



**INSTITUTO FEDERAL**  
Piauí



**PPGEM**  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE MATERIAIS

**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 E  
PROCESSOS INDUSTRIAIS  
DISSERTAÇÃO DE MESTRADO**

**REJANNE ALVES DE MELO**

**METALSYNC: ferramenta de análise da conformidade de padrão de estampa  
em chapas metálicas por meio de redes neurais convolucionais**

**TERESINA**

**2025**

**REJANNE ALVES DE MELO**

**METALSYNC: ferramenta de análise da conformidade de padrão de estampa  
em chapas metálicas por meio de redes neurais convolucionais**

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 e Processos Industriais.  
Área de concentração: Computação Aplicada

Orientador: Prof. Dr. Otílio Paulo da Silva Neto

**TERESINA**

**2025**

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

---

Melo, Rejanne Alves de

M528m      Metalsync : ferramenta de análise da conformidade de padrão estampa em chapas metálicas por meio de redes neurais convolucionais / Rejanne Alves de Melo. - 2025.  
107 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. Indústria metalúrgica . 2. Inspeção automatizada. 3. Não conformidades .  
4. Redes neurais convolucionais. I.Título.

CDD - 620.1

---

**Elaborado por Tanize Maria Sales CRB 3/1024**

REJANNE ALVES DE MELO

METALSYNC: ferramenta de análise da conformidade de padrão de estampa em chapas metálicas por meio de redes neurais convolucionais

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 e Processos Industriais.

Aprovada em: 21 / 08 / 2025.

BANCA EXAMINADORA

---

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

---

Prof. Dr. Haroldo Reis Alves de Macedo  
Instituto Federal do Piauí (IFPI)

---

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

---

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

Dedico este trabalho ao meu querido pai, José Pedro, que partiu recentemente, deixando em meu coração um vazio imenso e, ao mesmo tempo, a certeza de sua eterna presença em minha vida. Sua força, amor e apoio foram fundamentais para que eu chegasse até aqui.

## AGRADECIMENTOS

Agradeço primeiramente a Deus, por me proporcionar saúde, força e sabedoria ao longo de toda esta caminhada, e por me guiar em cada desafio enfrentado.

Ao Instituto Federal do Piauí (IFPI), que me possibilitou participar deste mestrado, sendo uma instituição pública de ensino essencial na construção de conhecimento.

Ao meu orientador, Profº. Dr. Otilio Paulo da Silva Neto, pela paciência, dedicação, orientação precisa e pela confiança em meu trabalho. Sua expertise foi fundamental para a realização deste estudo e sou imensamente grata(a) por sua orientação ao longo dessa jornada.

Aos professores e colaboradores do Programa de Pós-Graduação em Engenharia de Materiais (PPGEM) do IFPI, que, com seu conhecimento e dedicação, desenvolvem significativamente para a minha formação acadêmica e profissional.

À todos que compõem o GRUNALABS por dividir seu espaço e por todos os encontros e discussões que tanto contribuíram para este trabalho.

À minha família, que foi meu alicerce durante toda essa trajetória, em especial aos meus pais, José Pereira de Melo (*In memoriam*), Francisca Rodrigues de Melo e Maria da Conceição Rodrigues de Melo, que são minhas maiores inspirações, por me estimularem incansavelmente e me proporcionarem educação e conhecimento pela via dos estudos. Sinônimos de fé, esperança, resistência e luta, nunca mediram esforços para me apoiar na caminhada da vida. Sem o apoio de vocês, esta conquista não seria possível.

Aos meus amigos, que, com sua amizade e incentivo, me motivaram a seguir em frente e nunca desistir, mesmo nos momentos de dificuldades.

A todos que, de alguma forma, contribuíram para a realização deste trabalho, o meu sincero agradecimento.

“Por vezes sentimos que aquilo que fazemos não é senão uma gota de água no mar. Mas o mar seria menor se lhe faltasse uma gota”.

Madre Teresa de Calcutá

## RESUMO

A crescente demanda por qualidade e eficiência na indústria metalúrgica impulsiona a adoção de tecnologias inteligentes para inspeção automatizada. Neste contexto, este trabalho apresenta uma solução baseada em visão computacional para a detecção de não conformidades em chapas metálicas estampadas, utilizando redes neurais convolucionais (CNNs). A pesquisa foi realizada com imagens reais de peças metálicas obtidas na empresa Só Aço Industrial Ltda., envolvendo etapas de pré-processamento, organização dos dados em conjuntos de treino, validação e teste, além da aplicação de técnicas de aumento de dados para ampliar a robustez do modelo. O classificador CNN foi otimizado para identificar padrões visuais de conformidade nas estampas e avaliado por métricas como acurácia, precisão, *recall* e F1-score. Os resultados demonstraram desempenho expressivo, alcançando acurácia global de 95,24%, precisão de 98,33%, *recall* de 90,31% e F1-score de 94,14%. Em especial, para peças fora do padrão, o modelo obteve *recall* de 100%, evidenciando sua eficácia na detecção de falhas com elevada confiabilidade. A proposta mostrou viabilidade técnica para aplicações industriais em tempo real, ao reduzir a subjetividade da inspeção manual e permitir integração com fluxos operacionais por meio de um aplicativo móvel com interface intuitiva. Este estudo representa um avanço na inspeção automatizada de peças estampadas, contribuindo para a modernização da indústria com foco em qualidade, rastreabilidade e produtividade.

**Palavras-chave:** Indústria metalúrgica; Inspeção automatizada; Não conformidades; Redes neurais convolucionais; Aplicativo móvel.

## ABSTRACT

The growing demand for quality and efficiency in the metallurgical industry has been driving the adoption of intelligent technologies for automated inspection. In this context, this study presents a computer vision–based solution for detecting nonconformities in stamped metal sheets using convolutional neural networks (CNNs). The research was conducted with real images of metallic parts obtained from the company Só Aço Industrial Ltda., comprising preprocessing steps, organization of data into training, validation, and testing sets, as well as the application of data augmentation techniques to enhance the robustness of the model. The CNN classifier was optimized to identify visual conformity patterns in stamped surfaces and evaluated using metrics such as accuracy, precision, *recall*, and F1-score. The results demonstrated remarkable performance, achieving an overall accuracy of 95.24%, precision of 98.33%, *recall* of 90.31%, and F1-score of 94.14%. Notably, for nonconforming parts, the model achieved 100% *recall*, highlighting its effectiveness in reliably detecting defects. The proposed approach proved technically feasible for real-time industrial applications by reducing the subjectivity of manual inspection and enabling integration into operational workflows through a mobile application with an intuitive interface. This study represents an advancement in the automated inspection of stamped parts, contributing to the modernization of the industry with an emphasis on quality, traceability, and productivity.

**Keywords:** Metallurgical industry; Automated inspection; Nonconformities; Convolutional neural networks; Mobile application.

## LISTA DE FIGURAS

|                                                                                                                                        |    |
|----------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1 – Estoque de bobinas de aço laminado.....                                                                                     | 17 |
| Figura 2 – Porta automotiva após o processo de estampagem metálica.....                                                                | 18 |
| Figura 3 – Exemplo de Ruptura em Chapa Metálica após Estampagem.....                                                                   | 19 |
| Figura 4 – Defeito de Engripamento em Superfície Metálica.....                                                                         | 20 |
| Figura 5 – Deformação Superficial em Peça Estampada.....                                                                               | 21 |
| Figura 6 – Exemplo de inspeção manual.....                                                                                             | 25 |
| Figura 7 – Exemplo sistema de inspeção automatizada.....                                                                               | 26 |
| Figura 8 – Etapas de um sistema de visão computacional típico.....                                                                     | 29 |
| Figura 9 – Exemplo de imagem (a) antes do pré-processamento e (b) após a aplicação de um filtro de mediana como pré-processamento..... | 33 |
| Figura 10 – Exemplo segmentação de um tecido muscular.....                                                                             | 35 |
| Figura 11 – Arquitetura CNN VGG-16.....                                                                                                | 42 |
| Figura 12 – Exemplo de uma aplicação de <i>pooling</i> dos tipos (a) <i>Max pooling</i> e (b) <i>Average pooling</i> .....             | 43 |
| Figura 13 – Curvas típicas das funções de ativação <i>Sigmoid</i> e Tangente hiperbólica ( <i>tanh</i> ).....                          | 44 |
| Figura 14 – Representação gráfica da função de ativação <i>ReLU</i> .....                                                              | 45 |
| Figura 15 – Representação gráfica da função de ativação <i>Leaky ReLU</i> .....                                                        | 46 |
| Figura 16 – Curva característica da função <i>Softmax</i> .....                                                                        | 46 |
| Figura 17 – Algoritmo de gradiente descendente.....                                                                                    | 47 |
| Figura 18 – Algoritmos de gradiente descendente com passos de aprendizado (a) excessivamente pequenos ou (b) grandes.....              | 48 |
| Figura 19 – Dois principais desafios do gradiente descendente.....                                                                     | 49 |
| Figura 20 – Distinção entre uma (a) camada totalmente conectada e uma (b) camada com <i>dropout</i> .....                              | 51 |
| Figura 21 – Três modelos de roupeiros: (a) Coluna única, (b) Duas colunas e (c) Quatro colunas.....                                    | 68 |
| Figura 22 – Peça estampada recém fabricada.....                                                                                        | 69 |
| Figura 23 – Lote de peças recém fabricadas.....                                                                                        | 69 |
| Figura 24 – Prensa modelo CMSLP1000, Camasi.....                                                                                       | 70 |
| Figura 25 – Dimensões e detalhes da peça.....                                                                                          | 71 |

|                                                                                                                                                      |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 26 – Amostras de peças fora e dentro padrão de conformidade.....                                                                              | 72 |
| Figura 27 – Exemplo de imagem de peça: (a) original e (b) após o<br>pré-processamento.....                                                           | 74 |
| Figura 28 – Tela inicial do aplicativo MetalSync.....                                                                                                | 82 |
| Figura 29 – Perdas por época do treino e validação do modelo.....                                                                                    | 83 |
| Figura 30 – Acurácia por época do treino e validação do modelo.....                                                                                  | 84 |
| Figura 31 – Matriz de confusão do teste do modelo.....                                                                                               | 85 |
| Figura 32 – Tela inicial do aplicativo MetalSync com opções para captura ou<br>importação de imagem da peça metálica.....                            | 87 |
| Figura 33 – Interface de confirmação da imagem selecionada.....                                                                                      | 88 |
| Figura 34 – Etapas finais do processo: (a) inserção do identificador da amostra e<br>(b) exibição do resultado da classificação de conformidade..... | 89 |

## LISTA DE QUADROS E TABELAS

|                                                                                          |    |
|------------------------------------------------------------------------------------------|----|
| Quadro 1– Resumo Estrutural e Paramétrico da Rede Neural Convolucional.....              | 77 |
| Quadro 2– Síntese do comparativo entre trabalhos relacionados.....                       | 91 |
| Tabela 1 – Distribuição das imagens nas listas de treino, validação e teste.....         | 75 |
| Tabela 2 – Resumo da acurácia, precisão, <i>recall</i> e <i>F1-score</i> por classe..... | 86 |

