com frestas ou as que são submetidas à ação de substâncias química, as que são mais sujeitas às condições atmosféricas e as com soldas são as frequentemente afetadas por defeitos (Weg Tintas, [20–]).

Também existem outros agentes causadores de falhas nas tintas, tais como: “aplicação errada da tinta, tinta com defeito, escolha errada da tinta ou exposição a ambientes danosos” (Weg Tintas, [20–], p. 06).

As figuras 5 a 10 (Exemplo de defeito em pintura por baixa fluidização, Exemplo de defeito em pintura por falta de aderência, Exemplo de defeito em pintura por conta de golfada de pó, Exemplo de defeito em pintura por conta de gancheira suja, Exemplo de defeito em pintura por conta de pontos salientes e Exemplo de defeito em pintura por falha no leque, respectivamente) ilustram exemplos comuns de defeitos na pintura industrial.

Figura 5 - Exemplo de defeito em pintura por baixa fluidização.



Fonte: Weg Tintas ([20–])

Figura 6- Exemplo de defeito em pintura por falta de aderência



Fonte: Weg Tintas ([20–])

Figura 7- Exemplo de defeito em pintura por conta de golfada de pó.



Fonte: Weg Tintas ([20–])

Figura 8- Exemplo de defeito em pintura por conta de gancheira suja




Fonte: Weg Tintas ([20–])

Figura 9- Exemplo de defeito em pintura por conta de pontos salientes.



Fonte: Weg Tintas ([20–])

Figura 10- Exemplo de defeito em pintura por falha no leque.



Fonte: Weg Tintas ([20–])

2.3 CONTROLE DE QUALIDADE

O controle da qualidade se faz necessário nos mais diversos segmentos de produção, pois garante que produtos e serviços atendam aos padrões estabelecidos, com foco na segurança e satisfação do cliente e, também, na competitividade do mercado. Ele permite identificar falhas nos processos produtivos, reduzir desperdícios e custos, além de assegurar a conformidade com normas técnicas e regulatórias. Segundo Drummond (1998 *apud* Barreto; Lopes, 2005, local 10) a aplicação do Controle de Qualidade Total faz “com que os clientes percebam que aquela corporação possui comprometimento e envolvimento de todos para que o cliente evidencie as melhorias dos produtos e serviços e delas desfrute”.

Por conseguinte, esses mesmos autores asseveram que para manter um processo sob controle faz-se necessário o procedimento de localização do problema, em que se analisa o processo, padroniza-o e se estabelece itens de controle para se evitar o problema identificado anteriormente (Barreto; Lopes, 2005). Adicionalmente, a ABNT ISO 9001/2015 orienta que a “organização deve determinar o conhecimento necessário para a operação de seus processos e para alcançar a conformidade de produtos e serviços” (ABNT, 2015, p. 08).

Ao manter um sistema de controle de qualidade eficaz, as empresas aumentam sua credibilidade, melhoram a eficiência operacional e fomentam a melhoria contínua,

fatores essenciais para o sucesso e a sustentabilidade no longo prazo. A esse respeito, Machado *et al.* (2023) perceberam que o controle estatístico de processo contribui para a redução de desperdícios e retrabalhos e que contribui significativamente com a uniformidade do produto. Para tanto, esses autores recomendam que haja um treinamento contínuo dos colaboradores.

Destarte, a preocupação com a qualidade nos processos não é uma questão atual, e isso pode ser percebido nas construções egípcias que perpassam séculos e séculos, todavia, foi a partir do século XX que ela passou a ser entendida como uma área do conhecimento e de prática formal, sendo disseminado no pós Segunda Guerra Mundial, sendo o Japão um dos seus responsáveis por tal feito (Lima; Silva; Souza, 2023).

Ademais, os autores supracitados ainda discorrem sobre a importância de ser implantado na indústria um Sistema de Gerenciamento da qualidade, visto que contribui para: o aumento da produtividade, controle de processos, controle dos recursos, satisfação do cliente (*Idem*).

Dessa forma, depreende-se que na indústria, para se evitar desperdício de materiais e de tempo, faz-se indispensável a aplicação dos métodos de controle da qualidade, visando uma entrega segundo as necessidades dos clientes.

3 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) é uma área de pesquisa da ciência da computação que busca métodos ou dispositivos computacionais que simulam a capacidade humana de resolver problemas. De acordo com Ginsberg (1993, *apud* Valdati, 2020, p. 9) “o objetivo da IA era construir um sistema de símbolos físicos [...] que possa passar com segurança no teste de Turing”. Acerca desse teste, Valdati (2020) explica que ele leva o nome de seu criador e era um teste comportamental de inteligência, através da imitação. Ademais, Gomes (2024, p. 21) ainda acrescenta que “foi desenvolvido para [...] testar a performance, a capacidade de uma máquina digital em imitar e simular [...] uma fatia do comportamento humano, a saber, sua capacidade de dialogar e responder toda sorte de questões”.

Esse tipo de inteligência abrange uma ampla capacidade de aprendizado, de raciocínio, resolver problemas, perceber o ambiente, de entender a linguagem humana e até criar arte, baseada em algoritmos (Suave, 2024). Esse mesmo autor assevera que ela está presente nos *smartphones* por meio dos assistentes virtuais, nos algoritmos que direcionam o que se vê *online* e também nas plataformas de *streaming* (*idem*).

A IA causa impactos em diversos segmentos da sociedade que vão desde a solução para problemas, como a descoberta de doenças e seu diagnóstico a perdas de empregos e vulnerabilidade de dados pessoais por meio dos serviços *online* (Suave, 2024).

3.1 BREVE HISTÓRICO DA INTELIGÊNCIA ARTIFICIAL

A inteligência artificial surgiu na década de 50 com o objetivo de desenvolver sistemas para realizar tarefas que, no momento, são melhor realizadas por seres humanos que por máquinas, ou não possuem solução algorítmica viável pela computação convencional. Vale salientar que foi durante a Conferência de Investigação de Dartmouth que a IA passou a ser campo de estudo da Ciência da Computação, congregando ainda áreas como Filosofia, Psicologia, Lógica e Matemática (Valdati, 2020). Todavia, o termo inteligência artificial foi cunhado por John McCarthy em 1956 (*idem*) e, a partir de então, ela passou a ser estudada academicamente (Gomes, 2024).

Em 1952, Turing apresenta a nova versão do que fora nominado de Teste de Turing, onde há participantes máquinas e humanos que interagem entre si por meio de perguntas sem saberem quem é o quê, cuja única restrição é que o interrogador não poderia exigir demonstrações práticas, a fim de se evitar quem era a máquina e quem era o humano (Gomes, 2024).

Ademais, Mei e Cheng (2010, *apud* Valdati, 2020) acrescentam que no início, a IA tinha uma capacidade limitada, todavia, nos anos 60 até final dos anos 70, ela foi liderada pelo uso prático por pesquisas e desenvolvimento de sistemas especialistas e que a partir da década de 90 a pesquisa de IA passou para o ambiente baseado em web e distribuído, passando a penetrar em todas as áreas da vida social, isso por meio das descobertas das redes neurais.

Ao longo do tempo, ela passa por quatro linhas de pensamentos, conforme seguem abaixo:

I- Sistemas que pensam como seres humanos: “O novo e interessante esforço para fazer os computadores pensarem em máquinas com mentes, no sentido total e literal”. (Haugeland, 1985).


II-Sistemas que atuam como seres humanos: “A arte de criar máquinas que executam funções que exigem inteligência quando executadas por pessoas.” (Kurzweil, 1990,).

III-Sistemas que pensam racionalmente: “O estudo das faculdades mentais pelo seu uso de modelos computacionais.” (Charniak; Mcdermott, 1985).

IV-Sistemas que atuam racionalmente: “A Inteligência Computacional é o estudo do projeto de agentes inteligentes” (Poole *et al.*, 1998).

No geral, as linhas de pensamento I e III referem-se ao processo de pensamento e raciocínio, enquanto as II e IV, ao comportamento. Além disso, as linhas de pensamento I e II medem o sucesso em termos de fidelidade ao desempenho humano, enquanto na III e IV medem o sucesso comparando-o a um conceito ideal que de inteligência, que se chamará de racionalidade. Um sistema é racional se “faz tudo certo”, com os dados que tem (Russell; Norvig, 2004).

Figura 11- Linhas de pensamento da Inteligência Artificial.



Fonte: Ademir/ADS-2010

Desde a sua criação, as pesquisas em Inteligência Artificial tentam implementar computacionalmente sistemas que pensam e agem de forma racional e que pensam e agem de forma semelhante aos seres humanos. Essas quatro vertentes supracitadas mostram que há uma teoria ou paradigma unificado estabelecido que guie a pesquisa em IA.

Atualmente, ela se subdivide em oito subcampos, sendo eles: resolução de problemas, processamento de linguagem natural, robótica, sistemas baseados no conhecimento (KBES), visão computacional (processamento de imagens), aprendizagem de máquina, algoritmos genéticos, redes neurais (Valdati, 2020).

Tais descobertas abriram novos caminhos para a aplicação da inteligência artificial, permitindo progressos como o reconhecimento de fala, visão computacional e processamento de linguagem natural (PLN), dentre outros (Suave, 2024). Consoante à PLN, Gomes (2023, p. 19) afirma que são "sistemas capazes de analisar a linguagem humana, como Google Assistant, Alexa, Siri, entre outros, permitindo assim que pessoas e computadores digitais se comuniquem".

3.2 USO DA IA NA INDÚSTRIA

O uso da Inteligência Artificial (IA) na indústria tem transformado profundamente os processos produtivos, operacionais e estratégicos, marcando o que

muitos chamam de Indústria 4.0, "expressão utilizada pela primeira vez em 2011 pelo governo alemão para se referir aos processos produtivos ciberfísicos [...]" (Machado, 2020, cap. 1). Essa nova era industrial traz como integrantes: a internet das coisas (IoT), Internet de serviços, big data, computação em nuvem etc.


Cada vez mais se utiliza a inteligência artificial no ramo da indústria, visto que ela "está revolucionando [...], tornando operações mais eficientes e criando produtos e serviços" (Suave, 2024). Nesses espaços, as máquinas, a exemplo dos robôs, poderão desenvolver atividades perigosas, de soldagem, sobretudo, porque esse tipo de serviço libera ruídos e calores excessivos (Valdati, 2020). Diante disso, depreende-se que a IA automatiza não só tarefas repetitivas, mas também as complexas e perigosas. Para tanto, torna-se mais conveniente que uma máquina desenvolva tais atividades, sobretudo porque seu uso permite prever falhas em máquinas antes que elas ocorram, o que contribui significativamente com a redução do tempo de parada, com os custos com reparos, e desperdício de matéria-prima.

Assim, depreende-se que à medida que a indústria evolui em tecnologia, consoante às inovações digitais, novos modelos de negócios vão surgindo e, por conseguinte, tais transformações impactam tanto a mão de obra qualificada que atua em áreas de gerência, quanto à meramente operacional, ou seja, isso reverbera na contratação de empregos, concessão de créditos e sistemas judiciais, em que as decisões automatizadas influenciam a vida das pessoas de maneiras fundamentais (Suave, 2024).

Os avanços na área de tecnologia alteraram

[...]não somente o processo organizacional das empresas e o nível de produtividade, mas também as características da oferta e demanda e o mercado de trabalho. Estão surgindo um novo padrão de eficiência, novos materiais que mudam os processos e a composição de custos, uma maior capacidade de controle dos métodos de produção, distribuição e acompanhamento do pós-venda (Lima; Gomes, 2020, p. 14).

Figura 12 - Robôs humanóides trabalhando numa indústria



Fonte: Elaborado pelo autor por meio do ChatGPT (2025)

Outrossim, vale salientar que a IA na indústria não é apenas uma evolução tecnológica, mas uma mudança de paradigma. Ela transforma a maneira como as empresas operam, decidem e competem, criando oportunidades inéditas para produtividade e inovação.

3.2.1 A IA nos métodos avaliativos de qualidade na indústria: Acurácia, F1 score e recall

A adoção de Inteligência Artificial na indústria representa algo muito mais profundo do que só a implementação de novas ferramentas: é uma transformação na forma de pensar, operar e tomar decisões. Dessa forma, avaliar corretamente o desempenho dos modelos de IA é essencial para garantir que essas tecnologias tragam resultados confiáveis e seguros, por essa razão, métricas como acurácia, F1 score e recall tornam-se fundamentais nesse contexto.

Dentro da tecnologia, o termo acurácia tem se tornado bastante comum como sinônimo de precisão e eficiência, determinando um grau de exatidão, podendo ser melhor entendida como uma espécie de soma entre exatidão e precisão; seu uso se faz necessário, sobretudo, ao se utilizar de Inteligência Artificial e Machine Learning em soluções antifraude (Clear Sale, 2024).

Consoante ao recall, este enfatiza a capacidade de identificar corretamente os casos relevantes em aplicações industriais onde falhas podem ter impactos significativos. Em linhas de produção, um alto recall é fundamental para garantir que nenhum produto com defeito passe despercebido, evitando, assim, que a reputação da empresa seja afetada. Outro ponto a ser salientado, é que na indústria, o recall é uma ação de suma importância com vistas a manter a segurança e confiança dos consumidores, sobretudo, para que os usuários dos produtos não sejam colocados em risco. Seu processo bem definido demonstra que a empresa possui comprometimento com a qualidade e a transparência. (Korp, 2024).

Quanto ao F1 Score, “é uma métrica de desempenho para classificação e é calculada como a média harmônica de precisão e recall” (C3.ai, [202-]). Essa classificação é “comumente usada para medir o desempenho da classificação binária” (*idem*).

Ou seja, F1 score surge como um equilíbrio entre precisão e recall, sendo vital para garantir a qualidade dos resultados dos produtos. Salienta-se, outrossim, que na indústria, a escolha entre essas métricas depende do custo associado a erros, sendo comum ajustar modelos com base no contexto operacional.

3.3 VISÃO COMPUTACIONAL

A visão computacional é uma das aplicações da *machine learning* (aprendizagem por máquina) que busca dar aos computadores a capacidade de "ver" e interpretar o mundo visual, assim como os humanos fazem (Romeral; Zancul; Nascimento, 2023). A *machine learning* é uma força transformadora que impacta os setores da indústria e da ciência devido a sua capacidade de automatizar decisões e prever resultados com base em dados massivos. (Suave, 2024).

Ela combina algoritmos, matemática, estatística e, mais recentemente, técnicas de aprendizado de máquina (especialmente *deep learning*) para analisar, entender e tomar decisões com base em imagens ou vídeos. Rouhani (2019, *apud* Valdati, 2020, p. 43) acrescenta que “técnicas de deep learning permitem que as redes com várias camadas de processamento aprendam representação de dados com vários níveis de abstração”. Pode, ainda, analisar imagens com precisão acima da humana, bem como um grande conjunto de dados, ou seja, é um facilitador de inovações que transformam indústrias (*idem*).

A visão computacional é uma subárea da inteligência artificial dedicada a capacitar sistemas computacionais a interpretar e compreender imagens ou vídeos, a partir de dados capturados por câmeras, sensores ópticos ou dispositivos de digitalização. Esses sistemas buscam extrair informações relevantes de ambientes visuais, permitindo que máquinas identifiquem objetos, reconheçam padrões e tomem decisões com base em estímulos visuais (Sze *et al.*, 2017).

Essa tecnologia permite o processamento eficiente de grandes volumes de dados visuais, possibilitando a execução de tarefas complexas de maneira autônoma, muitas vezes emulando aspectos da percepção humana. Embora as pesquisas em visão computacional tenham começado entre as décadas de 1960 e 1970, expectativas iniciais de rápida replicação da visão humana foram desacreditadas ao longo do tempo. Com o avanço das investigações, ficou evidente que a interpretação visual humana é um processo altamente sofisticado, desafiador de ser modelado

computacionalmente, principalmente devido à complexidade neuro cognitiva envolvida (Shan *et al.*, 2025).

Atualmente, a visão computacional tem sido amplamente aplicada em setores diversos, como saúde, agricultura, segurança e indústria. Na indústria metalúrgica, por exemplo, essa tecnologia é utilizada na inspeção de soldas e na medição da conformidade geométrica de peças unidas, contribuindo para o controle de qualidade e a automação de processos produtivos (Hütten *et al.*, 2024).

3.3.1 Estrutura da Visão Computacional

O processo de visão computacional na classificação de defeitos na pintura de peças metálicas envolve etapas interconectadas voltadas à análise de imagens digitais. Inicialmente, a aquisição das imagens é crucial, pois a qualidade e a resolução impactam a detecção de imperfeições (Lecun, 2022). Técnicas de iluminação controlada e escolha do ângulo de visão são fundamentais para identificar variações sutis na superfície da pintura (Dhillon, 2020).

Após a captura, o próximo passo é o pré-processamento das imagens, essencial para aplicar filtros que eliminam ruídos e melhoram o contraste, fatores que podem dificultar a análise. A normalização dos dados alinha as imagens para comparação eficaz no aprendizado, enquanto a segmentação isola regiões de interesse, concentrando-se em áreas com possíveis defeitos, como arranhões ou bolhas (Gonzalez; Woods, 2018).

A fase de extração de características e a classificação são essenciais no processo. Métodos de aprendizado de máquina, especialmente algoritmos de inteligência artificial, identificam padrões e categorizam imperfeições (Gonzalez; Woods, 2018). Redes neurais convolucionais (CNNs) são usadas pela eficácia em dados de imagem, permitindo análise complexa e reconhecimento de características. A implementação e treinamento adequados desses modelos são fundamentais para o sucesso do sistema, garantindo aprendizado contínuo e adaptação às variações na pintura metálica, resultando em monitoramento e controle de qualidade mais eficaz (Saha; Tejashree; Kumari, 2021).

3.3.2 Aplicações de Visão Computacional em Diferentes Setores

O uso de Visão Computacional é essencial em várias áreas, principalmente no processamento de imagens e reconhecimento de padrões. Sua arquitetura imita a percepção visual humana, utilizando camadas convolucionais para extrair características relevantes. Essa habilidade é útil em saúde, indústria automotiva, segurança e na análise crescente de superfícies metálicas (Khan; Laghari; Awan, 2021).

As CNNs têm se mostrado eficazes na saúde ao diagnosticar doenças por meio de exames de imagem, identificando precocemente anomalias que podem ser invisíveis a olho nu (Litjens *et al.*, 2017). Isso resulta em tratamentos mais eficientes e redução de custos com diagnósticos errôneos. Na indústria automotiva, são aplicadas na detecção de falhas em peças e no reconhecimento de sinalizações, melhorando a segurança e a automação veicular. Além disso, sua implementação em visão computacional ajuda em processos de fabricação inteligentes e manutenção preditiva com análise constante de imagens (Janai *et al.*, 2020).


A segurança e vigilância são áreas onde as CNNs têm sido eficazes, oferecendo soluções para reconhecimento facial e análise de comportamento em locais seguros (Parkhi *et al.*, 2015). Para a avaliação de peças metálicas, as CNNs ajudam a identificar defeitos como corrosão e descascamento, reduzindo erros humanos e aumentando a eficiência no controle de qualidade (Akçay *et al.*, 2018). Com seu aprendizado profundo, as CNNs mostram-se ferramentas versáteis, melhorando operações em diversos setores e impactando significativamente na eficiência e qualidade dos produtos. O futuro indicará uma maior conexão entre inteligência artificial e indústrias, com as CNNs exploradas para enfrentar desafios e promover inovações (Zhang; Yang, 2020).

3.4 REDES NEURAI CONVOLUCIONAIS

Uma Rede Neural Convolucional (CNN) pode ser vista como uma variante da rede neural *Perceptron* de Múltiplas Camadas (MLP). Diferentemente da MLP, que utiliza apenas camadas ocultas totalmente conectadas, a arquitetura de uma CNN é composta por uma alternância de camadas de convolução, responsáveis por dar nome à arquitetura; e camadas de *pooling*. Cada uma dessas camadas com um

conjunto de filtros, também conhecido como *kernel*, cuja função é extrair características locais (*local features*) de uma entrada. Dessa forma, são gerados diversos mapas de convolução e *pooling*, os quais capturam diferentes propriedades, como bordas, contornos, formas e intensidades de cor. Os mapas de características compartilham um mesmo conjunto de pesos, o que contribui para a redução da complexidade computacional da rede (Vargas, 2016). Por fim, a etapa de classificação é realizada por uma camada totalmente conectada, na qual todos os neurônios da camada anterior são conectados aos neurônios da camada de saída, conforme exemplificado na Figura 13 (Representação esquemática da arquitetura de uma CNN).

Figura 13- Representação esquemática da arquitetura de uma CNN



Fonte: Vargas (2016)


3.4.1 Arquitetura de uma CNN

A arquitetura de uma CNN, segundo Rawat e Wang (2017), é formada basicamente por múltiplas camadas, que incluem camadas convolucionais, camadas de *pooling* e camadas totalmente conectadas, cada uma desempenhando um papel crucial na análise e classificação de dados visuais (Lecun *et al.*, 2015).

- **Camada de Convolução:** Uma camada de convolução é composta por neurônios que se conectam a sub-regiões específicas das imagens de entrada ou das saídas da camada anterior. Nessa etapa, é aplicado um conjunto de filtros convolucionais responsáveis por percorrer toda a imagem e gerar mapas de características. Cada filtro possui um conjunto próprio de pesos, de modo que diferentes filtros aprendem diferentes tipos de atributos da entrada. A Figura 14 (Exemplo de extração de característica – Detecção de borda vertical) é apresenta um exemplo de detecção de bordas verticais, com uma entrada 6x6, com valores em escala de cinza, sendo processada por um filtro de dimensão 3x3, aplicado com *stride* igual a 1. O *stride* é um parâmetro fundamental na construção dessa camada, pois

define o deslocamento do filtro sobre a entrada, podendo ser, por exemplo, de um em um (1×1) ou de dois em dois (2×2), entre outras variações (Lecun, 2022).


Figura 14- Exemplo de extração de característica – Detecção de borda vertical



Fonte: Lecun (2022)

Além do *stride*, outra técnica comumente utilizada na camada de convolução é o *padding*, que consiste em adicionar zeros nas bordas da imagem. Essa operação permite preservar a informação contida nas extremidades e viabiliza a extração de características próximas às bordas. A Figura 15 ilustra a aplicação do *padding* de tamanho 1, em que uma borda adicional com valor igual a zero é adicionada ao redor da matriz de entrada.

Figura 15 – Exemplo de aplicação do *padding* com tamanho 1.



Fonte: Lecun (2022)

• **Camada de Normalização em lote:** A camada de normalização em lote (*Batch Normalization*) tem como principal função normalizar os dados fornecidos a cada camada oculta da rede. Essa normalização é realizada sobre cada minilote de dados (Pascal *et al.*, 2010), contribuindo para uma maior eficiência na aplicação das transformações. Segundo os experimentos conduzidos pelos autores da técnica


(Sergey, 2015), além de aumentar a estabilidade do treinamento, a normalização em lote também atua como uma forma de regularização, reduzindo o risco de *overfitting*. Os resultados indicaram ainda uma aceleração expressiva no tempo de treinamento: observou-se uma redução de até 14 vezes no número de etapas necessárias, quando comparado ao treinamento sem o uso dessa técnica.

• **Unidade linear retificada** (Rectified Linear Unit – ReLU): As camadas de convolução e de normalização em lote são, geralmente, seguidas por funções de ativação não lineares, sendo a ReLU uma das mais utilizadas. Essa função aplica uma operação de limiar a cada elemento da entrada, sem modificar suas dimensões: todos os valores inferiores a zero são transformados em zero, mantendo inalterados os valores positivos.

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1)$$

De acordo com experimentos apresentados por Krizhevsky, Sutskever e Hinton (2012), a função ReLU apresenta vantagens em relação às funções de ativação clássicas, como a sigmoide e a tangente hiperbólica. Essas últimas implementam formas de não-linearidade saturante, enquanto a ReLU, por sua natureza não linear e não saturante, tende a reduzir tanto o tempo quanto o erro durante o treinamento da rede. A Figura 16 ilustra graficamente o comportamento da função ReLU.

Figura 16 – Representação gráfica da função de ativação ReLU.




Fonte: Hijazi, Kumar e Rowen (2015)

As atualizações dos pesos em uma rede neural, a cada iteração, são proporcionais ao valor do gradiente calculado. No caso da função de ativação

tangente hiperbólica ($\tanh$), observa-se que seu gradiente torna-se praticamente nulo em regiões cujos valores ultrapassam 1 ou são inferiores a -1. Quando a saída de determinados neurônios atinge esses limites, o gradiente se aproxima de zero, fazendo com que os pesos deixem de ser ajustados. Tal comportamento é especialmente problemático quando ocorre nas etapas iniciais do treinamento, pois pode comprometer o aprendizado da rede. Em contrapartida, a função de ativação ReLU permite que os pesos de um neurônio continuem sendo atualizados proporcionalmente ao longo de todo o processo de treinamento, o que contribui para a eficiência da aprendizagem (Krizhevsky; Sutskever; Hinton, 2012).

• **Camadas de Pooling:** Também conhecidas como camadas de subamostragem, as camadas de pooling têm como principal função reduzir a dimensionalidade dos mapas de características recebidos como entrada, gerando mapas mais compactos que representam um resumo das informações essenciais do original (Hijazi; Kumar; Rowen, 2015). Existem diferentes técnicas de subamostragem que podem ser aplicadas a um mapa de características, sendo as mais comuns: a seleção do valor máximo (*max pooling*), o cálculo da média (*average pooling*) e a utilização da norma do conjunto (L2- *pooling*), entre outras. A Figura 17 ilustra a aplicação do *max pooling* utilizando filtros de tamanho 2×2 e *stride* igual a 2, resultando em um novo mapa de características com menor resolução espacial, mas com a preservação das informações mais relevantes.

Figura 17 - Exemplo de Max-Pooling com filtro 2×2 e stride igual a 2.




Fonte: Hijazi, Kumar e Rowen (2015)

• **Camada totalmente conectada (Fully Connected Layer)-** A camada totalmente conectada estabelece ligações entre todos os neurônios da camada anterior e os neurônios da camada de saída, que correspondem às classes a serem classificadas. Essa camada é responsável por integrar todas as características locais extraídas pelas camadas anteriores, combinando-as para formar descritores globais

da imagem. Esses descritores são, então, utilizados pela camada de saída que geralmente emprega a função *softmax* para realizar a classificação final. A Figura 18 ilustra a camada totalmente conectada L, na qual dois mapas de características provenientes da camada anterior são combinados por meio dos pesos $w(L)$. Conforme representado na imagem, o processo culmina na geração do *target* correspondente à classe prevista na saída da rede (Hijazi; Kumar; Rowen, 2015).

Figura 18- Processamento de uma camada totalmente conectada.