## LISTA DE ABREVIATURAS E SIGLAS

|        |                                                                  |
|--------|------------------------------------------------------------------|
| ABNT   | Associação Brasileira de Normas Técnicas                         |
| ASTM   | <i>American Society for Testing and Materials</i>                |
| BN     | <i>Batch Normalization</i>                                       |
| CNN    | <i>Convolutional Neural Networks</i> (Rede Neural Convolucional) |
| FCN    | <i>Fully Convolutional Networks</i>                              |
| IA     | Inteligência Artificial                                          |
| ISO    | <i>International Organization for Standardization</i>            |
| JSON   | <i>JavaScript Object Notation</i>                                |
| KNN    | <i>K-Nearest Neighbors</i>                                       |
| MVC    | <i>Model-View-Controller</i>                                     |
| OpenCV | <i>Open Source Computer Vision Library</i>                       |
| PDI    | Processamento Digital de Imagens                                 |
| ReLU   | <i>Rectified Linear Unit</i>                                     |
| RGB    | <i>Red, Green, Blue</i>                                          |
| ROC    | <i>Receiver Operating Characteristic</i>                         |
| RNA    | Redes Neurais Artificiais                                        |
| SGD    | <i>Stochastic Gradient Descent</i>                               |
| SVM    | <i>Support Vector Machine</i>                                    |
| VGG    | <i>Visual Geometry Group</i>                                     |
| TPU    | <i>Tensor Processing Unit</i>                                    |
| WSGI   | <i>Web Server Gateway Interface</i>                              |
| YOLO   | <i>You Only Look Once</i>                                        |

## SUMÁRIO

|          |                                                                 |           |
|----------|-----------------------------------------------------------------|-----------|
| <b>1</b> | <b>INTRODUÇÃO.....</b>                                          | <b>13</b> |
| <b>2</b> | <b>REFERENCIAL TEÓRICO.....</b>                                 | <b>16</b> |
| 2.1      | LAMINADOS DE AÇO.....                                           | 16        |
| 2.2      | PROCESSO DE ESTAMPAGEM DE CHAPAS METÁLICAS.....                 | 17        |
| 2.3      | DETECÇÃO DE DEFEITOS NA FABRICAÇÃO DO AÇO.....                  | 23        |
| 2.4      | SISTEMAS DE INSPEÇÃO INDUSTRIAL.....                            | 24        |
| 2.5      | VISÃO COMPUTACIONAL.....                                        | 28        |
| 2.6      | AQUISIÇÃO DE IMAGENS.....                                       | 31        |
| 2.7      | PRÉ-PROCESSAMENTO.....                                          | 32        |
| 2.8      | PROCESSAMENTO E ANÁLISE DA IMAGEM.....                          | 33        |
| 2.9      | SEGMENTAÇÃO.....                                                | 34        |
| 2.10     | EXTRAÇÃO DE CARACTERÍSTICA.....                                 | 36        |
| 2.11     | CLASSIFICAÇÃO E RECONHECIMENTO.....                             | 36        |
| 2.12     | VISÃO COMPUTACIONAL PARA DETECÇÃO DE DEFEITOS EM METAIS.....    | 37        |
| 2.13     | REDES NEURAIS CONVOLUCIONAIS.....                               | 40        |
| 2.14     | MÉTRICAS DE AVALIAÇÃO DE CLASSIFICAÇÃO.....                     | 58        |
| 2.15     | REDES NEURAIS CONVOLUCIONAIS PARA CLASSIFICAÇÃO DE IMAGENS..... | 62        |
| <b>3</b> | <b>MATERIAIS E MÉTODOS.....</b>                                 | <b>67</b> |
| 3.1      | CARACTERIZAÇÃO DA PEÇA.....                                     | 68        |
| 3.2      | AQUISIÇÃO DO BANCO DE IMAGENS.....                              | 72        |
| 3.3      | PRÉ-PROCESSAMENTO DAS IMAGENS.....                              | 73        |
| 3.4      | COMPOSIÇÃO DAS LISTAS DE TREINO, VALIDAÇÃO E TESTE.....         | 74        |
| 3.5      | PARAMETRIZAÇÃO DO ALGORITMO.....                                | 75        |
| 3.6      | MÉTRICAS DE AVALIAÇÃO.....                                      | 77        |
| 3.7      | APLICATIVO DE CLASSIFICAÇÃO DAS PEÇAS.....                      | 78        |
| <b>4</b> | <b>RESULTADOS E DISCUSSÕES.....</b>                             | <b>83</b> |
| 4.1      | TREINAMENTO DO MODELO.....                                      | 83        |
| 4.2      | TESTE DO MODELO.....                                            | 84        |
| 4.3      | TESTE DO APLICATIVO.....                                        | 86        |
| 4.4      | COMPARATIVO COM TRABALHOS RELACIONADOS.....                     | 90        |
| 4.5      | CONTRIBUIÇÕES DO TRABALHO.....                                  | 91        |
| <b>5</b> | <b>CONCLUSÃO.....</b>                                           | <b>93</b> |
|          | <b>REFERÊNCIAS.....</b>                                         | <b>94</b> |

## 1 INTRODUÇÃO

A indústria metalúrgica exerce papel essencial na produção de bens duráveis, com destaque para a fabricação de mobiliário metálico, como roupeiros escolares e industriais. Esses produtos são constituídos por chapas de aço estampadas, um processo que envolve a conformação do metal por meio de prensas mecânicas equipadas com matrizes específicas (Singh *et al.*, 2024).

A qualidade das estampas é determinante para a montagem final do produto, sendo essencial que os padrões de conformidade sejam rigidamente observados. Contudo, devido à frequente troca de componentes, como rolamentos e matrizes nas máquinas de estampagem, podem ocorrer erros durante o processo, resultando em peças fora do padrão que comprometem a montagem, aumentam os custos de retrabalho e impactam negativamente a percepção do cliente quanto à qualidade do produto (Machado *et al.*, 2024).

Com o advento da Indústria 4.0, a busca por eficiência, produtividade e rastreabilidade nos processos industriais impulsionou a adoção de tecnologias inteligentes, entre elas a visão computacional. Essa área da inteligência artificial permite que sistemas computacionais interpretem informações visuais, simulando a percepção humana por meio de técnicas de processamento de imagens e aprendizado de máquina (Gonzalez; Woods, 2018; Penumuru *et al.*, 2020).

Aplicada à inspeção industrial, a visão computacional possibilita a detecção automática de falhas, promovendo maior precisão e agilidade na verificação da conformidade de peças, além de reduzir a subjetividade inerente à avaliação humana (Zhou *et al.*, 2022; My, 2021).

Algoritmos como Redes Neurais Artificiais (RNA), Support Vector Machines (SVM) e K-Nearest Neighbors (KNN) têm sido amplamente empregados para a extração de características visuais em imagens industriais. Entre esses, destacam-se as Redes Neurais Convolucionais (CNNs), projetadas para reconhecer padrões espaciais com alto grau de eficiência e acurácia. Essas redes operam por meio de camadas convolucionais e de *pooling*, capazes de identificar padrões locais e globais em imagens, sendo amplamente utilizadas em tarefas de classificação, segmentação e detecção de objetos (Miranda *et al.*, 2015).

A literatura apresenta exemplos bem-sucedidos de aplicação da visão computacional na indústria metalúrgica. Um exemplo é o estudo de Ferreira e

Jaimes (2018), que desenvolveram um sistema para identificar números de série em chapas de aço bruto com 93% de precisão, evidenciando o potencial dessas técnicas para soluções de inspeção automatizada.

Alinhado a esse cenário, o presente trabalho propõe o desenvolvimento de uma ferramenta baseada em visão computacional para realizar a classificação automatizada da conformidade das estampas em chapas metálicas utilizadas como fundo de roupeiros fabricados pela empresa Só Aço Industrial Ltda., localizada em Teresina-PI. As peças são produzidas por meio de uma prensa Camasi CMSLP1000, que permite a fabricação de diversos modelos de estampas, sendo essencial garantir a uniformidade dos padrões para viabilizar a montagem correta dos produtos.

O sistema proposto foi desenvolvido com base em um modelo de CNN treinado a partir de imagens reais coletadas na linha de produção. As imagens foram submetidas a etapas de pré-processamento, conversão para tons de cinza, equalização de histograma e aumento de dados (*data augmentation*), com posterior treinamento, validação e teste do modelo. As bibliotecas *OpenCV* e *scikit-learn*, juntamente com a linguagem Python, foram utilizadas para a implementação dos algoritmos de processamento e classificação. Como produto final, foi desenvolvido um aplicativo móvel capaz de realizar a inspeção em tempo real, oferecendo uma interface intuitiva e portabilidade para uso direto na fábrica.

Dessa forma, este trabalho busca contribuir com a modernização do processo de controle de qualidade industrial por meio da aplicação de visão computacional, promovendo maior confiabilidade, redução de erros humanos e otimização do fluxo produtivo no setor metalúrgico.

## 1.1 OBJETIVOS

### 1.1.1 Geral

Desenvolver uma aplicação móvel, MetalSync, que utilize visão computacional com redes neurais convolucionais (CNNs) para identificar automaticamente a conformidade de estampas em chapas metálicas utilizadas como fundo de roupeiros industriais.

### 1.1.2 Específicos

Para atingir o objetivo geral deste trabalho, é necessário alcançar os seguintes objetivos específicos:

- Realizar a aquisição do conjunto de imagens das peças utilizadas como fundo de roupeiro, incluindo seleção, rotulagem conforme o padrão de conformidade das estampas, pré-processamento das imagens e aplicação de técnicas de aumento de dados (*data augmentation*) para assegurar diversidade e representatividade visual.
- Projetar a arquitetura de uma rede neural convolucional (CNN), definindo o número de camadas, filtros, funções de ativação e realizando o ajuste de hiperparâmetros críticos, como taxa de aprendizagem, tamanho do *batch* e algoritmo otimizador, a fim de obter um desempenho eficiente.
- Treinar e validar o modelo de CNN utilizando o banco de imagens preparado, adotando estratégias como validação cruzada para mitigar *overfitting* e garantir a generalização do modelo.
- Avaliar o desempenho da rede neural por meio de métricas como acurácia, precisão, *recall*, *F1-score* e análise da matriz de confusão, assegurando robustez na detecção de não conformidades nas estampas.
- Implementar um aplicativo móvel com interface intuitiva, integrando o modelo treinado para a captura e análise em tempo real das imagens das peças, com foco na usabilidade em ambientes industriais e compatibilidade com dispositivos *Android*.

## 2 REFERENCIAL TEÓRICO

### 2.1 LAMINADOS DE AÇO

Os laminados de aço representam materiais largamente utilizados na indústria siderúrgica, devido às suas propriedades mecânicas favoráveis, como resistência e maleabilidade. Sua produção ocorre por meio de processos de laminação a quente ou a frio, que resultam em chapas metálicas uniformes, amplamente aplicadas na fabricação de peças estampadas (Zaitsev, *et al.*, 2023).

A qualidade e a uniformidade dessas chapas são fatores determinantes para o sucesso do processo de estampagem, tornando a análise da conformidade do padrão de estampa uma etapa essencial para a garantia da qualidade do produto final (Rizzo, 2022; Zaitsev, *et al.*, 2023).