Fonte: Hijazi, Kumar e Rowen (2015)

Softmax: A função de ativação *Softmax* é utilizada para normalizar a saída da camada totalmente conectada. Essa função transforma os valores de ativação em uma distribuição de probabilidade, produzindo como saída um vetor composto por valores positivos cuja soma é igual a 1. Esses valores podem, então, ser interpretados como as probabilidades associadas a cada classe, sendo utilizados no processo de classificação final (Goodfellow; Bengio; Courville, 2016). A ativação de cada unidade da camada de saída é determinada pela aplicação da função *Softmax*, conforme a expressão matemática correspondente.

$$y_r(x) = \frac{\exp(a_r(x))}{\sum_{j=1}^k \exp(a_j(x))} \quad (2)$$

$$\text{onde } 0 \leq y_r \leq 1 \quad \sum_{j=1}^k y_j = 1$$

Camada de Classificação: Deve aplicada após a função de ativação *Softmax*. Nessa etapa, os valores normalizados fornecidos pela *Softmax* são utilizados pela função de

perda para atribuir cada entrada a uma das k classes mutuamente exclusivas (NIELSEN 2015). Para isso, é empregada a função de perda de entropia cruzada, em um esquema de codificação de 1-de- k :

$$E(\theta) = - \sum_{i=1}^n \sum_{j=1}^k t_{ij} \ln y_j(x_i, \theta) \quad (3)$$

onde t_{ij} é o indicador de que a amostra i pertence à classe j , θ é o vetor de parâmetros. A saída para a amostra i é definida como $y_j(x_i, \theta)$ que neste caso é o valor da função *Softmax*. Ou seja, é a probabilidade de a rede associar a entrada i à classe j conforme:

$$P(t_j = 1 | x_i) \quad (4)$$

3.4.2 Emprego em Reconhecimento de Padrões

O reconhecimento de padrões é vital em aplicações tecnológicas, especialmente no controle de qualidade da pintura de peças metálicas. Sistemas de inteligência artificial permitem que máquinas identifiquem e classifiquem defeitos visuais, fundamentais na indústria, onde a qualidade das superfícies pintadas é crucial. Técnicas de aprendizado de máquina, como redes neurais convolucionais, possibilitam a detecção de imperfeições que comprometem a funcionalidade e a estética dos produtos (Patel *et al.*, 2021).

As aplicações para reconhecimento de padrões vão além da inspeção, incluindo automação da verificação e otimização da produção. Com câmeras de alta resolução, algoritmos de IA detectam anomalias e distinguem entre defeitos aceitáveis e inaceitáveis, influenciando decisões econômicas sobre retrabalho ou descarte de produtos, o que reduz custos e aumenta a eficiência. Além disso, esses sistemas criam bancos de dados que alimentam algoritmos de aprendizado, aprimorando continuamente as capacidades de identificação (Krizhevsky; Sutskever; Hinton, 2017).

O reconhecimento de padrões também impulsiona a personalização e inovação de produtos. Coletando dados sobre acabamentos e fatores ambientais, as empresas podem otimizar suas formulações de tinta, melhorando qualidade e durabilidade. Esse ciclo de feedback eleva a qualidade final e cria um ambiente de produção sustentável,

utilizando recursos de maneira eficiente. Por isso, o reconhecimento de padrões é uma ferramenta vital para inovação contínua na indústria siderúrgica (Qiao *et al.*, 2025).

3.4.3 Uso no Setor Industrial

As Redes Neurais Convolucionais (CNNs) têm desempenhado um papel crescente na modernização de processos industriais, especialmente na inspeção automatizada baseada em imagens e na previsão da qualidade de produtos em tempo real. Em segmentos produtivos que envolvem aquecimento intenso ou fabricação rápida como manufatura aditiva, soldagem por pontos e produção de semicondutores, sensores ópticos, como câmeras de alta velocidade e pirômetros, são empregados para monitoramento contínuo, permitindo detectar falhas durante a produção e realizar correções imediatas.

A aplicação de CNNs tem se mostrado altamente eficaz na identificação e classificação de falhas em ambientes industriais, contribuindo significativamente para a automação e a melhoria do controle de qualidade. Liu, Li e Shen (2020) apresentaram uma revisão sobre o uso de técnicas de aprendizado profundo em sistemas de inspeção de superfícies, evidenciando a eficiência dos métodos baseados em CNNs na detecção automatizada de defeitos. De forma semelhante, Zhang, Cheng e Wang (2020) descreveram diversas estratégias de aprendizado profundo aplicadas à identificação de anomalias em processos industriais, incluindo classificadores baseados em imagens com alta acurácia.

No setor cerâmico, onde os defeitos se concentram majoritariamente na superfície dos produtos, a inspeção visual por meio de redes neurais também tem avançado significativamente. Ma *et al.* (2021) apresentaram um levantamento abrangente de métodos baseados em visão computacional para inspeção de superfícies, abordando algoritmos voltados à análise de revestimentos cerâmicos. Os autores discutem técnicas que incluem desde extração de características locais até classificadores como Máquinas de Vetores de Suporte (SVM), ressaltando a importância da combinação de abordagens estatísticas e estruturais. Complementando essa perspectiva, Xie e Liu (2022) revisaram algoritmos modernos de detecção de defeitos industriais com base em redes neurais profundas, destacando modelos especializados para regiões críticas, como as bordas de peças.

Na área da construção civil, o uso de redes neurais profundas também tem se mostrado promissor. Técnicas de detecção visual, com base em imagens de estruturas de concreto, têm sido empregadas para identificar fissuras, manchas de umidade, corrosão e outras patologias. Essas abordagens automatizadas contribuem para o diagnóstico precoce e para a manutenção preventiva, aumentando a segurança e a durabilidade das construções (Zhang; Cheng; Wang, 2020).

Esses trabalhos reforçam a versatilidade das CNNs e das técnicas de visão computacional como soluções eficazes para demandas industriais. Sua adoção tem promovido maior precisão e agilidade na detecção de falhas, consolidando essas tecnologias como componentes-chave da automação inteligente no contexto da Indústria 4.0.

3.4.4 Aplicações em Reconhecimento de Imagens

O uso da inteligência artificial (IA) para o reconhecimento de imagens tem transformado diversos setores da sociedade, como a saúde, a segurança pública e o marketing, tornando-se uma das aplicações mais significativas da tecnologia contemporânea. Essa técnica baseia-se na identificação e classificação de objetos, pessoas ou ambientes em imagens digitais, utilizando algoritmos de aprendizado profundo que simulam a percepção visual humana. Nesse cenário, as Redes Neurais Convolucionais (CNNs) têm papel central, possibilitando a análise precisa e eficiente de grandes quantidades de dados visuais. Por meio de suas camadas convolucionais, essas redes extraem características progressivas e representativas, convertendo dados brutos em informações estruturadas e interpretáveis (Gu *et al.*, 2018).

Na área médica, o reconhecimento automatizado de padrões visuais tem proporcionado avanços significativos, especialmente na detecção precoce de doenças. Aplicações baseadas em IA são capazes de interpretar exames como tomografias, radiografias e ressonâncias magnéticas, identificando alterações patológicas que poderiam não ser percebidas por profissionais de saúde em uma análise convencional. Estudos apontam que algoritmos de deep learning têm alcançado taxas de acurácia elevadas na identificação de câncer de mama em mamografias, por vezes superando especialistas humanos (Litjens *et al.*, 2017). Além da detecção, esses sistemas auxiliam na personalização terapêutica, ao reconhecer

variações sutis nas características das doenças, promovendo tratamentos mais direcionados.

No campo da segurança pública, tecnologias de reconhecimento facial baseadas em IA têm sido amplamente empregadas para identificação de indivíduos em tempo real. Câmeras de vigilância alimentadas por sistemas inteligentes podem associar imagens de rostos a bancos de dados criminais, contribuindo para ações preventivas e reativas por parte das autoridades. No entanto, esse tipo de aplicação também traz à tona importantes dilemas éticos e legais, especialmente no que se refere à privacidade, ao consentimento e ao risco de viés algorítmico (Garvie; Bedoya; Frankle, 2016). Assim, é necessário um debate contínuo sobre os limites do uso dessas tecnologias, de forma a equilibrar os benefícios à segurança com os direitos individuais.

Portanto, o reconhecimento de imagens com IA representa uma inovação poderosa e multifacetada. Suas aplicações têm o potencial de transformar áreas essenciais, otimizando processos, reduzindo erros humanos e oferecendo novas possibilidades de diagnóstico e vigilância. Ainda assim, sua implementação deve ser acompanhada de regulamentações adequadas e de uma análise crítica quanto às implicações sociais e éticas envolvidas.

3.4.5 Inspeções automatizadas

A automação das inspeções tem se consolidado como uma solução eficaz para aprimorar a qualidade e a confiabilidade nos processos produtivos de diversos setores industriais. A incorporação de tecnologias baseadas em inteligência artificial (IA), sensores inteligentes e visão computacional tem possibilitado a realização de análises detalhadas em tempo real, minimizando a intervenção humana e reduzindo significativamente o risco de erros associados à variabilidade humana (Hütten *et al.*, 2024).

Essa abordagem permite uma coleta contínua e sistemática de dados visuais, que são processados por algoritmos capazes de identificar padrões e anomalias com alto grau de precisão. Com isso, as inspeções automatizadas se tornam ferramentas essenciais não apenas para o controle de qualidade, mas também para a manutenção

preditiva e para a rastreabilidade dos processos, contribuindo para a tomada de decisões mais ágil e assertiva (Shan *et al.*, 2025).

Na indústria de manufatura, por exemplo, câmeras de alta resolução integradas a modelos de deep learning podem inspecionar produtos em linhas de produção com velocidade e precisão superiores às capacidades humanas. Esses sistemas são capazes de detectar defeitos mínimos, como variações de textura ou microfissuras, assegurando maior uniformidade e conformidade com padrões regulatórios. Além disso, o uso de redes neurais convolucionais (CNNs) permite que esses modelos aprendam continuamente com novos dados, tornando-se progressivamente mais eficientes (Ryck *et al.*, 2021).

Outro benefício relevante é a padronização dos critérios de inspeção, que garante consistência nos resultados e reduz a subjetividade na avaliação. Essa uniformidade é especialmente importante em setores regulados, como o farmacêutico e o alimentício, onde a precisão e a rastreabilidade são fundamentais (Patel; Sharma, 2023).

Contudo, a efetividade da inspeção automatizada depende não apenas da tecnologia implementada, mas também da integração de uma estratégia organizacional. Isso inclui o treinamento adequado das equipes, a interpretação correta dos dados gerados e a adaptação contínua dos processos com base nas informações coletadas. A automação, nesse contexto, não é apenas uma ferramenta de controle, mas um vetor de inovação, que promove melhorias contínuas e fortalece a competitividade das empresas em um mercado cada vez mais exigente (Bomfim *et al.*, 2024).

3.4.6 Processamento Digital de Imagens


Conforme destacado por Gonzalez e Woods (2008), o processamento digital de imagens abrange técnicas em que tanto os dados de entrada quanto os de saída são imagens, além de métodos voltados à extração de informações visuais e à identificação de objetos específicos nelas contidos. Essa área pode ser segmentada em três estágios principais: baixo, médio e alto nível. No nível mais básico, são realizadas operações simples e preliminares de pré-processamento, em que as imagens originais são também os produtos finais do processo. Já o nível intermediário envolve atividades como a segmentação da imagem, a descrição de formas e a

categorização de elementos, onde se parte de imagens como entrada, mas os resultados obtidos são atributos extraídos delas. Por fim, o processamento de alto nível está relacionado à interpretação do conteúdo das imagens, promovendo análises cognitivas e atribuindo significados aos objetos detectados, aproximando-se das capacidades do sistema visual humano.

3. 4.6.1 Sistema de Visão Artificial

De acordo com Sze *et al.* (2017), um Sistema de Visão Artificial pode ser definido como um conjunto computacional capaz de capturar, processar e interpretar imagens de cenas do mundo real. Esse tipo de sistema tem como objetivo extrair informações relevantes a partir de dados visuais, permitindo a tomada de decisões automatizadas. As etapas fundamentais que compõem um Sistema de Visão Artificial estão representadas na Figura 19.

Figura 19- Etapas de um Sistema de Visão Artificial



Fonte: Jancarczyk *et al.* (2024)

3.4.6.2 Aquisição

O processo de aquisição refere-se à transformação de uma imagem em uma forma numérica adequada para o processamento digital. Esse processo envolve um

dispositivo físico sensível a uma faixa específica do espectro eletromagnético, capaz de gerar um sinal elétrico proporcional à energia detectada, e um digitalizador, que converte esse sinal analógico em dados digitais (Sze *et al.*, 2017).

Uma imagem é gerada pela interação entre uma fonte de luminosa e os objetos da cena, que refletem ou absorvem a energia eletromagnética. A captação ocorre por meio de um sensor, que transforma a energia luminosa em variações de tensão elétrica (Mishra *et al.*, 2017).

A digitalização da imagem envolve os processos de amostragem e quantização do sinal analógico fornecido pelo sensor. A amostragem promove a discretização espacial, convertendo a imagem contínua em uma matriz $M \times N$, na qual cada elemento corresponde a um pixel, conforme ilustrado na Equação 5. Já a quantização trata da discretização em amplitude, atribuindo a cada pixel um valor inteiro que varia entre 0 e $2^n - 1$, sendo n o número de bits usados para representar os níveis de intensidade (Marques Filho; Vieira Neto, 1999).

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & \vdots & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix} \quad (5)$$

3.4.6.3 Pré-processamento

Durante o pré-processamento, busca-se aprimorar a qualidade da imagem com o objetivo de facilitar as etapas posteriores do processamento. As operações realizadas nesse estágio atuam diretamente sobre os níveis de intensidade dos pixels (Marques Filho; Vieira Neto, 1999).

As técnicas empregadas nessa fase podem ser classificadas em duas abordagens principais: aquelas que atuam no domínio espacial, utilizando filtros aplicados diretamente na imagem, e aquelas que operam no domínio da frequência, com filtros aplicados sobre o espectro da imagem (Gupta *et al.*, 2017).