A laminação consiste em um processo de deformação plástica que altera a geometria original dos metais por meio da aplicação de pressão contínua. Essa operação é realizada por equipamentos denominados laminadores, compostos por cilindros que comprimem o material metálico, reduzindo sua seção transversal e, simultaneamente, aumentando seu comprimento (Rizzo, 2022).

Após o processo de laminação, as chapas metálicas são enroladas em grandes bobinas, o que facilita seu transporte, armazenamento e posterior alimentação das linhas de produção. Essas bobinas são acondicionadas em áreas específicas do estoque industrial, onde permanecem organizadas até sua utilização nas etapas seguintes de corte ou estampagem (Hamryszczak *et al.*, 2024).

A Figura 1 ilustra bobinas de aço laminado armazenadas em um estoque industrial, prontas para uso. O controle adequado dessas unidades, aliado a condições ambientais adequadas, é essencial para preservar a integridade superficial do material e garantir a conformidade dimensional exigida nos processos subsequentes (Zaitsev, *et al.*, 2023).

Figura 1 - Estoque de bobinas de aço laminado



Fonte: Lankhorst Mouldings, 2025.


## 2.2 PROCESSO DE ESTAMPAGEM DE CHAPAS METÁLICAS

A estampagem é um processo de fabricação amplamente empregado na indústria, caracterizado pela conformação mecânica de chapas metálicas por meio de operações como corte, dobra e embutimento, geralmente realizadas a frio (Felisbino *et al.*, 2021). Nesse método, a chapa metálica é posicionada sobre uma matriz e submetida à ação de uma ferramenta acoplada a uma prensa, a qual aplica uma força específica que induz deformações plásticas no material (Junior; Caversan, 2012; Qattawi *et al.*, 2012; Chiaverini, 1995).

As chapas utilizadas nesse processo são, em sua maioria, compostas por aço, alumínio ou ligas metálicas, e apresentam espessura consideravelmente inferior à sua largura e comprimento. São disponibilizadas comercialmente em formatos como bobinas, tiras ou folhas, obtidas a partir de processos de laminação a quente ou a frio (Schaeffer, 2011; Felisbino *et al.*, 2021).

A Figura 2 ilustra uma etapa típica do processo de fabricação de componentes metálicos, destacando uma porta automotiva logo após a estampagem. Esse exemplo evidencia a aplicação prática das chapas metálicas em larga escala na indústria, especialmente em setores que demandam precisão dimensional e alta resistência estrutural, como o automotivo (Schaeffer; Cavaler, 2018).

Figura 2 - Porta automotiva após o processo de estampagem metálica



Fonte: Schaeffer e Cavaler, 2018.

A conformação plástica conferida pela estampagem proporciona ao produto final propriedades desejáveis, como elevada resistência mecânica, rigidez estrutural e bom acabamento superficial. Esses atributos contribuem para a redução da necessidade de retrabalho ou de processos complementares, otimizando o desempenho e a eficiência da linha de produção (Schaeffer; Cavaler, 2018).

Entre os métodos de conformação, destacam-se a estampagem a frio e a estampagem a quente. A estampagem a frio é realizada à temperatura ambiente e é indicada para a fabricação de peças que exigem alta precisão dimensional e bom acabamento superficial. Trata-se de um processo ideal para produções em larga escala, pois oferece elevada repetibilidade e eficiência (Caron; Daun; Wells, 2014; Gatea; Ou; McCartney, 2016).

Por sua vez, a estampagem a quente é executada em temperaturas elevadas, o que permite a conformação de geometrias mais complexas e promove alterações nas propriedades mecânicas do material, como o aumento da resistência e da ductilidade (Gronostajski *et al.*, 2019).

Esse método apresenta vantagens como alta produtividade, bom acabamento superficial, maior resistência das peças e menor custo unitário, especialmente quando aplicado em produções de grande volume. Contudo, o investimento em ferramentas especializadas pode representar um custo inicial elevado, sendo compensado pela escala de produção (Schaeffer, 2011).

A eficiência do processo de estampagem está diretamente relacionada a fatores como a geometria da matriz, as propriedades físico-mecânicas do material e as condições operacionais adotadas (Gatea; Ou; McCartney, 2016; Felisbino *et al.*, 2021).

Nesse contexto, a integração com tecnologias emergentes, como a visão computacional, tem desempenhado papel estratégico no controle de qualidade em tempo real, viabilizando a detecção precoce de falhas e a correção de desvios ainda durante a fabricação. Essa integração contribui para o aumento da conformidade das peças com os padrões estabelecidos, além de otimizar a eficiência dos ciclos produtivos (Fang, 2020; Felisbino *et al.*, 2021).

### 2.2.1 Tipos de Defeitos Comuns

Entre os principais defeitos observados em chapas metálicas destacam-se as rachaduras, as dobras e as imperfeições superficiais. Dentre esses, as rachaduras são especialmente críticas, pois comprometem a integridade estrutural do material e, em situações mais severas, podem causar falhas mecânicas graves (Ashour *et al.*, 2019).

Essas falhas geralmente resultam de tensões internas geradas por processos inadequados de fabricação ou tratamentos térmicos incorretos. Um tipo comum de rachadura é a ruptura, que ocorre quando o afinamento gerado pelo estiramento da chapa não é aliviado, levando à falha completa da parede metálica (Cui; Lei; Xing, 2012). A Figura 3 ilustra esse tipo de defeito, evidenciando o rompimento da superfície após o esforço excessivo aplicado durante o processo de estampagem.

Figura 3 - Exemplo de Ruptura em Chapa Metálica após Estampagem



Fonte: Ashour *et al.*, 2019.

A detecção precoce dessas fissuras é essencial, e as tecnologias baseadas em visão computacional têm demonstrado elevada eficácia na identificação de trincas microscópicas ainda em seus estágios iniciais, possibilitando a

implementação de medidas corretivas antes da progressão dos danos (Wang *et al.*, 2021). A atuação preventiva viabiliza a redução de desperdícios, aumento da segurança e melhora no controle de qualidade da linha de produção.

Outro defeito recorrente é o engripamento, que ocorre principalmente quando há excesso de força do quebra-rugas sobre a chapa, provocando o desprendimento de resíduos metálicos devido ao atrito excessivo. Esse acúmulo de resíduos causa marcas irregulares e falhas na superfície, exigindo reparos imediatos e podendo comprometer toda a peça (Cui; Lei; Xing, 2012).

Na Figura 4 é possível observar um exemplo típico desse defeito, que, embora não necessariamente comprometa a estrutura da peça, afeta significativamente a estética e a funcionalidade, além de gerar retrabalho e tempo ocioso na produção (Ashour *et al.*, 2019).

Figura 4 - Defeito de Engripamento em Superfície Metálica



Fonte: Ashour *et al.*, 2019.

Além das falhas estruturais e do engripamento, a deformação da chapa constitui um defeito significativo no processo de estampagem. Essa deformação ocorre quando a peça final apresenta desvios geométricos indesejados, geralmente provocados pela alimentação irregular do material durante a conformação. Entre os fatores que contribuem para esse tipo de falha, destacam-se a regulação inadequada da prensa, variações nas dimensões dos componentes da ferramenta e oscilações nas propriedades do material da chapa (Ashour *et al.*, 2019).

Durante a etapa de *tryout* das ferramentas, são frequentemente realizados ajustes no desenho de punções e matrizes com o objetivo de eliminar tais

imperfeições. A Figura 5 ilustra uma ocorrência típica de deformação visível após o processo de estampagem, evidenciando como a falta de uniformidade compromete a qualidade e a conformidade dimensional do produto final (Ashour *et al.*, 2019).

Figura 5 - Deformação Superficial em Peça Estampada



Fonte: Ashour *et al.*, 2019.

As dobras também são defeitos comuns e ocorrem tanto durante a manipulação das chapas quanto em decorrência de falhas no processo de conformação. Essas deformações, sejam permanentes ou temporárias, comprometem não apenas a integridade estrutural das peças, mas também sua qualidade estética, resultando em prejuízos financeiros e aumento do retrabalho nas linhas de produção (Ashour *et al.*, 2019).

A utilização de técnicas de visão computacional permite a detecção precisa dessas irregularidades, viabilizando a correção imediata dos defeitos e a análise das condições operacionais que contribuem para sua ocorrência (Wang *et al.*, 2021).

As imperfeições de superfície, tais como arranhões e manchas, configuram anomalias relevantes que comprometem tanto a estética quanto a resistência à corrosão dos produtos finais. Embora sejam menos críticas que as rachaduras do ponto de vista estrutural, a detecção contínua dessas falhas por meio de sistemas de visão computacional é essencial para garantir a qualidade ao longo do processo produtivo (Ashour *et al.*, 2019; Chen, 2003).

Essa tecnologia possibilita a identificação em tempo real de defeitos em grandes volumes de peças, contribuindo para a redução do descarte, a otimização do controle de qualidade e a prevenção de não conformidades recorrentes. Dessa forma, promove-se um ciclo sustentável de melhoria contínua na fabricação de chapas metálicas (Ashour *et al.*, 2019).

### 2.2.2 Normas e Critérios de Qualidade em Peças Estampadas

A qualidade das peças estampadas em chapas metálicas é assegurada por um conjunto de normas técnicas e critérios de controle que garantem a conformidade com especificações rigorosas exigidas pela indústria (ABNT, 2015). Entre as normas de referência, destacam-se as internacionalmente reconhecidas ISO 9001, que trata do sistema de gestão da qualidade; ISO 2768, que estabelece tolerâncias dimensionais gerais; e as normas ISO 4287 e ISO 1302, que definem parâmetros e métodos para a indicação da rugosidade superficial (Cardinali; Silva; Poker Junior, 2022).

Além disso, diretrizes da ASTM International, como a ASTM E18, referente ao método de ensaio de dureza Rockwell, e a ASTM E384, que trata dos ensaios de microdureza Vickers e Knoop, compõem a base normativa utilizada no controle de qualidade dos processos de estampagem (Cardinali; Silva; Poker Junior, 2022). Esses padrões orientam a avaliação técnica das peças, assegurando a conformidade dimensional, superficial e mecânica, essenciais para a garantia da funcionalidade e durabilidade dos produtos finais (Muslimin *et al.*, 2023).

Os critérios de qualidade para peças estampadas em chapas metálicas abrangem aspectos relacionados às dimensões e tolerâncias, ao acabamento superficial e às propriedades mecânicas. As dimensões e tolerâncias são fundamentais para garantir a correta montagem e o funcionamento adequado das peças nos sistemas a que se destinam, uma vez que desvios podem acarretar falhas operacionais, necessidade de retrabalho ou até riscos de acidentes (Cardinali; Silva; Poker Junior, 2022).

O acabamento superficial, regulamentado por normas como a ISO 1302, impacta não apenas a estética do produto final, mas também sua resistência à corrosão e ao desgaste (Rocha *et al.*, 2023). Quanto às propriedades mecânicas, destacam-se a resistência à tração e a dureza, parâmetros essenciais para assegurar o desempenho das peças em condições reais de uso, avaliados conforme normas ASTM, como a E8/E8M, referente a ensaios de tração, e a E18, que trata da dureza Rockwell (Xie *et al.*, 2021).