Um procedimento bastante comum no pré-processamento é a conversão de imagens coloridas em tons de cinza, uma vez que muitas técnicas de processamento trabalham preferencialmente com imagens monocromáticas devido à sua menor complexidade (Gonzalez; Woods, 2018).

Os filtros espaciais também se destacam por sua ampla utilização nesta etapa. Esses filtros realizam operações sobre cada pixel levando em consideração seus vizinhos, resultando em novos valores para os pixels da imagem. Entre as operações mais comuns estão a suavização, voltada para a redução de ruídos, e o realce, que busca destacar mudanças significativas na intensidade da imagem (Gonzalez; Woods, 2008).

Outra prática recorrente no pré-processamento é a análise do histograma da imagem, que consiste em contabilizar os níveis de cinza existentes. Essa análise fornece informações relevantes sobre o contraste e a distribuição da iluminação da imagem, sendo útil para ajustes posteriores (Gupta *et al.*, 2017).

3.4.6.4 Segmentação

A segmentação é uma etapa essencial no processamento de imagens, responsável por dividi-las em regiões que representam objetos ou áreas de interesse. De acordo com Gonzalez e Woods (2018), as principais técnicas de segmentação baseiam-se na similaridade ou na descontinuidade dos valores de intensidade dos pixels. Métodos baseados na similaridade agrupam pixels com características semelhantes, enquanto os baseados na descontinuidade identificam variações abruptas nesses valores.

Entre as técnicas que utilizam a similaridade, destaca-se a binarização, que transforma a imagem em apenas dois níveis de luminância — preto e branco — por meio de um limiar (threshold) que separa objeto e fundo (Gupta *et al.*, 2017).

Já nas abordagens por descontinuidade, a detecção de bordas é uma das mais comuns. Segundo Costa e César (2009), essa técnica pode usar o gradiente, que corresponde à derivada de primeira ordem, ou o Laplaciano, que representa a derivada de segunda ordem. No gradiente, as bordas são identificadas por meio de um limiar aplicado à magnitude da variação de intensidade. No caso do Laplaciano, a borda ocorre onde essa variação é nula.

Dentre os métodos baseados em gradiente, o operador de Sobel é amplamente utilizado. Ele calcula os gradientes por meio de máscaras de convolução aplicadas à imagem e, em seguida, usa um threshold para destacar os pixels com maiores variações (Marques Filho; Vieira Neto, 1999).

O detector de bordas de Canny, por sua vez, é um método mais sofisticado e preciso. Além da estimativa dos gradientes, realiza a supressão de não-máximos, garantindo bordas mais finas, e aplica uma limiarização com histerese, que ajuda a reduzir erros na detecção (Gonzalez; Woods, 2018).


3.4.6.5 Extração de Características

A extração de características é a fase do processamento de imagens dedicada à obtenção de informações numéricas relevantes sobre a imagem ou sobre regiões previamente segmentadas. Conforme Gupta *et al.* (2017), essa etapa permite representar os objetos identificados de forma quantitativa, facilitando sua análise. Inicialmente, as regiões de interesse são rotuladas, e as características podem ser extraídas de toda a imagem ou de áreas específicas. No primeiro caso, obtêm-se, por exemplo, o número total de objetos ou a área que ocupam; no segundo, é possível calcular métricas como área individual, perímetro e forma.

Entre os métodos empregados para essa finalidade, destaca-se a Transformada de Hough, um procedimento eficiente para identificar curvas com representação matemática, como linhas e círculos. Essa técnica permite estimar parâmetros estruturais dos elementos detectados (Mileski, 2017).

Conforme descrito por Gonzalez e Woods (2018), a Transformada de Hough atua mapeando pontos da imagem para um espaço de parâmetros, onde cada eixo representa um parâmetro da curva a ser identificada. No caso específico da detecção de círculos, a técnica localiza o centro da forma com base em um raio previamente definido. Assim, considerando um círculo com raio R e centro em (a_0, b_0) cada ponto da borda identificado na segmentação contribui com um círculo no espaço de parâmetros, com centro no ponto da borda (x_i, y_j) e raio R , conforme mostra a Figura 20.

Figura 20- Ilustração da Transformada de Hough para círculos.



Fonte: Cherabit et al. (2012)

O centro verdadeiro do círculo (a_0, b_0) , é identificado no ponto de interseção entre os diversos círculos gerados no espaço de parâmetros, indicando a presença de uma borda circular na imagem (Cherabit *et al.*, 2012).

3.4.6.6 Reconhecimento e Interpretação

As etapas finais de um sistema de visão computacional envolvem o reconhecimento e a interpretação dos objetos extraídos. A fase de reconhecimento consiste na classificação dos elementos por meio das características previamente extraídas, atribuindo rótulos ou categorias a cada objeto. Já a interpretação busca relacionar esses objetos ao contexto, conferindo-lhes significado dentro do cenário analisado (Marques Filho; Vieira Neto, 1999).

3.5 MODELOS DE CORES

3.5.1 Escala de Cinza- Imagem Monocromática

De acordo com Marques Filho e Vieira Neto (1999), uma imagem monocromática pode ser matematicamente descrita por uma função $f(x,y)$ que representa a intensidade luminosa em cada ponto com coordenadas espaciais (x,y) . O valor dessa função, em qualquer ponto, é proporcional ao brilho, e esse tipo de imagem também é conhecido como imagem binária nesse local específico.

A percepção de imagens por seres vivos difere da forma como os computadores as interpretam. Enquanto os seres vivos interpretam diretamente as imagens, os computadores trabalham com números, por isso as imagens precisam ser convertidas em conjuntos numéricos denominados pixels. Os *pixels* ou *pels* (abreviação de *picture elements*) são as menores unidades constituintes de uma imagem digital. Na Figura 21, observa-se uma imagem em escala de cinza, onde cada elemento da matriz que compõe a imagem digital é chamado de pixel, termo que significa "elemento da figura" (Gonzalez; Woods, 2010; Pedrini; Schwartz, 2008)


Figura 21 – Imagem em escala de cinza e a convenção utilizada para o sistema de coordenadas (x,y).



Fonte: Marques Filho; Vieira Neto (1999).

Conforme apresentado na Figura 21, os autores adotam uma convenção diferente do sistema cartesiano tradicional: a origem da imagem está localizada no canto superior esquerdo, e esse mesmo sistema será adotado neste trabalho. Por essa razão, as coordenadas X e Y não assumem valores negativos (Marques Filho; Vieira Neto, 1999). As imagens digitais podem ser representadas por matrizes bidimensionais, onde o valor do pixel é localizado no ponto (0,0). Para melhor visualização, a Figura 22 exemplifica a representação matricial.

Figura 22 – Representação matricial de uma imagem.




Fonte: Marques Filho; Vieira Neto (1999)

Na Figura 22, pode-se observar que as coordenadas nos eixos X e Y indicam um ponto específico da imagem, e o valor associado a esse ponto corresponde ao nível de cinza naquela posição. A distribuição desses níveis pode ser expressa por meio de um histograma, comum na análise de imagens monocromáticas.

Além das imagens em escala de cinza, existem imagens digitais coloridas que são representadas por matrizes tridimensionais, compondo imagens multiespectrais. A percepção das cores pelo olho humano pode ser descrita pelo modelo RGB (Red, Green, Blue – Vermelho, Verde e Azul), que pode ser visualizado como um cubo tridimensional, conforme ilustrado na Figura 23.

Figura 23 – Esquema em cubo de cores RGB



Fonte: Marques Filho; Vieira Neto (1999).

Na figura 23, os vértices desse cubo representam as cores primárias do modelo RGB, enquanto a diagonal principal apresenta os valores correspondentes aos tons de cinza.

Para imagens em tons de cinza, existem métodos de segmentação baseados em descontinuidade ou similaridade. A descontinuidade ocorre quando há uma mudança abrupta nos níveis de cinza, permitindo identificar as bordas que delimitam regiões diferentes na imagem. Já a segmentação por similaridade utiliza a técnica de limiarização (*thresholding*), que classifica diferentes objetos da imagem com base nas diferenças entre seus níveis de cinza.

Por meio da limiarização, é possível segmentar uma imagem em duas classes distintas utilizando um valor de corte, processo também conhecido como binarização, pois gera como resultado uma imagem binária. Os objetos de interesse podem ser classificados como primeiro plano, fundo ou um objeto específico a ser detectado, utilizando características como cor, borda ou similaridade para a identificação (Solem, 2012).


3.5.2 Modelos RGB e HSV

As imagens digitais podem ser representadas por diferentes modelos de cores, que estabelecem padrões para descrever as variadas tonalidades existentes (Gonzales; Woods, 2018). Entre os mais usados em visão computacional destacam-se os modelos RGB (Red, Green, Blue) e HSV (Hue, Saturation, Value).

No modelo RGB, as cores são formadas pela combinação dos três componentes: vermelho, verde e azul. Como modelo aditivo, ele gera as cores por meio da soma das intensidades desses canais (Meskaldji; Boucherkha; Chikhi, 2009). Imagens em RGB podem ser representadas por uma matriz tridimensional $m \times n \times 3$, em que m e n são as dimensões da imagem e 3 corresponde aos canais de cor. Os valores geralmente variam entre 0 e 255.

Já o modelo HSV descreve as cores com base em matiz (hue), saturação (saturation) e valor (value). O canal matiz indica a tonalidade da cor, a saturação refere-se à intensidade ou pureza da cor, e o valor determina seu brilho (Pandey; Mishra; Sharma, 2011; Mythili; V. Kavitha, 2012; Georgieva; Dimitrova; Angelov, 2005). A Figura 22 mostra uma comparação dos dois modelos: o RGB é representado por um cubo (Figura 22a) e o HSV por um cilindro (Figura 22b).


Figura 24 – Representação de cor nos modelos RGB e HSV



Fonte: Meskaldji *et al.* (2009)

Uma característica importante do modelo HSV é a invariância do canal matiz às variações de iluminação (Sergyán, 2007). Isso torna o HSV especialmente adequado para aplicações de visão computacional que dependem da cor. Na Figura 25, observa-se a decomposição de uma imagem nos canais dos modelos RGB e HSV, sob diferentes níveis de brilho. Nota-se que o canal matiz do HSV (destacado em vermelho) permanece constante, mesmo com mudanças na iluminação.

Figura 25 – Comparativo da decomposição de uma imagem nos modelos HSV e RGB



Fonte: Meskaldji *et al.* (2009)

3.6 TREINAMENTO DO MODELO

O processo de treinamento de um modelo envolve o ajuste contínuo dos pesos das camadas totalmente conectadas e dos filtros convolucionais. Isso ocorre por meio de interações sucessivas entre as camadas, com o objetivo de reduzir a diferença entre a saída gerada pela rede e o resultado esperado. Esse processo utiliza as etapas de propagação direta (forward) e retropropagação (backpropagation) a cada ciclo de treinamento (Goodfellow; Bengio; Courville, 2016).

Antes de iniciar o treinamento propriamente dito, de acordo com Géron (2020), é necessário definir diversos hiperparâmetros — variáveis que orientam a estrutura e o comportamento do processo de aprendizado. Alguns já foram mencionados, como o número de camadas ocultas, além de configurações de pooling e stride. Outros dizem respeito diretamente ao treinamento, como a taxa de aprendizado, o número de épocas, o uso de dropout, entre outros. A escolha adequada desses parâmetros é desafiadora e requer investigação cuidadosa (Goodfellow; Bengio; Courville, 2016). Neste trabalho, as definições adotadas basearam-se em estudos prévios e nas limitações computacionais disponíveis.

Dois hiperparâmetros importantes são o tamanho do mini-lote (batch size) e o número de épocas. O mini-lote representa a divisão do conjunto de treinamento em pequenos grupos de dados, facilitando o processamento e reduzindo o uso de memória em comparação com o uso de uma amostra por vez. Ao final de cada lote, calcula-se o erro entre as saídas previstas e as esperadas, permitindo a atualização dos pesos por meio do algoritmo de otimização. Esse processo se repete ao longo de todos os lotes de uma época. Cada época corresponde a um ciclo completo de avaliação de todas as imagens do conjunto de dados. O número de épocas deve ser suficiente para que a rede alcance um erro mínimo aceitável (Zhang *et al.*, 2017, p. 5).

3.7 MÉTRICAS DE AVALIAÇÃO

Após o treinamento e a obtenção do modelo final, torna-se essencial avaliar seu desempenho, a fim de verificar a eficácia da abordagem adotada (Singh; Thakur; Sharma, 2016). No caso da tarefa de classificação binária abordada neste estudo, utiliza-se um conjunto de métricas baseadas em quatro possíveis tipos de resultado, como apresentado no Quadro 1 (Resultados de classificações possíveis).

Quadro 1- Resultados de classificações possíveis.

Verdadeiro Positivo (VP)	O sistema classificou como verdadeiro, e efetivamente o resultado é verdadeiro
Verdadeiro Negativo (VN)	O sistema classificou como falso, e efetivamente o resultado é falso
Falso Positivo (FP)	O sistema classificou como verdadeiro, e efetivamente o resultado é falso
Falso Negativo (FN)	O sistema classificou como falso, e efetivamente o resultado é verdadeiro

Fonte: Autoria própria (2025).

A acurácia é uma das métricas mais utilizadas, representando a proporção de acertos (tanto positivos quanto negativos) sobre o total de amostras avaliadas (Singh; Thakur; Sharma, 2016). Conforme a Equação 6:

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (6)$$

Outra métrica importante é a precisão, que expressa a proporção de amostras classificadas como positivas que realmente pertencem à classe positiva (Equação 7) (SINGH; THAKUR; SHARMA, 2016):

$$Precisão = \frac{VP}{VP + FP} \quad (7)$$

A revocação (ou sensibilidade) mede a capacidade do modelo de identificar corretamente os exemplos da classe positiva (Singh; Thakur; Sharma, 2016). Conforme a Equação 8:

$$Revocação = \frac{VP}{VP + FN} \quad (8)$$

Por fim, o F1-Score é a média harmônica entre precisão e revocação, oferecendo um equilíbrio entre ambas, como definido na Equação 9 (Singh; Thakur; Sharma, 2016):

$$F1 - Score = 2 * \frac{Precisão * Revocação}{Precisão + Revocação} \quad (9)$$

Outro recurso relevante na análise de desempenho é a matriz de confusão, que permite comparar as classificações reais com as previstas para cada classe (Powers, 2017). No Quadro 2, observa-se que os valores na diagonal principal indicam as classificações corretas, enquanto os demais representam os erros: falsos positivos (FP) e falsos negativos (FN), conhecidos também como erros tipo I e tipo II, respectivamente.

Quadro 2 - Matriz de confusão.

		Classe Preditada	
		Positivo	Negativo
Classe Real	Positivo	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Negativo	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: Autoria própria (2025).

4 MATERIAS E MÉTODOS

Neste capítulo, apresentam-se detalhadamente o material e os métodos utilizados na condução da pesquisa. Na Seção 3.1, são delineados os materiais empregados como objetos de teste. Já na Seção 3.2, discute-se a metodologia desenvolvida, que inclui a descrição dos arranjos montados na fábrica para os ensaios experimentais, bem como as técnicas empregadas no processamento digital das imagens para a extração de dados e análise quantitativa e qualitativa.

4.1 MATERIAL

O material utilizado para o desenvolvimento deste trabalho são as imagens de peças metálicas de um processo produtivo local. O processo de aquisição das imagens ocorreu por meio de amostragem de algumas imagens do processo. Além disso, foi aproveitado o banco de dados da própria indústria, que mantém um controle de qualidade sobre as peças com defeitos na pintura.

4.2 MÉTODOS

4.2.1 Aquisição das imagens

As imagens utilizadas no trabalho foram obtidas de duas formas. A primeira são as imagens de peças com defeitos de fabricação, que foram extraídas do banco de dados da própria indústria, esse banco de dados é para controle interno e avaliação de melhorias do processo produtivo. A segunda forma, foi através de imagens registradas pelo próprio autor, através de câmera fotográfica, posicionada no final do processo e em locais de armazenamento das peças já concluídas.

Figura 26 – Esteira de pintura das peças metálicas.




Fonte: Próprio autor.

A metodologia utilizada para o desenvolvimento do trabalho, foi o treinamento de uma inteligência artificial, onde ela poderá identificar uma peça defeituosa antes que seja entregue no final do processo.

Abaixo temos um resumo das etapas que serão aplicadas dentro do processo de identificação.

Figura 27 – Etapas de um sistema de Visão Computacional típico.



Fonte: Próprio autor (2025).

4.2.2 Segmentação

Este trabalho apresenta uma estrutura para a classificação de imagens em

duas categorias "conforme" e "não conforme", onde esta classificação será um indicativo que a peça analisada está dentro dos padrões de fabricação ou não. Abaixo apresenta-se alguns exemplos de imagens utilizadas na pesquisa.

Figura 28 – Imagem de peça não conforme.



Fonte: Próprio autor (2025).

Figura 29 – Imagem de peça não conforme.



Fonte: Próprio autor (2025).

Figura 30 – Imagem de peça conforme.



Fonte: Próprio autor (2025).

Figura 31 – Imagem de peça conforme.




Fonte: Próprio autor (2025).

A preparação dos dados é uma etapa crucial em qualquer projeto de aprendizado de máquina, uma vez que a qualidade e a diversidade dos dados de entrada impactam diretamente o desempenho do modelo (Bishop, 2006). No nosso caso, as imagens coletadas são organizadas em diretórios, representando as duas classes de interesse, conformes e não conformes. A biblioteca OpenCV será utilizada para ler as imagens em escala de cinza, um formato que reduz a complexidade computacional e facilita a extração de características essenciais (Zhang *et al.*, 2019).

A leitura em escala de cinza permite que o modelo se concentre nas variações de luminosidade e textura, que frequentemente são mais relevantes para a tarefa de classificação do que a informação de cor.


Abaixo, vemos alguns exemplos de imagens antes e depois do pré-processamento.

Figura 29 – Imagem de peça antes e após a preparação.



Fonte: Próprio autor(2025).

Figura 31 – Imagem de peça antes e após a preparação.



Fonte: Próprio autor(2025).

Uma vez lidas, as imagens devem ser ajustadas para um tamanho fixo. As CNNs requerem entradas de tamanho uniforme para garantir que as operações convolucionais funcionem corretamente (Goodfellow *et al.*, 2016). Neste estudo, as imagens são redimensionadas para 700x700 pixels.

Esse ajuste é fundamental, pois uma entrada consistente permite que a arquitetura da rede seja definida de forma mais eficiente, evitando problemas de dimensionalidade.

Após esta inicial, será feita uma normalização das imagens. A normalização é uma técnica amplamente utilizada que melhora a eficiência do treinamento de modelos de aprendizado de máquina. Neste pipeline, os valores de pixel das imagens são escalados para a faixa [0, 1] dividindo-se por 255. Essa prática não apenas acelera a convergência do modelo, mas também ajuda a estabilizar o processo de aprendizado (Ioffe; Szegedy, 2015).

A normalização é especialmente importante em CNNs, pois reduz a sensibilidade a diferentes escalas de entrada, permitindo que a rede aprenda de maneira mais eficaz.

4.2.3 Extração das características

4.2.3.1 Redes neurais

As Redes Neurais Convolucionais (CNNs) são uma classe de redes neurais

projetadas especificamente para processar dados com uma estrutura de grade, como imagens. Desde a sua introdução, as CNNs têm revolucionado o campo da visão computacional, sendo amplamente utilizadas em tarefas como reconhecimento de objetos, segmentação de imagens e detecção de faces. A arquitetura das CNNs é inspirada na organização do córtex visual dos animais, onde diferentes áreas são responsáveis por detectar características específicas em estímulos visuais.

Esse processo é essencial para a identificação de padrões em dados visuais. Após as operações de convolução, as camadas de pooling são utilizadas para reduzir a dimensionalidade dos dados, preservando as características mais relevantes e melhorando a eficiência computacional. Finalmente, as camadas totalmente conectadas interpretam as características extraídas e realizam a classificação final.

A eficácia das CNNs se deve à sua capacidade de aprender representações hierárquicas de dados. Em camadas iniciais, a rede pode aprender características simples, como bordas, enquanto camadas mais profundas podem combinar essas características para detectar formas e, eventualmente, objetos inteiros. Essa abordagem hierárquica permite que as CNNs superem muitos métodos tradicionais de aprendizado de máquina em tarefas de visão computacional, levando a avanços significativos em aplicações práticas (Krizhevsky *et al.*, 2012; LeCun *et al.*, 2015).

A introdução de técnicas como regularização, normalização e aumento de dados contribuiu ainda mais para o sucesso das CNNs, permitindo que essas redes se tornem mais robustas e generalizáveis. Como resultado, as CNNs têm se consolidado como uma ferramenta fundamental na pesquisa e desenvolvimento de soluções baseadas em inteligência artificial, moldando o futuro da interação entre humanos e máquinas.

A etapa de construção do modelo de Rede Neural Convolucional (CNN) é um dos momentos mais críticos em um projeto de aprendizado profundo, especialmente para tarefas de classificação de imagens. No trabalho proposto, a construção do modelo é realizada usando a biblioteca TensorFlow e a API Keras. A seguir, detalharemos cada parte do processo de construção do modelo.

As camadas convolucionais são cruciais para a hierarquia de características que as CNNs aprendem. Em camadas iniciais, a rede aprende a detectar características simples, como bordas e cantos. À medida que se avança para camadas mais profundas, as características se tornam mais complexas, como formas e até mesmo objetos inteiros. Essa capacidade de hierarquização é uma das razões

pelas quais as CNNs têm um desempenho superior em tarefas de visão computacional.

4.2.4 Modelo da rede neural

A construção de uma Rede Neural Convolucional (CNN) envolve várias etapas fundamentais que visam extrair características relevantes de imagens e realizar a classificação. Este resumo detalha cada etapa do modelo implementado na função `create_model()`, explicando o propósito e a configuração de cada camada (Krizhevsky; Sutskever; Hinton, 2012).

A arquitetura do modelo é iniciada pela instância da classe `'Sequential'` do Keras, esse tipo de modelo permite a adição de camadas de forma sequencial, facilitando a construção de redes de profundidade variada. A abordagem sequencial é comum em tarefas de classificação de imagens devido à sua simplicidade e eficácia (*Idem*).

4.2.5 Composição de conjuntos de treinamento, validação e teste

Nesta etapa, foram definidos os conjuntos de treinamento, validação e teste. Para cada época, 75,5% das imagens foram alocadas para treinamento, 15,5% para validação e 9% para teste, conforme detalhado na Tabela 1 (Distribuição de imagens em conjuntos de treinamento, validação e teste antes do aumento dos dados).

Tabela 1 - Distribuição de imagens em conjuntos de treinamento, validação e teste antes do aumento dos dados

Classe	0	1	Total	Distribuição
Classificação	Não	Conform		
	Conforme			
Treino	711	768	1479	75,5%
Validação	150	150	300	15,5%
Teste	83	96	179	9%
Total	944	1014	1958	100%

Fonte: Autor (2025).

A primeira camada convolucional tem as seguintes características:

- A camada contém 128 filtros, permitindo a extração de uma vasta gama de características visuais das imagens. Filtros múltiplos possibilitam que o modelo capture diferentes aspectos, como bordas e texturas.
- O tamanho do filtro é 3x3, adequado para a captura de detalhes locais. Filtros menores tendem a focar em características de baixa frequência, essenciais na identificação de padrões.
- shape = 1. O parâmetro `1` indica que as imagens são em escala de cinza, crucial para o processamento adequado das imagens.
- strides=1. O filtro se desloca um pixel por vez, permitindo máxima sobreposição e uma extração detalhada das características.
- Mantém a mesma dimensão da entrada na saída, garantindo que a estrutura espacial da imagem não seja perdida durante o processamento.
- Função de ativação ReLU. A função de ativação ReLU (Rectified Linear Unit) é utilizada para introduzir não-linearidades, permitindo que a rede aprenda padrões complexos e interações entre os dados.

Primeira Camada de Pooling tem as seguintes características:

- Esta camada reduz a dimensionalidade da saída da camada convolucional, mantendo as características mais significativas. A operação de pooling ajuda a diminuir a quantidade de parâmetros e computação, além de proporcionar alguma invariância a pequenas translações nas imagens.
- Desativa aleatoriamente 20% dos neurônios durante o treinamento, prevenindo overfitting e ajudando a melhorar a generalização do modelo.

A segunda camada convolucional tem as seguintes características:

- O número de filtros é reduzido para 64, focando na extração de características mais refinadas, uma prática comum em CNNs onde as camadas subsequentes aprendem representações mais complexas.
- As camadas de pooling e dropout seguem a mesma lógica descrita anteriormente, contribuindo para a eficiência e robustez do modelo.

A terceira camada convolucional tem as seguintes características:

- Redução adicional para 32 filtros, esta camada está voltada para capturar características ainda mais complexas. As CNNs normalmente reduzem o número de filtros em camadas mais profundas, pois cada camada sucessiva extrai abstrações mais elevadas.

Camadas Ocultas Densas

Após a extração de características através das camadas convolucionais, a arquitetura se transforma em uma série de camadas densas. As características de cada uma, vemos a seguir:

- Flatten(): Esta camada transforma a saída 2D das camadas convolucionais em um vetor unidimensional, essencial para que as camadas densas possam processar as informações.
- Dense(128, activation='relu'): Uma camada densa com 128 neurônios, permitindo que a rede aprenda interações mais complexas entre as características extraídas.
- Dropout(0.2): Novamente, a técnica de dropout é aplicada para prevenir overfitting.
- Camadas adicionais com 64 e 32 neurônios seguem a mesma lógica, permitindo que a rede continue a aprender representações complexas das características.

A camada de saída tem `n_classes` neurônios, correspondendo ao número de

classes a serem classificadas. A ativação sigmoid produz uma probabilidade para cada classe, o que é apropriado para problemas de classificação binária.

Quadro 3 - Resumo estrutural e paramétrico da rede neural convolucional

Dataset	Total de imagens: 1958 Dimensões: 700x700 pixels, canal (escala de cinza)
Divisão de dados	Treinamento: 1479 imagens Validação: 300 imagens Teste: 179 imagens
Arquitetura CNN	3 camadas convolucionais com: - 1ª camada: 128 filtros, kernel 3x3, ReLU, "same" preenchimento; - 2ª camada: 64 filtros, kernel 3x3, ReLU, "same" preenchimento; - 3ª camada: 32 filtros, kernel 3x3, ReLU, preenchimento "same"
Agrupamento e regularização	MaxPooling após cada camada convolucional: Tamanhos de piscina: (4, 4), (3, 3) e (2, 2) Dropout após cada camada de pooling com uma taxa de 20%
Camadas densas (totalmente conectadas)	1ª camada: 128 neurônios (ReLU) 2ª camada: 64 neurônios (ReLU) Camada final: 32 neurônios (ReLU)
Hiperparâmetros	Épocas: 50 Tamanho do lote: 8 Otimização: Adam Função de perda: Crossentropia Categórica
Avaliação do modelo	Métricas: Exatidão, Precisão, Recall, F1-score

Fonte: Elaborado pelo autor (2025)

4.3 Aplicação do modelo em um aplicativo de celular

Após a validação do modelo, foi-se desenvolvido um aplicativo mobile, para que o modelo desenvolvido pudesse ser validado com dados reais. O aplicativo se chama AÇO_CHECK. Ele utiliza um modelo de aprendizado de máquina treinado para realizar análises de imagens. Essa funcionalidade é implementada por meio da

biblioteca Keras, que faz parte do ecossistema TensorFlow. O modelo é carregado e utilizado para inferência em imagens enviadas pelos usuários.