Para garantir o atendimento aos requisitos de qualidade, os processos de inspeção contam com tecnologias avançadas, destacando-se os sistemas de visão computacional (Skardzius; Gargasas, 2025). Esses sistemas permitem a automação

da inspeção com elevada precisão e rapidez, possibilitando a detecção precoce de falhas como trincas, deformações e imperfeições superficiais, que podem comprometer tanto a qualidade quanto a segurança dos produtos (Dong *et al.*, 2025).

A integração entre as normas técnicas vigentes e as tecnologias modernas de inspeção, conforme destacado por Abanda *et al.* (2025), não apenas assegura a conformidade regulatória, mas também promove ganhos significativos em eficiência operacional, rastreabilidade dos processos e redução de desperdícios. Esses fatores são essenciais para a consolidação de uma indústria moderna, competitiva e ambientalmente sustentável.

## 2.3 DETECÇÃO DE DEFEITOS NA FABRICAÇÃO DO AÇO

Pesquisas demonstram que o uso de tecnologias avançadas para detecção de defeitos pode reduzir custos operacionais, aumentar a eficiência produtiva e elevar a qualidade dos produtos, estabelecendo as bases para a transformação da indústria siderúrgica em um ambiente inteligente (Yang, 2020). Essas técnicas são aplicadas principalmente na inspeção visual de produtos industriais, especialmente em contextos onde não há controle de qualidade automatizado.

Nos últimos anos, tem-se intensificado o desenvolvimento de modelos de detecção baseados em aprendizado profundo, com ênfase na inspeção automática de superfícies metálicas — um dos principais desafios na fabricação de aço. Nesse contexto, Yun (2020) propôs um sistema de inspeção utilizando redes neurais profundas, com uma arquitetura baseada em CNN (*Convolutional Neural Network*) para a classificação automática de defeitos.

Diante da limitação de dados de treinamento, os autores implementaram uma estratégia de *data augmentation*, gerando novas amostras por meio de transformações como rotações, translações e adição de ruído às imagens. Os resultados experimentais indicaram desempenho satisfatório do modelo, com acurácia de detecção de 98%.

Li *et al.* (2018) desenvolveram um sistema para detecção automática de defeitos superficiais em tiras de aço, empregando uma versão adaptada da arquitetura YOLO (*You Only Look Once*), modificada para operar como uma rede totalmente convolucional. A rede YOLO, originalmente proposta por Redmon (2016),

é amplamente reconhecida por sua capacidade de realizar detecção de objetos em tempo real, combinando velocidade e acurácia em aplicações industriais.

## 2.4 SISTEMAS DE INSPEÇÃO INDUSTRIAL

Os sistemas de inspeção industrial desempenham papel fundamental na garantia da qualidade dos produtos, especialmente no setor metalúrgico. Esses sistemas empregam tecnologias avançadas para verificar atributos físicos e geométricos dos componentes produzidos, assegurando sua conformidade com especificações técnicas rigorosas (Guimarães *et al.*, 2023).

Embora a inspeção manual tenha sido tradicionalmente adotada, ela apresenta limitações relacionadas à lentidão do processo e à suscetibilidade a erros humanos. Com o avanço tecnológico, a visão computacional emergiu como uma solução inovadora para esses desafios, possibilitando análises mais rápidas, precisas e automatizadas, elevando significativamente a eficiência e a confiabilidade dos processos de inspeção (Szeliski, 2022).

A aplicação da visão computacional na inspeção industrial envolve o uso de câmeras e algoritmos de processamento de imagem para detectar padrões e identificar defeitos em chapas metálicas. Por meio de técnicas de aprendizado de máquina, esses sistemas são capazes de reconhecer imperfeições sutis, muitas vezes imperceptíveis à inspeção humana. A integração de sensores avançados e redes neurais possibilita a adaptação dinâmica às variáveis do processo produtivo e a rápida resposta a desvios de qualidade (Huang; Pedoeem; Chen, 2018; Hussain, 2023).

Um aspecto crucial desses sistemas é o controle em tempo real, que permite a detecção imediata de falhas em lotes de produção, fornecendo feedback instantâneo para ajustes no processo (Szeliski, 2022).

Essa capacidade reduz desperdícios e retrabalhos, contribuindo para a melhoria contínua da qualidade. Dessa forma, a visão computacional torna-se uma ferramenta estratégica para o setor metalúrgico, atendendo às demandas crescentes por eficiência e competitividade (Hussain, 2023).

### 2.4.1 Inspeção manual *versus* automatizada

A inspeção de chapas metálicas é um processo essencial para o controle da qualidade, garantindo que os produtos atendam a padrões rigorosos antes de sua liberação ao mercado. Tradicionalmente, esse processo tem sido realizado por operadores treinados que avaliam visualmente superfícies das chapas em busca de identificar imperfeições, como descontinuidades, deformações e padrões fora de especificação (Zeng *et al.*, 2024).

No entanto, a inspeção manual está sujeita a limitações significativas relacionadas à variabilidade humana, como fadiga visual, subjetividade na interpretação e inconsistência nos critérios de julgamento, o que pode comprometer a confiabilidade e a repetibilidade dos resultados (Aust; Pons, 2022).

Na Figura 6 é exemplificada uma situação real de inspeção visual convencional, aplicada ao controle de qualidade na indústria cerâmica, especificamente na fabricação de azulejos. Nesse modelo tradicional, um operador permanece posicionado em um ponto estratégico da linha de produção, sendo responsável por inspecionar individualmente cada peça produzida. Durante essa avaliação, o funcionário deve verificar a integridade física, a qualidade da impressão e a conformidade dimensional dos azulejos (Xing; Jia, 2021).

Figura 6 - Exemplo de inspeção manual



Fonte: Aust e Pons, 2022.

Por outro lado, os sistemas de inspeção automatizada baseados em visão computacional e técnicas de aprendizado de máquina têm se consolidado como soluções tecnológicas robustas e eficazes para a detecção e classificação de não

conformidades em chapas metálicas estampadas. Esses sistemas operam com base na aquisição e processamento de imagens de alta resolução, permitindo a análise precisa de padrões geométricos e texturais com elevada repetibilidade e em tempo real (Li *et al.*, 2023b).

A Figura 7 ilustra um sistema de inspeção automatizada empregado na indústria de bebidas. Esse tipo de sistema é integrado à linha de produção com o objetivo de realizar, em tempo real, a verificação de conformidade dos produtos, substituindo ou complementando a inspeção visual manual realizada por operadores.

Figura 7 - Exemplo sistema de inspeção automatizada



Fonte: Aust e Pons, 2022.

A aplicação de redes neurais convolucionais (CNNs) tem se mostrado particularmente promissora na identificação de padrões complexos e sutis, superando em diversos casos o desempenho humano. A escolha entre inspeção manual e automatizada deve considerar aspectos como o volume de produção, a complexidade das peças e a criticidade dos defeitos a serem detectados (Pratama *et al.*, 2025).

Enquanto a inspeção manual oferece flexibilidade para ambientes de produção de menor escala ou personalizados, a inspeção automatizada se mostra superior em processos de alta produtividade, garantindo consistência e maior eficiência (Zeng *et al.*, 2024). Além disso, a automação contribui para a redução de custos operacionais a longo prazo e para a elevação da qualidade dos produtos finais, evidenciando a importância de sistemas de controle de qualidade adaptados às necessidades específicas da indústria (Zeng *et al.*, 2024; Xing; Jia, 2021).

### 2.4.2 Arquiteturas de visão computacional em linha de produção

A arquitetura de visão computacional em linhas de produção refere-se à integração de tecnologias de processamento e análise de imagens em sistemas automatizados, com o objetivo de monitorar a qualidade e a conformidade dos produtos durante as etapas de manufatura. Essa abordagem possibilita a identificação em tempo real de defeitos e variações nos padrões de estampa em chapas metálicas, garantindo que os produtos atendam aos rigorosos critérios de qualidade estabelecidos pelas indústrias (Ibrahim *et al.*, 2024).

Essas arquiteturas são compostas por diversas camadas, que englobam desde a captura das imagens, passando pelo pré-processamento, até a análise e interpretação dos dados visuais. Essa estrutura facilita um fluxo contínuo e eficiente de trabalho, otimizando a operação e aumentando a assertividade do controle de qualidade (Ibrahim *et al.*, 2024).

No núcleo dessas arquiteturas estão algoritmos de aprendizado de máquina e técnicas avançadas de processamento de imagens, que permitem a detecção automática de falhas muitas vezes imperceptíveis ao olho humano. Destacam-se, em especial, as redes neurais convolucionais (CNNs), reconhecidas por sua eficácia em tarefas de visão computacional, como classificação e segmentação de imagens (Hütten *et al.*, 2024).

Além disso, componentes físicos variáveis, como sistemas de iluminação controlada e câmeras de alta resolução, são fundamentais para a aquisição de dados visuais precisos. Esses dados alimentam o treinamento dos modelos, que passam a reconhecer padrões desejados e a identificar anomalias, tais como arranhões, deformações e falhas na estampa (Fang *et al.*, 2020).

A aplicação dessas tecnologias não apenas acelera o processo de inspeção, mas também possibilita a realização de análises estatísticas detalhadas, as quais podem ser empregadas para promover a melhoria contínua dos processos produtivos (Fang *et al.*, 2020).

A compreensão e implementação de arquiteturas de visão computacional em ambientes de produção envolvem uma série de desafios, entre os quais se destacam a seleção adequada de *hardware* e *software*, bem como a integração eficiente com os sistemas de manufatura já existentes. Para que essas soluções sejam efetivas, é essencial que apresentem escalabilidade e flexibilidade, de modo a

se adaptarem a diferentes cenários industriais e às constantes mudanças nas demandas produtivas (Nosrati *et al.*, 2025).

A adoção bem-sucedida dessas arquiteturas permite não apenas assegurar a conformidade com rigorosos padrões de qualidade, mas também impulsionar a inovação contínua nos processos produtivos. Como consequência, observam-se ganhos expressivos em produtividade, redução de desperdícios e elevação dos níveis de satisfação do cliente — fatores decisivos para a competitividade em um mercado dinâmico e em constante transformação (Tang *et al.*, 2023).

## 2.5 VISÃO COMPUTACIONAL

A visão computacional é um campo interdisciplinar que combina algoritmos matemáticos e técnicas de aprendizado de máquina com o objetivo de permitir que sistemas computacionais interpretem e compreendam informações visuais do mundo real de maneira análoga à percepção humana (Oliveira; Melo, 2020).


Essencialmente, essa área busca extrair e processar dados relevantes a partir de imagens digitais e vídeos, sendo amplamente aplicada em ambientes industriais. Um exemplo expressivo de sua aplicação é a análise automatizada da conformidade de padrões em chapas metálicas, contribuindo para a otimização de processos produtivos e o aumento da precisão no controle de qualidade (Khemasuwan *et al.*, 2020).

O desenvolvimento de processos baseados em visão computacional voltados à inspeção de estampas metálicas demanda um conhecimento aprofundado nas áreas de aquisição de imagens, processamento de sinais e análise de padrões. O fluxo típico inicia-se com a captura de imagens por sensores de alta resolução, capazes de registrar detalhes minuciosos da superfície das chapas (Gonzalez; Woods, 2018; LUO *et al.*, 2020).