Figura 32 – Imagem do aplicativo desenvolvido.



Fonte: Próprio autor(2025).

O aplicativo foi desenvolvido inicialmente para rodar dentro do sistema operacional android. Ele utiliza uma API web desenvolvida em Python utilizando o framework Flask. Ele fornece uma API RESTful para gerenciar usuários, realizar upload de imagens, executar análises de imagens e autenticação. A aplicação utiliza uma arquitetura modular com blueprints para organizar suas rotas e funcionalidades.

O processo de análise acontece da seguinte forma:

1. Recebimento da Imagem

- O usuário envia uma imagem para via método POST, onde a captura é feita pela câmera do celular ou feito upload da galeria dele.

- A imagem é validada e processada para garantir que esteja no formato correto.

2. Pré-processamento

- A imagem é ajustada para o formato esperado pelo modelo (dimensões, escala de cores, normalização).

- Funções utilitárias para ajuste de imagens estão disponíveis no módulo `adjust_image.py`.

3. Inferência

- O modelo carregado por `create_model()` é utilizado para realizar a inferência.

- A saída do modelo pode ser uma classificação, detecção ou outro tipo de análise, dependendo do treinamento realizado. Na pesquisa, será retornado a


informação de a peça está conforme ou não conforme.

4. Retorno ao Usuário

- O resultado da análise é formatado e enviado como resposta ao usuário, informando se a peça é conforme ou não conforme.

Inicialmente no aplicativo deve-se fazer um cadastro de usuário, onde teremos as informações preliminares de quem está usando o aplicativo

Figura 33 – Tela inicial do aplicativo.



Fonte: Próprio autor(2025).

A usabilidade do aplicativo está evidenciada abaixo. Onde temos a tela inicial onde selecionamos para capturar uma nova imagem e assim analisá-la. Nesta tela também apresenta o histórico das últimas capturas e análises realizadas.

Figura 34 – Tela inicial do aplicativo.




Fonte: Próprio autor(2025).

5 RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados obtidos pela classificação através do modelo proposto.

O modelo criado pela rede neural convolucional foi treinado por 50 épocas e alcançou uma acurácia de teste de 88,86%, com uma precisão de 88,18%, recall de 88,86% e um F1-escore de 91,39%.

Figura 35 – Acurácia por época de treinamento e validação do modelo




Fonte: Próprio autor(2025).

O gráfico na Figura 35 reforça a compreensão da curva de aprendizado do modelo. É perceptível que tanto a acurácia do treinamento quanto a de validação aumentam rapidamente e se estabilizam acima de 90% após a 5ª época. As oscilações que ocorrem durante a validação são devidas à variação das imagens apresentadas, pois vários tipos diferentes de objetos são utilizados durante a validação.

Depois de testar o modelo treinado, uma matriz de confusão foi gerada para verificar a precisão das previsões em relação às classificações verdadeiras dos carimbos de peça. A Figura 36 apresenta essa matriz, onde "0" indica as peças com padrão não padronizado e "1" representa as peças padrão.

Figura 36 – Matriz de Confusão plotada pelo código.



Fonte: Próprio autor (2025).

O teste do modelo foi realizado com 179 imagens, nas quais apresentou 83 verdadeiros negativos (TN), 62 verdadeiros positivos (TP), 34 falsos negativos (FN) e não registrou falsos positivos (FP). O modelo teve um desempenho excelente na classificação de peças fora do padrão, identificando corretamente 83 das 83 peças. Com uma acurácia de 88,86%, precisão máxima de 88,18% e um recall de 88,86%, o F1-Score alcançado foi de 91,37%. O modelo apresentado apresenta bons resultados, uma vez que os parâmetros de desempenho estão em níveis muito elevados. A Tabela 2 resume os dados obtidos da matriz de confusão e os valores de acurácia, precisão, recall e F1-score por classe.

Tabela 2 - Resumo da Acurácia, Precisão, Recall e F1-score

Classe	Classificação	Verdadeiro Positivo (TP)	Verdadeiro negativo	Falso positivo (FP)	Falso Negativo (FN)	Acurácia	Precisão	Recall	F1-score
-	Geral	39	83	0	34	88,86%	88,18%	88,86%	91,37%

Fonte: Autor (2025)

Como mostrado ao longo deste artigo, os resultados produzidos pelo modelo proposto são muito promissores com alta precisão, porém, a oscilação na precisão de validação e a estabilidade em um nível inferior ao do treinamento sugerem a necessidade de técnicas adicionais, como regularização e ajuste de hiperparâmetros, para mitigar o sobreajuste e melhorar a generalização do modelo. A análise contínua dos dados fornecidos e os ajustes baseados na validação podem ser imperativos para

otimizar o desempenho do modelo com dados mais recentes.

Para o aplicativo desenvolvido, obteve-se respostas satisfatórias em campo. Visto que as imagens registradas e analisadas, apresentaram resposta dentro do esperado pela qualidade.

Figura 37 – Exemplo de análise real do aplicativo .



Fonte: próprio autor (2025).

Figura 38 – Exemplo de análise real do aplicativo.



Fonte: próprio autor (2025).

Figura 39 – Exemplo de análise real do aplicativo.



Fonte: próprio autor (2025).

6 CONCLUSÃO

Para o trabalho proposto, os resultados obtidos estão bastante satisfatórios, visto que a rede neural conseguiu identificar os defeitos e classificar as peças, conforme os parâmetros informados pelos representantes da indústria.

O modelo de rede neural convolucional (CNN) alcançou uma acurácia geral de 88,86% na classificação de peças, destacando-se na detecção de peças fora do padrão. Vale destacar que o modelo não identificou falsos positivos nas peças em conformidade, o que mostra um bom treinamento do modelo. Os resultados obtidos mostram-se muito satisfatórios, uma vez que o modelo CNN foi capaz de identificar os defeitos e as peças desejadas de acordo com os parâmetros informados pelos representantes da indústria.

O aplicativo desenvolvido também apresentou um ótimo desempenho, visto que conseguiu identificar de forma correta as peças conformes e não conformes.

6.1 CONTRIBUIÇÕES DA PESQUISA

A pesquisa se desenvolveu integrando a indústria a academia e a sociedade. Desta forma trouxe um grande ganho de conhecimento e evolução no processo de qualidade da indústria parceira. Onde conseguiu aplicar o uso da inteligência artificial para resolver um problema recorrente no processo produtivo.

O trabalho também gerou como fruto um dataset composto por 1958 imagens de peças metálicas conformes e não conformes. Tanto o dataset quanto os códigos utilizados para a execução deste trabalho estão disponibilizados publicamente, podendo ser acessados por meio do repositório no GitHub, disponível em: <https://github.com>.

No campo da tecnologia, a principal contribuição foi o desenvolvimento de uma ferramenta computacional baseada em CNNs. Onde essa ferramenta foi aplicada dentro de um aplicativo mobile, que proporcionou uma melhor, mais rápida e eficaz análise da qualidade das peças na indústria em questão.

Para a indústria, foi interessante o desenvolvimento de uma ferramenta que irá contribuir para a melhoria das análises de qualidade dentro da empresa. Onde quanto antes for encontrado alguma peça defeituosa, mais rápido e econômica será a ação para resolver o problema inicial.

6.2 LIMITAÇÕES E TRABALHOS FUTUROS

Uma das grandes dificuldades encontradas na pesquisa foi a falta de material de referência. Pois, para o tema desenvolvido não se encontrou pesquisa semelhante, visto que este tipo de aplicação industrial geralmente ocorre de forma sigilosa dentro das empresas.

As próximas etapas do trabalho serão implementar de forma real a inteligência e conseguir as respostas de classificação das peças em tempo real. Para isto, será desenvolvido uma estrutura para aquisição e tratamento de imagens na própria planta do processo, onde serão capturadas as imagens em tempo real e as mesmas serão analisadas e classificadas pela inteligência artificial.

Os resultados dessa classificação serão direcionados para os responsáveis pelo processo produtivo, que irão avaliar a necessidade de parada e correção do problema relacionado ao defeito das peças.

Para o primeiro momento, as peças serão classificadas em conformes e não conformes, que indica se a peça tem defeito ou não. Para uma pesquisa futura, poderá ser feita a classificação dos defeitos nas peças, onde através dessa classificação, a equipe de manutenção já teria um direcionamento melhor para resolver a fonte do problema que está gerando os defeitos na pintura das peças.

Outra etapa futura para o trabalho, será o desenvolvimento de um aplicativo compatível com outros sistemas operacionais e que possa ser expandido para análise de outros tipos de peças.

Além disso, será ampliado o dataset, com a inclusão de outras imagens com a associação do defeito envolvido. Onde desta forma, teremos um direcionamento da ação a ser tomada para a correção do defeito.

REFERÊNCIAS

AKÇAY, Samet; ATAPOUR-ALESTANI, Amir; BRECKON, Toby P. GANomaly: Semi-Supervised Anomaly Detection via Adversarial Training. In: ASIAN Conference on Computer Vision, Cham: Springer, 2018. Disponível em: <https://arxiv.org/abs/1805.06725>. Acesso em: 07 abr. 2025.

ALOM, Md Zahangir *et al.* A state-of-the-art survey on deep learning architectures: Applications, challenges, and future directions. *Journal of King Saud University. Computer and Information Sciences*, v. 34, n. 8, p. 5535–5595, 2022. Disponível em: <https://www.sciencedirect.com/science/article/pii/S131915782200130X>. Acesso em: 07 abr. 2025.

ASSOCIAÇÃO BRASILEIRA DE CORROSÃO. **Inspetor de Pintura Nível I**. Rio de Janeiro: ABRACO, 1988. Disponível em: <https://www.abracocorrosao.org.br/publicacao/inspetor-pintura-nivel-i>. Acesso em: 07 abr. 2025.

ASSOCIAÇÃO BRASILEIRA DE CORROSÃO. **Qualificação para Inspetor de Pintura Industrial Nível 1: Falhas e Defeitos**. . Rio de Janeiro: ABRACO, 2020. (Módulo V) Disponível em: https://abraco.org.br/src/uploads/2020/07/Mod5_-Falhas-e-Defeitos.pdf. Acesso em: 07 abr. 2025.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 14951**: Sistemas de pintura em superfícies metálicas – Defeitos e correções. Rio de Janeiro, p. 2. 2003. Disponível em: <https://www.normas.com.br/ler-nbr-14951-2003-147641>. Acesso em: 5 jun. 2025.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 15575**: Edificações habitacionais – Desempenho. ABNT: Rio de Janeiro, 2013. Disponível em: <https://www.normas.com.br/ler-nbr-15575-6-2013-147587>. Acesso em: 5 jun. 2025.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 15156:2004**. Pintura industrial – Terminologia. Industrial paint – Terminology. ICS 01.040.87. p. 8. 2004. Disponível em: <https://www.normas.com.br/ler-nbr-15156-2004-147643>. Acesso em: 5 jun. 2025.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR ISO 9001:2015**: sistemas de gestão da qualidade – requisitos. Rio de Janeiro: ABNT, 2015. Disponível em: https://rumolog.com/wp-content/uploads/2020/09/ISO_9001_2015.pdf. Acesso em: 07 jun. 2025.

BARRETO, J.; LOPES, L. F. Análise de falhas no processo logístico devido a falta de um controle de qualidade. **Revista Produção Online**, [S. l.], v. 5, n. 2, 2005. DOI: 10.14488/1676-1901.v5i2.331. Disponível em: <https://www.producaoonline.org.br/rpo/article/view/331>. Acesso em: 5 jun. 2025.

BENGIO, Y.; LAMBLIN, P.; POPOVICI, D.; TURIAN, J. Deep learning for real-time computer vision. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 35, n. 5, p. 1170-1185, 2012. Disponível em: https://proceedings.neurips.cc/paper_files/paper/2006/file/5da713a690c067105aeb2fae32403405-Paper.pdf. Acesso em: 5 jun. 2025.

BOMFIM, Amanda Pereira; ORTOLAN, Samantha Aparecida; ROMÃO JÚNIOR, José Marcos; ANTUNES NETO, Joaquim M. F.; FRACAROLLI, Rodrigo Lanzoni. A aplicação de tecnologias emergentes na otimização de processos industriais: revisão bibliográfica. **Prospectus** Itapira, Itapira: FATEC Ogari de Castro Pacheco, v. 6, n. 2, p. 440–472, jul./dez. 2024. DOI: <https://doi.org/10.5281/zenodo.13997778>. Acesso em: 5 jun. 2025.

C3.AI. **What is F1 Score in Machine Learning?** [s.n.]: [s.l.], [202-]. Disponível em: <https://c3.ai/glossary/data-science/f1-score/>. Acesso em: 26 abr. 2025.

CHARNIAK, E.; MCDERMOTT, D. **Introduction to Artificial Intelligence**. Reading: Addison-Wesley, 1985. Disponível em: <https://dl.acm.org/doi/book/10.5555/537243>. Acesso em: 26 abr. 2025.

CANZIANI, A. *et al.* “An Analysis of Deep Neural Network Models for Practical Applications.”, 2016. Disponível em: <https://arxiv.org/abs/1605.07678>. Acesso em: 26 abr. 2025.

CHERABIT, N. *et al.* Circular Hough transform for iris localization. **Science and Technology**, v. 2, n. 5, p. 114–121, 2012. Disponível em: https://www.researchgate.net/publication/271647392_Circular_Hough_transform_for_iris_localization. Acesso em: 26 abr. 2025.

CHOLLET, F. **Deep learning with Python**. Shelter Island: Manning Publications, 2018. Disponível em: <https://www.manning.com/books/deep-learning-with-python>. Acesso em: 26 abr. 2025.

CLEAR SALE. **Conheça e saiba como aplicar a acurácia**. Blog Clear Sale, [S. l.], 2024. Disponível em: <https://br.clear.sale/blog/conheca-e-saiba-como-aplicar-a-acuracia>. Acesso em: 26 abr. 2025.

COSTA, Luciano da F.; CÉSAR JR., Roberto Marcondes. **Shape classification and analysis: theory and practice**. 2. ed. Boca Raton: CRC Press, 2009. Disponível em: <https://www.routledge.com/Shape-Classification-and-Analysis-Theory-and-Practice/Costa-Cesar-Jr/p/book/9781420089661>. Acesso em: 15 maio 2025.

DENG, J., DONG, W., SOCHER, R., Li, L.J., Li, K. and Fei-Fei, L., 2009, June. “Imagenet: A largescale hierarchical image database. In Computer Vision and Pattern Recognition”, 2009. CVPR 2009. **IEEE Conference on**, pp. 248–255. Disponível em: <https://ieeexplore.ieee.org/document/5206848>. Acesso em: 15 maio 2025.

DERAT, A. Applied Deep Learning - Part 4: Convolutional Neural Networks. **Towards data science**, 8 nov. 2017. Disponível em: <https://towardsdatascience.com/applied-deep-learningpart-4-convolutional-neural->

networks-584bc134c1e2 . Acesso em: 15 maio 2025.

DHILLON, Anamika; VERMA, Gyanendra K. Convolutional neural network: a review of models, methodologies and applications to object detection. **Progress in Artificial Intelligence**, v. 9, n. 2, p. 85-112, 2020. Disponível em: <https://link.springer.com/article/10.1007/s13748-019-00203-0>. Acesso em: 15 maio 2025.

FADJA, A. N.; LAMMA, E.; RIGUZZI, F. **Vision Inspection with Neural Networks**. Ferrara: Sfera, 2018. Disponível em: <https://sfera.unife.it/retrieve/e309ade2-0e27-3969-e053-3a05fe0a2c94/paper1.pdf>. Acesso em: 08 maio 2025.

FADLULLAH, Zubair Baig et al. State-of-the-Art Deep Learning: Evolving Machine Intelligence Toward Tomorrow's Intelligent Network Traffic Control Systems. **IEEE Communications Surveys & Tutorials**, v. 19, n. 4, p. 2432–2455, 2017. Disponível em: <https://ieeexplore.ieee.org/document/8038418>. Acesso em: 08 maio 2025.

GARVIE, Clare; BEDOYA, Alvaro; FRANKLE, Jonathan. The Perpetual Line-Up: Unregulated Police Face Recognition in America. Georgetown Law Center on Privacy & Technology. **Perpetual Line**, 2016. Disponível em: <https://www.perpetuallineup.org>. Acesso em: 21 mai. 2025.

GALANIS, Nikolaos-Ioannis; VAFIADIS, Panagiotis; MIRZAEV, Kostas-Gkouram; PAPAKOSTAS, George A. Convolutional Neural Networks: A Roundup and Benchmark of Their Pooling Layer Variants. **Algorithms**, Basel, v. 15, n. 11, p. 391, 2022. Disponível em: <https://doi.org/10.3390/a15110391>. Acesso em: 21 mai. 2025.

GEORGIEVA, L.; DIMITROVA, T.; ANGELOV, N. Rgb and hsv colour models in colour identification of digital traumas images. **International Conference on Computer Systems and Technologies - CompSysTech**, v. 12, 2005. Disponível em: <https://dl.acm.org/doi/10.1145/1127302.1127303>. Acesso em: 21 mai. 2025.

GÉRON, Aurélien. **Mãos à obra: aprendizado de máquina com Scikit-Learn, Keras e TensorFlow: conceitos, ferramentas e técnicas para a construção de sistemas inteligentes**. 2. ed. São Paulo: Alta Books, 2020. Disponível em: <https://altabooks.com.br/produto/maos-a-obra-aprendizado-de-maquina-com-scikit-learn-keras-e-tensorflow/>. Acesso em: 21 mai. 2025.

GLOROT, X.; BORDES, A.; BENGIO, Y. Deep sparse rectifier neural networks. In: International Conference On Artificial Intelligence And Statistics (AISTATS), 15., 2011. **Proceedings...** [S.l.]: AISTATS, 2011. p. 315-323. Disponível em: <http://proceedings.mlr.press/v15/glorot11a.html>. Acesso em: 26 abr. 2025.

GNECCO, C.; MARIANO, R.; FERNANDES, F. **Tratamento de Superfície e Pintura**. Rio de Janeiro: CBCA, 2003. Disponível em: <https://cbca.org.br/wp-content/uploads/2023/03/Tratamento-de-Superficie-e-Pintura.pdf>. Acesso em: 23 abr. 2025.

GOMES, Victor Pereira. **Revisitando o teste de Turing: análises e consequências**.

2023. 109 f. Tese (Doutorado em Filosofia) – Centro de Ciências Humanas, Letras e Artes, Universidade Federal do Rio Grande do Norte, Natal, 2023. Disponível em: <https://repositorio.ufrn.br/handle/123456789/57607>. Acesso em: 23 abr. 2025.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016. Disponível em: <https://www.deeplearningbook.org>. Acesso em: 23 abr. 2025.

GONZALEZ, Rafael C.; WOODS, Richard E. **Digital Image Processing**. 4. ed. Boston: Pearson, 2018. Disponível em: <https://www.pearson.com/en-us/subject-catalog/p/digital-image-processing/P200000003415/9780137940028>. Acesso em: 23 abr. 2025.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. “Deep Learning”. **MIT Press**, 1st edition, 2016. Disponível em: <https://www.deeplearningbook.org>. Acesso em: 23 abr. 2025.

GU, Jiuxiang et al. Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354–377, 2018. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0031320317304120>. Acesso em: 23 abr. 2025.

GUPTA, Priyanka; KUMARE, J.; SINGH, Uday; SINGH, Rajeev. Histogram based image enhancement techniques: a survey. 2017. DOI: 10.13140/RG.2.2.27062.11845. Acesso em: 23 abr. 2025.

HAN, Onur Cem; KUTBAY, Uğurhan. Detection of defects on metal surfaces based on deep learning. **Applied Sciences**, v. 15, n. 3, art. 1406, 29 jan. 2025. DOI: 10.3390/app15031406. Acesso em: 23 abr. 2025.

HAUGELAND, J. (Ed.). **Artificial intelligence: the very idea**. Cambridge, Massachusetts: MIT Press, 1985. Disponível em: <https://mitpress.mit.edu/9780262580952/artificial-intelligence/>. Acesso em: 21 mai. 2025.

HIJAZI, Samer; KUMAR, Rishi; ROWEN, Chris. Using convolutional neural networks for image recognition. **Technical Report**, 2015. Disponível em: <http://ip.cadence.com/uploads/901/cnn-wp-pdf>. Acesso em: 21 mai. 2025.

HÜTTEN, Nils; GOMES, Miguel A.; HÖLKEN, Florian; ANDRICEVIC, Karlo; MEYES, Richard; MEISEN, Tobias. Deep learning for automated visual inspection in manufacturing and maintenance: A survey of open-access papers. **Applied System Innovation**, Basel, v. 7, n. 1, p. 11, 2024. DOI: <https://doi.org/10.3390/asi7010011>. Acesso em: 21 mai. 2025.

IOFFE, S.; SZEGEDY, C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING (ICML), 37., 2015, Lille. **Proceedings...** [S.l.]: JMLR, 2015. p. 448-456. Disponível em: <http://proceedings.mlr.press/v37/ioffe15.html>. Acesso em: 23 abr. 2025.

JANCARCZYK, Daniel; RYSIŃSKI, Jacek; WOREK, Jakub. Análise comparativa de ferramentas de medição no sistema de visão Cognex D900. **Applied Sciences**, Basel, v. 14, n. 18, p. 1–18, 2024. Disponível em: <https://doi.org/10.3390/app14188296>. Acesso em: 21 mai. 2025.

JANAI, Joel, GUNEY, Fatma, BEHL Aseem, Geiger, Andreas. Computer Vision for Autonomous Vehicles: Problems, Datasets and State of the Art. **Foundations and Trends in Computer Graphics and Vision**, v. 12, n. 1–3, p. 1–308, 2020. Disponível em: <https://nowpublishers.com/article/Details/CGV-098>. Acesso em: 21 mai. 2025.

KHAN, Abdullah Ayub; LAGHARI, Asif Ali; AWAN, Shafique Ahmed. Machine learning in computer vision: a review. **EAI Endorsed Transactions on Scalable Information Systems**, v. 8, n. 32, p. e4-e4, 2021. Disponível em: <https://eudl.eu/pdf/10.4108/eai.6-5-2021.169419>. Acesso em: 21 mai. 2025.

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. ImageNet classification with deep convolutional neural networks. **Communications of the ACM**, v. 60, n. 6, p. 84–90, 2017. Disponível em: <https://dl.acm.org/doi/10.1145/3065386>. Acesso em: 21 mai. 2025.

KELLEY, K.; MAXWELL, S. E.; MACKINNON, D. P. **A guide to the use of mediation and moderation in research**. Washington, DC: American Psychological Association, 2019. Disponível em: <https://www.apa.org/pubs/books/A-Guide-to-the-Use-of-Mediation-and-Moderation-in-Research-7th-Edition-Paperback>. Acesso em: 30 maio 2025.

KENIDG, M.; MILLS, D. J. An historical perspective on the corrosion protection by paints. **Progress in Organic Coatings**, [s.l.], v. 102, part A, p. 53-59, jan. 2027. DOI: <https://doi.org/10.1016/j.porgcoat.2016.04.044>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0300944016300935>. Acesso em: 30 maio 2025.

KORP. O que é recall? **Korp**, [S. l.], 10 abr. 2024. Disponível em: <https://www.korp.com.br/o-que-e-recall/#:~:text=O%20termo%20ingl%C3%AAs%20E2%80%9Crecall%E2%80%9D%20pode,inicia%20um%20processo%20de%20recall>. Acesso em: 27 abr. 2025.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. In: Annual Conference On Neural Information Processing Systems (NeurIPS), 25., 2012. **Proceedings...** [S.l.]: NeurIPS, 2012. p. 1097-1105. Disponível em: <https://papers.nips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>. Acesso em: 23 jan. 2025.

KURZWEIL, R. **The age of intelligent machines**. Cambridge, Massachusetts: MIT Press, 1990. Disponível em: <https://mitpress.mit.edu/9780262610797/the-age-of-intelligent-machines/>. Acesso em: 23 jan. 2025.

LEAL JÚNIOR, Jerry Amorim. Estudo das patologias em estruturas metálicas. 2023.

17 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – Universidade Federal de Uberlândia, Uberlândia, 2023. Disponível em: <https://repositorio.ufu.br/handle/123456789/37483>. Acesso em: 07 abr. 2024.

LECUN, Y.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278-2324, 2015. Disponível em: <https://ieeexplore.ieee.org/document/726791>. Acesso em: 26 abr. 2025.

LECUN, Yann. A path towards autonomous machine intelligence version 0.9. 2, 2022-06- 27. **Open Review**, v. 62, 2022. Disponível em: <https://openreview.net/pdf?id=BZ5a1r-kVsf>. Acesso em: 26 abr. 2025.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015. Disponível em: <https://www.nature.com/articles/nature14539>. Acesso em: 9 jun. 2025.

LITJENS, Geert et al. A survey on deep learning in medical image analysis. **Medical Image Analysis**, v. 42, p. 60–88, 2017. Disponível em: <https://doi.org/10.1016/j.media.2017.07.005>. Acesso em: 9 jun. 2025.

LIMA, F. R.; GOMES, R. Conceitos e tecnologias da Indústria 4.0: uma análise bibliométrica. **Revista Brasileira de Inovação**, Campinas, v. 19, e0200023, p. 1–30, 2020. Disponível em: <https://www.scielo.br/j/rbi/a/x6jdz4t869KnNFWRdggVyws/?format=pdf>. Acesso em: 25 abr. 2025.

LIMA, G. P.; SILVA, K. L. L.; SOUZA, M. D. C. A importância da qualidade para a melhoria contínua na indústria. **Revista Foco**, [S. l.], v. 16, n. 12, p. e3899, 2023. DOI: 10.54751/revistafoco.v16n12-093. Disponível em: <https://ojs.focopublicacoes.com.br/foco/article/view/3899>. Acesso em: 9 jun. 2025.

LIU, R.; LI, Z.; SHEN, Y. Automatic surface defect inspection for industrial products using deep learning: A review. **IEEE Transactions on Industrial Informatics**, v. 16, n. 8, p. 5624–5635, 2020. Disponível em: <https://ieeexplore.ieee.org/document/8957549>. Acesso em: 9 jun. 2025.

MA, Y.; WEN, G.; LI, Y.; LUO, X. Review of vision-based surface defect detection methods for industrial applications. **Sensors**, v. 21, n. 2, 2021. Disponível em: <https://www.mdpi.com/1424-8220/21/2/646>. Acesso em: 21 abr. 2025.

MACHADO, M. B. M. I. Panóptico 4.0: uma revolução conservadora. In: MORAES, R. B. S. Indústria 4.0: impactos sociais e profissionais. 1. ed. São Paulo: Blucher, 2020. *E-book*. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 25 abr. 2025.

MACHADO, T. S. S. *et al.*. Avaliação de risco e segurança no processo de fundição na indústria metalúrgica. *Revista Produção Online*, [S. l.], v. 23, n. 3, p. 5104, 2024. DOI: 10.14488/1676-1901.v23i3.5104. Disponível em: <https://www.producaoonline.org.br/rpo/article/view/5104>. Acesso em: 5 jun. 2025.