Na sequência, são aplicados algoritmos de pré-processamento com a finalidade de aprimorar a qualidade das imagens obtidas, por meio de correções de iluminação, eliminação de ruídos e realce de contrastes. A etapa subsequente concentra-se na identificação de padrões, utilizando técnicas como segmentação e extração de características, o que possibilita a detecção automatizada de defeitos ou inconformidades em relação aos padrões previamente definidos (Gonzalez; Woods, 2018).

Na Figura 8 são ilustradas as etapas fundamentais de um sistema genérico de visão computacional, organizadas em dois eixos principais de análise: qualitativa e quantitativa. Na fase de análise qualitativa, correspondente ao pré-processamento visual, a imagem é inicialmente digitalizada em uma matriz de pixels, seguida por processos de restauração e realce que visam aprimorar sua qualidade. Em seguida, a imagem é submetida à segmentação, processo que agrupa pixels com características semelhantes, formando regiões de interesse relevantes para o contexto da aplicação (Azevedo; Conci; Leta, 2022).

Figura 8 - Etapas de um sistema de visão computacional típico



Fonte: Adaptado de Azevedo, Conci e Leta, 2022.

Esses grupos segmentados servem como entrada para a análise quantitativa, etapa na qual são realizados o reconhecimento ou classificação dos padrões visuais e a extração de atributos, convertendo as regiões segmentadas em dados estruturados. A última fase, de decisão, utiliza essas informações quantitativas para gerar uma interpretação final do conteúdo da imagem. O fluxo contínuo entre essas etapas transforma dados visuais brutos em conhecimento aplicável, promovendo uma integração eficiente entre melhoria visual e extração automatizada de informações relevantes (Azevedo; Conci; Leta, 2022).

Nesse contexto, o uso de redes neurais convolucionais (CNNs) tem se destacado pela eficácia na análise de imagens, dado seu potencial para extrair e processar padrões visuais complexos. Por meio do treinamento supervisionado com

conjuntos de dados representativos, essas arquiteturas aprendem a reconhecer características hierárquicas e sutis nas imagens, proporcionando classificações com elevado grau de acurácia (Varshni *et al.*, 2019; Geetha; Abhishek; Akshayanat, 2021).

A integração entre os avanços teóricos e as aplicações práticas voltadas à inspeção de estampas metálicas representa um passo significativo na modernização tecnológica da indústria. Essa convergência tem possibilitado um controle de qualidade mais rigoroso e a redução de falhas ao longo do processo de fabricação. Nesse contexto, os princípios da visão computacional oferecem não apenas suporte técnico qualificado, mas também impulsionam novos padrões de eficiência e confiabilidade nas linhas de produção da indústria metalúrgica (Pratama *et al.*, 2025).

Os sistemas de inspeção industrial exercem um papel fundamental na verificação da qualidade e conformidade de produtos manufaturados, especialmente no setor metalúrgico. Combinando diversas tecnologias, esses sistemas analisam atributos físicos e geométricos de componentes e superfícies, proporcionando inspeções mais rápidas, precisas e confiáveis quando comparadas aos métodos tradicionais (Guimarães *et al.*, 2023).

Historicamente, os processos de inspeção eram realizados majoritariamente de forma manual. Embora essa abordagem se mostrasse eficaz em determinadas situações, apresentava limitações quanto à precisão, reprodutibilidade e agilidade, além de estar sujeita a erros humanos. Com o avanço das tecnologias digitais, a inspeção por visão computacional surgiu como uma solução inovadora, proporcionando análises muito mais rápidas, precisas e padronizadas (Szeliski, 2022).

Quando integrada aos sistemas de inspeção industrial, a visão computacional utiliza câmeras e algoritmos de processamento de imagem para detectar padrões, medir dimensões e identificar defeitos em chapas metálicas. Por meio de técnicas avançadas de aprendizado de máquina e inteligência artificial, esses sistemas são capazes de reconhecer imperfeições sutis — como arranhões, manchas ou variações de cor — que muitas vezes passariam despercebidas em inspeções manuais (Huang; Pedoeem; Chen, 2018).

Além disso, a incorporação de sensores inteligentes e redes neurais convolucionais permite uma adaptação dinâmica às variáveis do processo produtivo,

otimizando o tempo de resposta a desvios de qualidade e, com isso, elevando os níveis de eficiência e produtividade na indústria (Huang; Pedoeem; Chen, 2018; Hussain, 2023).

Um dos aspectos mais relevantes dos sistemas de inspeção industrial é sua capacidade de atuar em tempo real. Ao coletar e analisar dados continuamente, esses sistemas não apenas detectam falhas com agilidade durante o processo produtivo, como também oferecem *feedback* imediato, permitindo ajustes automáticos e precisos nos parâmetros de fabricação. Essa resposta instantânea reduz de forma significativa o desperdício de materiais e a necessidade de retrabalho, além de sustentar um ciclo contínuo de melhoria e controle de qualidade (Hussain, 2023).

Em síntese, a adoção de sistemas de inspeção baseados em visão computacional marca uma transformação significativa na forma como se conduz a garantia da qualidade na indústria metalúrgica. Essa tecnologia responde às demandas contemporâneas por eficiência, rastreabilidade e precisão, consolidando-se como um diferencial competitivo em ambientes produtivos cada vez mais exigentes (Hussain, 2023).

## 2.6 AQUISIÇÃO DE IMAGENS

O processo de aquisição de imagens em visão computacional envolve várias etapas importantes, desde a captura inicial da cena até a representação digital da imagem. Primeiro, uma cena é capturada por um dispositivo como uma câmera, sensor ou scanner, e a informação visual é convertida em sinais elétricos ou digitais. A conversão de analógico para digital é frequentemente necessária para permitir processamento adicional por um computador (Barelli, 2018).

O processo inicia-se com a captação de imagens através de um dispositivo que recebe ondas de luz tridimensionais, gerando um sinal elétrico proporcional à intensidade energética. Posteriormente, esse sinal é convertido para um formato digital bidimensional. Conforme destacado por Marshall (2018), uma imagem pode ser conceitualmente definida como o resultado da interação de dois componentes: a intensidade da luz que atinge um objeto e a fração dessa luz que o objeto permite passar.

Após a captura, as imagens podem passar por técnicas de pré-processamento, como ajuste de brilho, contraste e remoção de ruídos, para melhorar a qualidade e facilitar análises posteriores. A armazenagem digital é comum para permitir o acesso e manipulação eficientes, especialmente em casos de grandes volumes de dados visuais (Barelli, 2018). Nessa etapa a representação de cores de uma imagem, é muito comum o uso do padrão RGB. Este padrão foi elaborado segundo a teoria tricromática de Young-Helmholtz, em que para a percepção de cores pelo olho humano há 3 cores primárias que são: vermelho (R, *red*), verde (G, *green*) e azul (B, *blue*) (Pedrini; Schwartz, 2008).

## 2.7 PRÉ-PROCESSAMENTO

O pré-processamento de imagens é uma etapa essencial dentro do processamento digital de imagens (PDI), com o objetivo de melhorar a qualidade visual e estrutural dos dados antes de etapas mais avançadas, como a segmentação, extração de atributos e classificação. Frequentemente, as imagens capturadas apresentam ruídos, variações de iluminação, distorções ou imperfeições causadas por limitações do sensor, condições ambientais ou movimentação do objeto, o que pode comprometer a análise automatizada (Barelli, 2018).

Para superar essas limitações, aplicam-se técnicas específicas de filtragem e realce, que atuam na suavização de ruídos, no aumento do contraste e na evidência de bordas e detalhes relevantes. Filtros convolucionais, como os do tipo média, mediana, gaussiano ou Sobel, são utilizados para destacar contornos, remover ruído ou realçar regiões específicas da imagem (Tavares *et al.*, 2024).

Além disso, técnicas de morfologia matemática, como erosão, dilatação, abertura e fechamento, são empregadas para corrigir lacunas, remover pequenos objetos indesejados e unificar regiões fragmentadas, sendo particularmente úteis em imagens binarizadas (Zheng, 2023).

A Figura 9 ilustra um exemplo da aplicação de um filtro de mediana como pré-processamento para atenuação de ruídos em uma imagem.

Figura 9 - Exemplo de imagem (a) antes do pré-processamento e (b) após a aplicação de um filtro de mediana como pré-processamento.



Fonte: Zheng, 2023.

Ao melhorar a clareza estrutural da imagem, o pré-processamento aumenta a robustez dos algoritmos de visão computacional, assegurando que as informações essenciais sejam preservadas e evidenciadas. Dessa forma, essa etapa não apenas facilita a segmentação que virá a seguir, como também contribui diretamente para a precisão e confiabilidade dos resultados finais (Zheng, 2023).

## 2.8 PROCESSAMENTO E ANÁLISE DA IMAGEM

O processamento de imagem desempenha um papel fundamental na extração de características dimensionais para análise em visão computacional. Nesta metodologia, são aplicadas técnicas e algoritmos para interpretar informações visuais contidas em imagens com o objetivo de extrair informações específicas relacionadas às dimensões dos objetos que se pretende analisar (Marshall, 2018)

Após a captura, um dos primeiros passos no processamento de imagem para extração de características dimensionais é o pré-processamento da imagem. Nessa etapa, podem ser aplicados filtros para melhorar a qualidade da imagem, eliminando ruídos, ajustando o contraste e corrigindo distorções (Albuquerque; Albuquerque, 2000).

A etapa fundamental para a extração de características dimensionais é a segmentação, que consiste em isolar as regiões de interesse na imagem. Isso pode ser feito destacando bordas, identificando regiões com intensidades específicas de *pixels* ou utilizando outras técnicas para dividir a imagem em partes relevantes (Gonzalez; Woods, 2018).

Uma vez que as regiões de interesse estão isoladas, são empregados algoritmos para medir as dimensões dessas áreas. Nesse ponto será utilizado algoritmos capazes de identificar características de formas, medições de comprimento de contornos e o cálculo de áreas e perímetros. Nessa etapa a calibração é essencial para converter as medidas obtidas em unidades físicas reais (Gonzalez; Woods, 2018).

Para que o sistema de visão computacional seja cada vez mais avançado e robusto, a aplicação de técnicas de aprendizado de máquina é fundamental para proporcionar uma análise mais confiável das características dimensionais. Isso possibilita que o sistema se adapte a diferentes condições e variações nas imagens, aprimorando a precisão e eficiência da extração de dimensões.


## 2.9 SEGMENTAÇÃO

A segmentação representa um dos problemas mais antigos e amplamente explorados no campo do processamento digital de imagens (Szelinski, 2010). Essa fase consiste em particionar o plano da imagem, objeto de estudo, visando isolar o elemento em foco. Sua relevância é crucial, pois é nesse estágio que ocorre a categorização dos diversos elementos, preparando o terreno para a extração de suas características específicas na próxima etapa. De acordo com Pedrini e Schwartz (2008), esse procedimento é essencial para assegurar que as informações resultantes do sistema de análise sejam confiáveis.

A segmentação visa abordar duas propriedades fundamentais da escala de cinza da imagem: descontinuidades e semelhanças. No primeiro caso, a ferramenta visa separar imagens com base em flutuações repentinas na escala de cinza, como as que ocorrem nas bordas. Na segunda abordagem, a ferramenta visa agrupar pontos de imagem com valores semelhantes para um determinado conjunto de características (Pedrini; Schwartz, 2010).

A Figura 10 apresenta um exemplo de segmentação aplicada à classificação de carne bovina, obtida após cinco iterações de dilatação adaptativa com ajuste do invólucro convexo. A linha branca que contorna a região muscular indica os limites definidos por esse invólucro (Rahman *et al.*, 2024).

Figura 10 - Exemplo segmentação de um tecido muscular



Fonte: Adaptado de Rahman *et al.*, 2024.

Esta técnica define um limite de intensidade de pixel e gera uma imagem binária. Para imagens que contenham um objeto de interesse, os valores que ultrapassam esse valor são destacados na imagem final com os *pixels* do objeto (geralmente brancos, representando o primeiro plano). No entanto, *pixels* com valores abaixo do limite são considerados parte do plano de fundo e são marcados em preto recebendo valor zero (Rahman *et al.*, 2024).

## 2.10 EXTRAÇÃO DE CARACTERÍSTICA

A extração de características é uma etapa essencial em sistemas de visão computacional pois gera informações que são a base para posterior classificação e identificação. Para atingir esse objetivo é importante estabelecer parâmetros quantificáveis relacionados ao objeto de interesse, como dimensões, inércia e propriedades topológicas (Conci *et al.*, 2008).

Uma das principais formas de extrair propriedades de um objeto de interesse que descreva a distribuição espacial de pontos dentro de uma imagem ou região é utilizar propriedades inerciais usando momentos de imagem.

## 2.11 CLASSIFICAÇÃO E RECONHECIMENTO

A etapa final do processo é a classificação e o reconhecimento, na qual são realizadas comparações essenciais entre os objetos de interesse para organizar um conjunto com propriedades em comum. Conforme descrito por Pedrini e Schwartz (2008), esse procedimento tem como objetivo estabelecer um mapeamento que relacione as características das amostras a um conjunto de rótulos, de maneira que amostras com propriedades semelhantes sejam agrupadas sob o mesmo rótulo.

Para fazer uma relação entre as características das amostras e um grupo de rótulos, utilizamos os classificadores. Os classificadores buscam atribuir a cada amostra uma classe específica, e o tipo de abordagem que empregam pode ser categorizado como classificação supervisionada ou não supervisionada, conforme definido por Pedrini e Schwartz (2008).

A classificação supervisionada envolve o treinamento de um algoritmo para reconhecer padrões de objetos previamente conhecidos. Nessa abordagem, um conjunto de características de objetos, juntamente com suas classes correspondentes, é apresentado ao classificador. Dessa forma, o algoritmo torna-se capaz de classificar automaticamente novos objetos (Barelli, 2018). Diversas técnicas são usadas para realizar essa classificação, variando desde abordagens mais simples, como KNN, até métodos mais complexos, como RNA e SVM (Conci *et al.*, 2008).

A classificação não supervisionada apresenta semelhanças com a abordagem supervisionada ao receber uma lista de características de diversos objetos para fins

de treinamento. Entretanto, a distinção crucial reside no fato de que não é necessário fornecer classificações para os objetos, eliminando assim a exigência de supervisão. Classificadores desse tipo demonstram a capacidade de identificar classes unicamente pela análise do grau de similaridade entre as propriedades dos objetos (Barelli, 2018).

## 2.12 VISÃO COMPUTACIONAL PARA DETECÇÃO DE DEFEITOS EM METAIS

A aplicação de visão computacional na inspeção de metais tem se consolidado como uma estratégia tecnológica de alta eficiência, especialmente em processos industriais que exigem controle rigoroso de qualidade e precisão operacional (Coltre; Martins, 2019). Inspirada na percepção visual humana, essa abordagem recorre a algoritmos sofisticados para analisar imagens de superfícies metálicas, capturando detalhes sutis com elevado grau de precisão (Qiao *et al.*, 2025).

Entre os defeitos mais recorrentes em chapas metálicas estão riscos, bolhas, trincas, delaminações e falhas no processo de estampagem — imperfeições que podem comprometer não apenas a integridade estrutural das peças, mas também sua estética e funcionalidade. Tais anomalias, muitas vezes difíceis de serem detectadas por métodos tradicionais de inspeção visual, tornam-se identificáveis por meio da análise computacional de imagens em alta resolução, que permite a identificação de variações discretas na textura, coloração e refletividade das superfícies (Aust; Pons, 2022; Martins; Pádua; Almeida, 2009).

A eficácia dessa técnica está fortemente vinculada à integração entre métodos de processamento digital de imagens e modelos de aprendizado de máquina. Em particular, redes neurais convolucionais (CNNs) têm se mostrado altamente eficazes na extração automática de características visuais complexas, possibilitando a identificação precisa de padrões e falhas que passariam despercebidos a inspeções humanas (Miranda *et al.*, 2015; Qiao *et al.*, 2025).

O processo de detecção automatizada de falhas em chapas metálicas geralmente tem início com a formação de um banco de imagens representativo, obtido sob diferentes condições operacionais e contendo variados tipos de defeitos. Essas imagens são essenciais para o treinamento supervisionado de modelos de aprendizado profundo, que aprendem a reconhecer padrões visuais associados à

perda de conformidade no processo de estampagem. Uma vez treinados, esses sistemas são capazes de operar em tempo real, executando inspeções contínuas diretamente na linha de produção, sem necessidade de interrupções ou intervenções humanas (Liu *et al.*, 2023).

Além da detecção precisa de não conformidades, as soluções de visão computacional incorporam funcionalidades analíticas avançadas, como geração automática de relatórios, análise estatística e visualização de indicadores de desempenho. Tais recursos conferem maior agilidade à tomada de decisão e fortalecem o controle de qualidade, contribuindo para a redução de retrabalho, do desperdício de insumos e dos custos operacionais envolvidos na produção (Zheng *et al.*, 2021).

Nesse cenário, a integração da visão computacional aos sistemas de manufatura inteligente consolida-se como um pilar estratégico da Indústria 4.0. Ao combinar automação, precisão e inteligência artificial, essa abordagem transforma a inspeção de qualidade em um processo preditivo e orientado por dados, promovendo avanços significativos em padronização, rastreabilidade e desempenho final dos produtos (Maack *et al.*, 2022; Li *et al.*, 2022).

### **2.12.1 Abordagens clássicas de processamento de imagem**

As técnicas clássicas de processamento de imagem têm sido fundamentais na análise de conformidade de padrões, especialmente em inspeções industriais como a verificação de estampas em chapas metálicas. A segmentação da imagem, etapa crítica nesse processo, visa decompor a imagem em regiões de interesse, sendo frequentemente realizada por limiarização — método que diferencia pixels com base em sua intensidade luminosa, facilitando a separação entre padrões e fundo (Gonzalez; Woods, 2018).

A extração de contornos complementa essa análise ao identificar bordas e descontinuidades. Métodos como os operadores de Sobel e Canny continuam relevantes por sua capacidade de detectar variações abruptas de intensidade, fornecendo representações vetoriais úteis para análise geométrica dos padrões (Szeliski, 2022).

Apesar de eficazes, essas técnicas apresentam limitações frente a ruídos e variações de iluminação. No entanto, quando aplicadas em ambientes controlados,

como linhas de produção, permanecem valiosas. A integração com métodos baseados em aprendizado profundo tem potencializado sistemas híbridos mais robustos e adaptáveis às exigências da indústria moderna (Alzarooni *et al.*, 2025; HE *et al.*, 2025).

### **2.12.2 Deep learning e CNNs aplicadas a inspeção de superfícies metálicas**

A crescente complexidade dos processos industriais e a exigência por precisão na fabricação de componentes metálicos têm impulsionado a adoção de métodos avançados para inspeção de superfícies (Li *et al.*, 2020). Nesse contexto, as redes neurais convolucionais (CNNs), uma das principais técnicas de deep learning, destacam-se pela capacidade de aprender automaticamente padrões visuais a partir de grandes volumes de dados (Wang *et al.*, 2021).

As CNNs apresentam alta eficácia no reconhecimento e na classificação de imagens, sendo especialmente adequadas para a identificação de falhas em chapas metálicas. Sua arquitetura, composta por múltiplas camadas convolucionais que simulam o funcionamento do sistema visual humano, permite a extração hierárquica de características complexas, desde elementos simples, como bordas, até padrões visuais mais abstratos, garantindo elevado desempenho na detecção de imperfeições (Bouguettaya; Zarzour; Messaadia, 2024).

A aplicação dessas redes em sistemas de inspeção visual segue um fluxo estruturado: inicia-se pela coleta e rotulagem de um conjunto robusto de imagens, representativo das diversas condições de superfície e iluminação encontradas no processo produtivo. Essa base de dados deve contemplar diferentes categorias, distinguindo superfícies em conformidade das que apresentam falhas (Liu *et al.*, 2023).

Após a preparação e anotação do conjunto de dados, procede-se ao treinamento da rede neural convolucional, durante o qual os parâmetros do modelo são ajustados com o objetivo de minimizar a taxa de erro na classificação. Esse processo requer considerável capacidade computacional, além da escolha de algoritmos de otimização eficientes para garantir a convergência do modelo (Konovalenko *et al.*, 2020; SI; Yasengjiang; Wu, 2022).

Os resultados obtidos com a aplicação de CNNs na inspeção de superfícies metálicas evidenciam um aumento expressivo na precisão em comparação com

métodos tradicionais, como a inspeção manual, que está sujeita a falhas humanas. A capacidade de realizar análises em tempo real, mesmo sob condições variáveis de produção, representa uma vantagem significativa para o controle da qualidade dos materiais. Assim, a integração do deep learning nas práticas de inspeção contribui para a modernização dos processos industriais, elevando a eficiência operacional e fortalecendo a competitividade de indústrias que exigem elevados padrões de qualidade (Alzarooni *et al.*, 2025).

## 2.13 REDES NEURAI CONVOLUCIONAIS

As redes neurais convolucionais (CNNs) representam uma classe avançada de arquiteturas de redes neurais, especialmente projetadas para o processamento e análise de dados estruturados, como imagens e vídeos. Inspiradas em princípios da neurociência, as CNNs simulam a forma como o cérebro humano interpreta informações visuais, por meio de um conjunto de camadas convolucionais capazes de extrair características hierárquicas e espaciais das entradas (Lecun *et al.*, 2015).

Cada camada convolucional realiza operações que combinam filtros aprendidos automaticamente com os dados de entrada, destacando padrões relevantes enquanto promovem a redução da dimensionalidade. Esse processo resulta em um tratamento mais eficiente e eficaz das informações visuais, facilitando tarefas complexas como reconhecimento, classificação e segmentação de imagens (Gu *et al.*, 2018).

O funcionamento das CNNs ocorre por meio de etapas fundamentais. Inicialmente, as camadas convolucionais aplicam filtros que detectam bordas, texturas e outros elementos básicos presentes nas imagens. Em seguida, camadas de agrupamento, ou *pooling*, são incorporadas para reduzir a resolução espacial, diminuindo o número de parâmetros e mitigando o risco de *overfitting*. Essas operações tornam as redes mais robustas e eficientes, favorecendo a generalização em tarefas de classificação e reconhecimento (Albawi *et al.*, 2017).