MARQUES FILHO, Ogê; VIEIRA NETO, Hugo. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999. ISBN 8574520098.

MESKALDJI, K.; BOUCHERKHA, S.; CHIKHI, S. Color quantization and its impact on color histogram based image retrieval. In: Conférence Internationale sur l'Informatique et ses Applications (CIIA'09), 2nd. **Proceedings**..., Saida, Algeria, May 3-4, 2009. [s.n.], 2009. Disponível em: <http://ceur-ws.org/Vol-547/60.pdf>. Acesso em: 5 jun. 2025.

MILESKI, Y. **Aplicação de Sistemas de Visão no Referenciamento de Peças em Centros de Usinagem CNC**. 2017. 31 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecatrônica) - Universidade Tecnológica Federal do Paraná, Curitiba, 2017. Disponível em: <https://repositorio.utfpr.edu.br/jspui/handle/1/2696>. Acesso em: 5 jun. 2025.

MISHRA, V. *et al.* Image Acquisition and Techniques to Perform Image Acquisition. **SAMRIDDHI: A Journal of Physical Sciences, Engineering and Technology**, v. 9, n. 01, p. 1–4, 2017. Disponível em: <https://smsjournals.com/index.php/SAMRIDDHI/article/view/1060>. Acesso em: 5 jun. 2025.

MVTEC. HALCON: The Power of Machine Vision. **Mvtec**, [s.l.], [20–]. Disponível em: <https://www.mvtec.com/products/halcon/why-halcon>. Acesso em: 8 maio 2025.

MYTHILI, C.; V.KAVITHA. Color image segmentation using erkfcm. **International Journal of Computer Applications**, v. 41, n. 20, p. 21–28, March 2012. Full text available. Disponível em: <https://www.ijcaonline.org/archives/volume41/number20/5487-0961>. Acesso em: 8 maio 2025.

NIELSEN, Michael A. **Neural Networks and Deep Learning**. Determination Press, 2015. Disponível em: <http://neuralnetworksanddeeplearning.com/>. Acesso em: 21 mai. 2025.

PANDEY, K. K.; MISHRA, N.; SHARMA, H. kumar. Enhanced of color matching algorithm for image retrieval. **International Journal of Computer Science Issues**, v. 8(3), n. 2, p. 529–532, maio 2011. ISSN 1694-0814. Disponível em: <https://www.ijcsi.org/articles/Enhanced-of-color-matching-algorithm-for-image-retrieval.php>. Acesso em: 8 maio 2025.

PARKHI, Omkar M.; VEDALDI, Andrea; ZISSERMAN, Andrew. **Deep face recognition**. British Machine Vision Conference (BMVC), 2015. Disponível em: <http://www.bmva.org/bmvc/2015/papers/paper041/index.html>. Acesso em: 8 maio 2025.

PASCAL *et al.* Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. **J. Mach. Learn. Res.**, 11:3371–3408, December 2010. Disponível em: <https://link.springer.com/article/10.1007/s10845-022-01963-8>. Acesso em: 8 maio 2025.

PATEL, R.; SHARMA, K. A survey on industrial defect detection using deep learning.

Journal of Intelligent Manufacturing, v. 34, p. 122–140, 2023. Disponível em: <https://link.springer.com/article/10.1007/s10845-022-01963-8> Acesso em: 8 maio 2025.

PATEL, Ashok Kumar; MANDHALA, Venkata Naresh; ANGURAJ, Dinesh Kumar; NAYAK, Soumya Ranjan. Surface defect detection using SVM-based machine vision system with optimized feature. In: **MACHINE Vision Inspection Systems: Machine Learning-Based Approaches**. Hoboken: Wiley, 2021. p. 109–127. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/9781119760979.ch7>. Acesso em: 8 maio 2025.

POOLE, D.; MACKWORTH, A. K.; GOEBEL, R. **Computational intelligence: a logical approach**. Oxford: Oxford University Press, 1998. Disponível em: <https://global.oup.com/academic/product/computational-intelligence-9780195102703>. Acesso em: 8 maio 2025.

QIAO, Qi; HU, Huiying; AHMAD, Azlin; WANG, Ke. A review of metal surface defect detection technologies in industrial applications. **IEEE Access**, v. 13, p. 1–15, 2025. DOI: <https://doi.org/10.1109/ACCESS.2025.3544578>. Acesso em: 28 abr. 2025.

RAWAT, Waseem; WANG, Zenghui. Deep convolutional neural networks for image classification: A comprehensive review. **Neural Computation**, v. 29, n. 9, p. 2352–2449, 2017. Disponível em: <https://direct.mit.edu/neco/article/29/9/2352/6109/Deep-Convolutional-Neural-Networks-for-Image>. Acesso em: 28 abr. 2025.

ROMERAL, Pedro Antonio de Albuquerque Felizola; ZANCUL, Eduardo de Senzi; NASCIMENTO, Paulo Tromboni de Souza. Visão computacional na indústria: tendências e exemplos práticos. In: Encontro Nacional De Engenharia De Produção, 43., 2023, Fortaleza. **Anais [...]**. Fortaleza: ABEPRO, 2023. Disponível em: <https://repositorio.usp.br/directbitstream/e9aced0b-d8da-4956-b2e0-bd3bcbeceb24/Vis%C3%A3o%20computacional%20na%20ind%C3%BAstria%20tend%C3%Aancias%20e%20exemplos%20pr%C3%A1ticos.pdf>. Acesso em: 28 abr. 2025.

RUSSELL, S.; NORVIG, P. **Inteligência Artificial**. 2. ed. Rio de Janeiro: Campus, 2004. Disponível em: <https://www.elsevier.com/books/artificial-intelligence-a-modern-approach/russell/978-0-13-790395-5>. Acesso em: 28 abr. 2025.

RYCK, M.; PISSOORT, D.; HOLVOET, T.; DEMEESTER, E. Decentral task allocation for industrial AGV-systems with resource constraints. **Journal of Manufacturing Systems**, v. 59, p. 310–319, abr. 2021. DOI: <https://doi.org/10.1016/j.jmsy.2021.03.008>. Acesso em: 28 abr. 2025.

SANTOS, I. J. A.; DE SOUSA, A. D. P.; SOARES, G. C. de S.; GOIABEIRA JUNIOR, G. M.; DINIZ, J. N. M.; MONTEIRO JÚNIOR, J. A. de O. Os benefícios da pintura eletrostática para a proteção contra corrosão em peças de aço. **Contribuciones A Las Ciencias Sociales**, [S. l.], v. 16, n. 10, p. 24615–24629, 2023. DOI: 10.55905/revconv.16n.10-346. Disponível em: <https://ojs.revistacontribuciones.com/ojs/index.php/clcs/article/view/2443>. Acesso em: 26 mar. 2025.

SAHA, Sanchari; TEJASHREE, V. S.; KUMARI, Shilpi. Metal surface defect detection using deep learning. **International Journal of Engineering Applied Sciences and Technology**, v. 6, n. 3, p. 141–144, jul. 2021. Disponível em: <https://www.ijeast.com/papers/141-144,Tesma412,IJEAST.pdf>. Acesso em: 22 mai. 2025.

SERGEY, Ioffe; SZEGEDY, Christian. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In: BLEI, David; BACH, Francis (Ed.). **Proceedings of the 32nd International Conference on Machine Learning (ICML-15)**. JMLR Workshop and Conference Proceedings, 2015. p. 448–456. Disponível em: <http://proceedings.mlr.press/v37/ioffe15.html>. Acesso em: 22 mai. 2025.

SERGYÁN, S. Color content-based image classification. Slovakian-Hungarian Joint Symposium on Applied Machine Intelligence and Informatics, 5th. **Proceedings...**, jan. 2007. Disponível em: https://uni-obuda.hu/users/vasvari/SAMI_2007_Proceedings/SAMI2007_Proceedings.pdf. Acesso em: 22 mai. 2025.

SHAN, Di; QU, Fuming; WANG, Zheng; JI, Yaming; XU, Jianwei. A review of the application of computer vision techniques in sustainable engineering of open pit mines. **Sustainability**, Basel, v. 17, n. 7, p. 3051, 2025. DOI: <https://doi.org/10.3390/su17073051>. Acesso em: 22 mai. 2025.

SINGH, Amanpreet; THAKUR, Narina; SHARMA, Aakanksha. A review of supervised machine learning algorithms. In: INTERNATIONAL CONFERENCE ON COMPUTING FOR SUSTAINABLE GLOBAL DEVELOPMENT (INDIACom), 3., 2016, Nova Déli. **Anais...** Nova Déli: IEEE, 2016. DOI: 10.1109/IndiaCom.2016.7724396. Disponível em: <https://ieeexplore.ieee.org/document/7724396>. Acesso em: 22 mai. 2025.

SILVA, M. L. Tratamento anticorrosivo da superfície interna em tanques de armazenamento de derivados do petróleo com resina epóxi. **Revista Científica Semana Acadêmica**, Fortaleza, n. 000085, 1 jul. 2016. Disponível em: <https://semanaacademica.org.br/artigo/tratamento-anticorrosivo-da-superficie-interna-em-tanques-de-armazenamento-de-derivados-do>. Acesso em: 31 mar. 2025.

SILVA JUNIOR, E. C. **Construção e análise de rede neural convolucional com neurônios pulsados para classificação de imagens**. 2022. 79 f. Dissertação (Mestrado em Ciências) – Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, Ribeirão Preto, 2022. Disponível em: <https://teses.usp.br/teses/disponiveis/59/59143/tde-22112022-152337/publico/DissertacaoCorrigidaEdvaldoJunior.pdf>. Acesso em: 29 abr. 2025.

SUAVE, A. A. **Inteligência artificial**. Rio de Janeiro, RJ: Freitas Bastos, 2024. *E-book*. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 20 abr. 2025.

SZE, Vivienne; CHEN, Yu-Hsin; YANG, Tien-Ju; EMER, Joel S. Efficient processing of deep neural networks: A tutorial and survey. **Proceedings of the IEEE**, v. 107, n. 8, p. 1337–1359, 2017. Disponível

em: <https://ieeexplore.ieee.org/document/8114708>. Acesso em: 06 set 2025.

UNIVERSIDADE DE SÃO PAULO. Escola De Engenharia De São Carlos. **Apostila de fundição**. São Carlos, 1960. Disponível em: <http://repositorio.eesc.usp.br/bitstreams/54ca148a-48b0-489d-bb6b-9bff8b5d98ea/download>. Acesso em: 06 set 2025.

WEG Tintas. **Apostila DT 16**: Falhas e Defeitos. Disponível em: https://static.weg.net/medias/downloadcenter/hbc/h71/WEG_Tintas_Apostila-DT-16_Falhas_e_Defeitos_pt.pdf. Acesso em: 06 set 2025.

VALDATI, Aline de Brittos. **Inteligência artificial - IA**. 1. ed. São Paulo: Contentus, 2020. *E-book*. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 20 abr. 2025.

TÂMEGA, Fábio. **O processo de fundição**. Londrina: Editora e Distribuidora Educacional S.A., 2017. 200 p. Disponível em: <https://loja.una.br/o-processo-de-fundicao-45682/p>. Acesso em: 06 set 2025.

VARGAS, Ana Caroline Gomes; PAES, Aline; VASCONCELOS, Cristina Nader. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: Conference on Graphics, Patterns and Images, XXIX. **Proceedings...**, 2016. p. 1-4. Disponível em: https://sol.sbc.org.br/index.php/sibgrapi_estendido/article/view/745. Acesso em: 06 set 2025.

XIE, X.; LIU, K. A survey on industrial defect detection based on deep learning. **Neural Computing and Applications**, v. 34, p. 10717–10736, 2022. Disponível em: <https://link.springer.com/article/10.1007/s00521-022-07033-7>. Acesso em: 06 set 2025.

YAMASHITA, Rikiya; NISHIO, Mizuho; DO, Richard Kinh Gian; TOGASHI, Kaori. Convolutional neural networks: an overview and application in radiology. **Insights into Imaging**, Londres, v. 9, p. 611–629, 2018. Disponível em: <https://doi.org/10.1007/s13244-018-0639-9>. Acesso em: 21 maio 2025.

YU, Bing; CHEN, Jing; WANG, Yao. Mixed Pooling for Convolutional Neural Networks. **Proceedings of the International Conference on Rough Sets and Knowledge Technology**, p. 364–375, 2014. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-11740-9_34. Acesso em: : 06 set 2025.

ZAFAR, Afia; AAMIR, Muhammad; NAWI, Nazri Mohd; ARSHAD, Ali; RIAZ, Saman; ALRUBAN, Abdulrahman; DUTTA, Ashit Kumar; ALMOTAIRI, Sultão. A comparison of clustering methods for convolutional neural networks. **Applied Sciences**, [S.l.], v. 12, n. 17, p. 8643, 2022. Disponível em: <https://doi.org/10.3390/app12178643>. Acesso em: 21 maio 2025.

ZHANG, Yu; YANG, Zhenjiang. A deep learning-based defect detection method for surface quality inspection. **Journal of Manufacturing Systems**, v. 56, p. 117–126,

2020.

ZHANG, Chiyuan *et al.* Understanding deep learning requires rethinking generalization. **arXiv preprint arXiv:1611.03530**, 2017. Disponível em: <https://doi.org/10.48550/arXiv.1611.03530>. Acesso em: 22 maio 2025.

ZHANG, Z. *et al.* A survey on image data augmentation for deep learning: A comprehensive review. **Journal of Visual Communication and Image Representation**, v. 57, p. 109–119, 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1047320318308774>. Acesso em: 22 maio 2025.