Além das camadas convolucionais, as CNNs frequentemente incluem camadas totalmente conectadas que integram as informações extraídas e realizam a classificação final. A interdependência entre essas camadas promove uma transição fluida da identificação de características para a tomada de decisão. Esse processo possibilita a aplicação eficaz das CNNs em tarefas complexas, como a análise da

conformidade de padrões de estampa, onde a precisão na detecção de anomalias é essencial (Li *et al.*, 2020).

Por meio do treinamento com conjuntos de dados rotulados, as CNNs aprendem não apenas a identificar padrões normais, mas também a distinguir variações que indicam possíveis falhas na produção. Assim, o avanço tecnológico proporcionado por essas redes contribui para a otimização dos processos industriais, elevando a qualidade e a eficiência nas linhas de produção (Maack *et al.*, 2022).

### 2.13.1 Arquitetura de CNNs


As Redes Neurais Convolucionais (CNNs) apresentam uma arquitetura composta por múltiplas camadas organizadas de forma hierárquica, nas quais cada tipo de camada exerce uma função específica no processamento de informações visuais (GU *et al.*, 2018).

Inicialmente, as camadas convolucionais são encarregadas de extrair automaticamente padrões relevantes das imagens por meio de filtros aprendidos durante o treinamento. Essas camadas são seguidas por camadas de *pooling*, que realizam a redução da dimensionalidade dos mapas de características, aumentando a eficiência computacional e contribuindo para a generalização do modelo (GU *et al.*, 2018).

Em tarefas de classificação de imagens, as camadas convolucionais e de *pooling* são sucedidas por camadas totalmente conectadas (*fully connected layers*), que integram as características extraídas para produzir a decisão final do modelo. No entanto, em aplicações de segmentação de imagens, essas camadas finais são substituídas por camadas convolucionais adicionais, originando as chamadas Redes Totalmente Convolucionais (*Fully Convolutional Networks* – FCNs), que permitem a geração de mapas de saída com resolução espacial preservada (Long; Shelhamer; Darrell, 2015).

Na Figura 11 é ilustrada a arquitetura da rede VGG-16, uma das variantes clássicas de CNNs, amplamente utilizada como base para diversas aplicações de visão computacional.

Figura 11 - Arquitetura CNN VGG-16



Fonte: Adaptado de Simonyan e Zisserman, 2015.

Essa organização modular e escalável permite que as CNNs capturem informações visuais de diferentes níveis de abstração, desde bordas e texturas até formas e padrões complexos. Tal capacidade as torna ferramentas altamente eficazes para reconhecimento de padrões em superfícies metálicas, onde a precisão na análise é essencial para a garantia da conformidade dimensional e visual (Ponti *et al.*, 2025; Lecun; Bengio; Hinton, 2015).

### 2.13.2 Camadas de convolução e *pooling*

As camadas de convolução, *pooling* e as funções de ativação desempenham papéis essenciais na arquitetura das Redes Neurais Convolucionais (CNNs), apresentando alta eficácia na análise de imagens e na detecção de padrões em superfícies metálicas. As camadas convolucionais aplicam filtros (*kernels*) sobre a imagem de entrada, produzindo mapas de características que destacam informações relevantes (Zhao *et al.*, 2024).

A operação de convolução consiste no deslizamento do filtro sobre a imagem, gerando uma matriz em que cada valor representa a resposta do filtro a uma região local. Essa técnica permite a identificação de padrões fundamentais, como bordas, texturas e formas, indispensáveis para a detecção de conformidades e falhas em estampas de chapas metálicas (Goodfellow *et al.*, 2019).


Posteriormente, as camadas de *pooling* são aplicadas para reduzir a dimensionalidade dos mapas de características extraídos, diminuindo o número de parâmetros e o custo computacional, sem perder as informações essenciais. As formas mais comuns de pooling são o *Max Pooling* e o *Average Pooling* (Goodfellow *et al.*, 2019).

No *Max Pooling*, cada região (janela) da imagem é percorrida e apenas o valor máximo é mantido, enfatizando as características mais intensas. Já no *Average Pooling*, calcula-se a média dos valores na região, resultando em uma representação suavizada (Zhao *et al.*, 2024).

Ambas as técnicas contribuem para aumentar a robustez da rede frente a variações locais, como ruídos e pequenas distorções, embora o *Max Pooling* seja preferido por preservar com maior eficácia os traços mais discriminativos da imagem (Zhao *et al.*, 2024).

Na Figura 12 tem-se exemplificada a aplicação dos dois tipos de *pooling*, evidenciando como cada técnica transforma uma mesma região da imagem em representações reduzidas e distintas.

Figura 12 - Exemplo de uma aplicação de *pooling* dos tipos (a) *Max pooling* e (b) *Average pooling*



Fonte: Zhao *et al.*, 2024.

Essa redução não apenas acelera o treinamento da rede, como também contribui para a mitigação do *overfitting*, tornando o modelo menos sensível a variações sutis na imagem de entrada. Essa robustez é especialmente importante na análise de conformidade em estampas metálicas, onde pequenas variações são toleradas dentro de limites específicos do processo industrial (Goodfellow *et al.*, 2019).

### 2.13.3 Funções de ativação


As funções de ativação são elementos fundamentais nas redes neurais artificiais, pois introduzem não-linearidades que permitem ao modelo aprender representações complexas dos dados. Sem essas funções, as redes seriam limitadas a combinações lineares dos pesos, o que inviabilizaria sua capacidade de resolver tarefas com alto grau de complexidade (Zhao *et al.*, 2024).

Atualmente, as funções de ativação mais amplamente empregadas incluem a ReLU e suas variantes, devido à sua simplicidade computacional e capacidade de mitigar o problema do desaparecimento do gradiente (*vanishing gradient*), acelerando o treinamento de redes profundas (Zhao *et al.*, 2024).

Funções mais antigas, como a *sigmoid* e a *tanh*, ainda são aplicadas em contextos específicos. A *sigmoid* é comum em classificações binárias, embora sofra com saturação em valores extremos e não seja centrada em zero, dificultando a propagação dos gradientes (Maas; Hannun; Ng, 2013).

Já a tangente hiperbólica (*tanh*), por ser centrada em zero, melhora o fluxo de informações, mas continua vulnerável ao desaparecimento do gradiente, especialmente em redes profundas (Zhao *et al.*, 2024). Na Figura 13 são apresentadas as curvas típicas das funções de ativação *sigmoid* e tangente hiperbólica sobrepostas.

Figura 13 - Curvas típicas das funções de ativação *Sigmoid* e Tangente hiperbólica (*tanh*)




Fonte: Zhao *et al.*, 2024.

A função ReLU tornou-se amplamente utilizada em redes neurais convolucionais modernas devido à sua simplicidade computacional e à eficiência no processo de treinamento. Sua equação é função linear  $x$  com saída nula para entradas negativas, o que elimina a saturação observada em funções como a *sigmoid* e a *tanh*, além de contribuir para uma convergência mais rápida do modelo (Zhao *et al.*, 2024).


No entanto, a ReLU apresenta como limitação o fenômeno conhecido como “neurônios mortos” (*dead neurons*), situação em que valores negativos da entrada resultam em gradientes nulos, impedindo a atualização dos pesos durante o treinamento (Maas; Hannun; Ng, 2013). A Figura 14 ilustra o gráfico da função ReLU.

Figura 14 - Representação gráfica da função de ativação ReLU



Fonte: Zhao *et al.*, 2024.


Para mitigar as limitações associadas à ReLU, especialmente o problema dos “neurônios mortos”, diversas variações foram propostas. Entre elas, destaca-se a *Leaky ReLU*, que modifica a função original ao permitir um pequeno coeficiente negativo para valores de entrada inferiores a zero. Essa abordagem assegura a propagação de gradientes mesmo em regiões negativas, reduzindo a inatividade de neurônios durante o treinamento (Zhao *et al.*, 2024). A Figura 15 apresenta a curva típica da função *Leaky ReLU*.

Figura 15 - Representação gráfica da função de ativação *Leaky ReLU*

Fonte: Zhao *et al.*, 2024.

A função *Softmax* é comumente empregada na camada de saída de classificadores multiclasse, pois converte os valores de ativação em uma distribuição de probabilidades cujos elementos somam exatamente 1. Essa característica é fundamental para problemas de classificação que envolvem múltiplas categorias, permitindo interpretar as saídas da rede como probabilidades de pertencimento a cada classe (Zhao *et al.*, 2024).

Na Figura 16 é possível ver o gráfico típico da função *Softmax*, ilustrando sua capacidade de realçar a classe com maior probabilidade.

Figura 16 - Curva característica da função *Softmax*

Fonte: Zhao *et al.*, 2024.

A escolha adequada da função de ativação impacta diretamente o desempenho do modelo, influenciando tanto a estabilidade durante o treinamento quanto a capacidade da rede de generalizar padrões complexos (Ramachandran; Zoph; Le, 2017).

## 2.13.4 Regularização e Otimização


### 2.13.4.1 Normalização em *batch*

A normalização em *batch* (*batch normalization*) é uma técnica amplamente utilizada para otimizar o treinamento e melhorar o desempenho de modelos de aprendizado profundo, sobretudo em tarefas desafiadoras como a análise da conformidade de padrões em peças estampadas de chapas metálicas (Yang *et al.*, 2020).

Durante o treinamento de redes neurais profundas, é comum enfrentar dificuldades relacionadas à estabilidade e à eficiência da otimização. Nesse cenário, o algoritmo de gradiente descendente se destaca como uma das estratégias mais utilizadas. Sua função é minimizar uma função objetivo por meio da atualização iterativa dos parâmetros da rede, ajustando-os na direção oposta ao gradiente calculado (Ioffe; Szegedy, 2015).

A Figura 17 ilustra esse processo: a partir de um ponto inicial aleatório, o gradiente da função é computado, e os parâmetros do modelo são atualizados continuamente até que a função objetivo atinja um valor mínimo ou uma variação considerada aceitável.

Figura 17 - Algoritmo de gradiente descendente




Fonte: Adaptado de Zhao *et al.*, 2024.

A Equação 1 representa esse processo de otimização. Nela,  $\theta$  é o parâmetro a ser ajustado,  $J(\theta)$  é a função objetivo, e  $\alpha$  corresponde à taxa de aprendizado (*learning rate*), que determina o tamanho do passo dado em cada iteração na direção oposta ao gradiente. Essa equação sintetiza o princípio fundamental do gradiente descendente: mover-se progressivamente em direção ao mínimo da função, ajustando os parâmetros do modelo a cada ciclo de treinamento (Xiao *et al.*, 2022).

$$\theta = \theta - \alpha \frac{\delta J(\theta)}{\delta(\theta)} \quad (1)$$

A escolha da taxa de aprendizado ( $\alpha$ ) é um fator determinante para o sucesso do treinamento. Como ilustrado na Figura 18, valores muito pequenos tornam a convergência extremamente lenta, exigindo um número elevado de iterações. Por outro lado, taxas muito altas podem fazer o algoritmo ultrapassar o ponto de mínimo ou até mesmo impedir que ele seja encontrado, resultando em instabilidade no processo de otimização (Zhao *et al.*, 2024).

Figura 18 - Algoritmos de gradiente descendente com passos de aprendizado (a) excessivamente pequenos ou (b) grandes




Fonte: Adaptado de Zhao *et al.*, 2024.

Além da escolha da taxa de aprendizado, o algoritmo de gradiente descendente também pode enfrentar dificuldades quando a função objetivo apresenta terrenos irregulares, como depressões, cristas ou planaltos (Xiao *et al.*, 2022).

A Figura 19 ilustra dois desafios comuns: no primeiro caso, o algoritmo converge para um mínimo local, deixando de alcançar o mínimo global; no segundo, a presença de regiões planas pode tornar o processo extremamente lento, dificultando a convergência mesmo com um número elevado de iterações (Zhao *et al.*, 2024).

Figura 19 - Dois principais desafios do gradiente descendente



Fonte: Adaptado de Zhao *et al.*, 2024.

Para mitigar essas limitações, uma das soluções mais eficazes é a *Batch Normalization* (BN), proposta por Ioffe e Szegedy em 2015. Essa técnica atua diretamente nas ativações internas da rede — ou seja, nos valores de saída de cada camada — normalizando-os para que tenham média zero e variância unitária. Esse processo é realizado em tempo real durante o treinamento, com base nas estatísticas de cada *mini-batch*.

A aplicação da BN traz melhorias significativas à estabilidade do treinamento, reduzindo problemas clássicos como o desvanecimento (*vanishing*) e a explosão de gradientes (*exploding gradients*). Ao suavizar a distribuição das ativações, ela facilita a propagação dos gradientes, acelera a convergência e permite o uso de taxas de aprendizado mais altas sem comprometer a performance do modelo (Ioffe; Szegedy, 2015).

Outro ponto positivo da *Batch Normalization* é sua atuação como uma forma indireta de regularização, ajudando a reduzir a dependência de técnicas como o *dropout*. Além disso, ela melhora a capacidade de generalização do modelo, tornando a rede mais adaptável a variações nos dados de entrada e contribuindo

para evitar a chamada "morte dos neurônios", especialmente em redes que utilizam a função de ativação ReLU (Ioffe; Szegedy, 2015).

No contexto específico da análise de conformidade de estampas em chapas metálicas, a utilização da BN se mostra especialmente vantajosa, promovendo um treinamento mais robusto e eficiente das redes neurais convolucionais, com ganhos em precisão na detecção de não conformidades e confiabilidade nos processos automatizados de inspeção visual (Ioffe; Szegedy, 2015).

#### 2.13.4.2 Dropout

O *dropout* é uma técnica de regularização amplamente utilizada para evitar o *overfitting* em redes neurais profundas, especialmente quando se trabalha com conjuntos de dados limitados ou complexos (Otter *et al.*, 2021).


Proposto por Srivastava *et al.* (2014), o método consiste em desativar aleatoriamente uma fração dos neurônios durante cada iteração do treinamento. Isso significa que, a cada ciclo de aprendizado, diferentes subconjuntos da rede são treinados, o que força o modelo a não depender excessivamente de neurônios específicos e a desenvolver representações mais robustas e generalizáveis.

Na prática, essa desativação aleatória transforma a rede original em várias versões menores, cada uma com uma arquitetura diferente. Durante o treinamento, essas “redes reduzidas” são ajustadas com pesos mais simples e menos propensos ao sobreajuste. Ao final do treinamento, a rede completa é restaurada com pesos otimizados, que representam uma aproximação média de todas essas redes alternativas (Otter *et al.*, 2021).

A Figura 20 ilustra visualmente essa diferença: enquanto uma camada totalmente conectada mantém todas as conexões ativas durante o treinamento, uma camada com *dropout* elimina aleatoriamente algumas dessas conexões, representando a essência da técnica (Zhao *et al.*, 2024).

Além de melhorar a capacidade de generalização do modelo, o *dropout* é particularmente eficaz quando combinado com outras estratégias de regularização, como a *Batch Normalization*, formando uma abordagem complementar que equilibra estabilidade, desempenho e prevenção de *overfitting* (Partel; Kakarla; Ampatzidis, 2019).

Figura 20 – Distinção entre uma (a) camada totalmente conectada e uma (b) camada com *dropout*.



Fonte: Adaptado de Zhao *et al.*, 2024.

No contexto de inspeção visual automatizada, como na análise da conformidade de estampas metálicas, o uso de *dropout* é essencial para garantir que o modelo mantenha alta confiabilidade e precisão, mesmo diante de variações sutis nos padrões das peças analisadas.

#### 2.13.4.3 Otimizadores de Parâmetros

O processo de treinamento de redes neurais artificiais envolve a adaptação contínua dos parâmetros internos, notadamente os pesos e vieses, com o objetivo de minimizar a função de custo e, conseqüentemente, melhorar o desempenho do modelo. Esses parâmetros são ajustados com base na capacidade da rede de aprender os padrões subjacentes aos dados de entrada, de forma a produzir saídas cada vez mais próximas das respostas desejadas (Kingma; Ba, 2014).

A atualização dos parâmetros é realizada por meio de algoritmos de otimização, que operam de maneira iterativa. O princípio central desses algoritmos é conduzir os ajustes no sentido contrário ao gradiente da função de custo, ou seja, na direção da sua descida mais acentuada — técnica amplamente conhecida como descida do gradiente. A ideia é simples: a cada iteração, a rede dá pequenos passos em direção ao mínimo da função de custo, onde o erro de predição é reduzido (Kingma; Ba, 2014).

A atualização dos parâmetros  $\theta$  durante o treinamento de uma rede neural pode ser descrita matematicamente pela Equação 2.

$$\theta_t = \theta_{t-1} - \eta \nabla_{\theta} J(\theta_{t-1}; D_t) \quad (2)$$

Na Equação 2, o termo  $\theta_t$  representa os parâmetros atualizados na iteração  $t$ , enquanto  $\theta_{t-1}$  representa corresponde aos valores desses mesmos parâmetros na iteração anterior. A variável  $\eta$  denota a taxa de aprendizado, um hiperparâmetro que controla o tamanho dos passos dados na direção do gradiente, influenciando diretamente a velocidade e a estabilidade do aprendizado. Já  $\nabla J(\theta_{t-1}; D_t)$  representa o gradiente da função de custo em relação aos parâmetros  $\theta$ , calculado com base no subconjunto de dados  $D_t$  utilizado naquela iteração, sendo o responsável por indicar a direção e a magnitude do ajuste necessário nos parâmetros da rede (Kingma; Ba, 2014).

A escolha do algoritmo de otimização e a calibração adequada da taxa de aprendizado são fatores cruciais para o sucesso do treinamento. Uma taxa muito alta pode levar à instabilidade e dificultar a convergência, enquanto uma taxa muito baixa pode tornar o aprendizado excessivamente lento. Por isso, técnicas modernas incluem otimizações adaptativas que ajustam a taxa de aprendizado ao longo do treinamento, como ocorre nos algoritmos *Adam*, *RMSprop* e *Adagrad*, amplamente utilizados em redes neurais convolucionais (Kingma; Ba, 2014).

Esses otimizadores avançados incorporam mecanismos que consideram o histórico das atualizações anteriores ou adaptam a taxa de aprendizado individualmente para cada parâmetro, acelerando a convergência e melhorando a capacidade da rede de escapar de mínimos locais. Assim, a otimização eficiente dos parâmetros constitui um dos pilares do aprendizado profundo, contribuindo diretamente para a construção de modelos mais precisos, estáveis e generalizáveis (Marin *et al.*, 2020).

Uma das estratégias mais utilizadas para a otimização de parâmetros em redes neurais é o Gradiente Descendente Estocástico (SGD), que, diferentemente da descida do gradiente padrão, atualiza os parâmetros com base em subconjuntos aleatórios dos dados — os chamados mini-batches (Marin *et al.*, 2020).

Essa abordagem reduz significativamente o custo computacional por iteração e melhora a capacidade de generalização do modelo, ao introduzir variações estocásticas que funcionam como uma forma de regularização implícita. No entanto, o desempenho do SGD está diretamente condicionado à escolha adequada da taxa de aprendizado (Yang *et al.*, 2020).

Valores excessivamente altos podem causar oscilações abruptas ou até a divergência do processo de treinamento, enquanto taxas muito baixas resultam em

uma convergência lenta, podendo levar o modelo a se estabilizar em mínimos locais indesejados (Kingma; Ba, 2014).

Para contornar essas limitações, variantes como o SGD com momentum foram desenvolvidas. Nessa abordagem, além do gradiente atual, considera-se uma fração do gradiente acumulado das iterações anteriores, o que introduz uma espécie de inércia ao processo de atualização dos parâmetros (Kingma; Ba, 2014).

O momentum funciona como um amortecedor que suaviza oscilações e acelera a convergência em regiões planas da função de custo, como vales ou platôs, reduzindo o risco de travamentos em mínimos rasos e contribuindo para trajetórias de descida mais estáveis e eficazes (Zhang; Ramaswamy; Agarwal, 2020).

#### 2.13.4.4 Otimizadores com Taxa de Aprendizado Adaptativa

A introdução de otimizadores com taxa de aprendizado adaptativa representa um avanço significativo em relação aos métodos tradicionais de atualização de pesos em redes neurais, ao permitir que a taxa de aprendizado seja ajustada dinamicamente durante o treinamento. Essa capacidade adaptativa visa superar limitações inerentes a algoritmos com taxa fixa, como a tendência ao *overfitting*, a lentidão na convergência ou a instabilidade em regiões com gradientes ruidosos ou mal condicionados (Kingma; Ba, 2014).

Ao contrário das abordagens convencionais, os métodos adaptativos calculam uma taxa de atualização específica para cada parâmetro com base na frequência e na magnitude dos gradientes acumulados ao longo das iterações anteriores. Isso proporciona um ajuste mais sensível e eficiente, especialmente em espaços de alta dimensionalidade, onde os gradientes podem variar consideravelmente entre diferentes direções (Abdulkadirov *et al.*, 2023).

Entre os principais otimizadores que seguem essa abordagem, destacam-se o AdaGrad, que adapta a taxa de aprendizado com base na soma acumulada dos quadrados dos gradientes e é eficaz em cenários com características esparsas; o RMSProp, que introduz uma média móvel exponencial para suavizar essa soma e evitar que a taxa de aprendizado se torne excessivamente pequena; o *Adam* (*Adaptive Moment Estimation*), que combina as vantagens do momentum e do *RMSProp* ao incorporar estimativas dos momentos de primeira e segunda ordem

dos gradientes; e o *Nadam*, uma extensão do *Adam* que inclui correções de Nesterov para acelerar a convergência (Kingma; Ba, 2015; Ruder, 2016).

O *AdaGrad* foi o primeiro entre os algoritmos de otimização com taxa de aprendizado adaptativa, introduzindo um mecanismo inovador de ajuste individualizado da taxa para cada parâmetro da rede. A ideia central é acumular o histórico dos gradientes ao longo das iterações, de modo que parâmetros com atualizações frequentes passem a receber correções menores, enquanto aqueles pouco atualizados mantenham uma taxa mais elevada. Essa característica torna o *AdaGrad* especialmente útil em tarefas com entradas esparsas, como na modelagem de linguagem natural ou em classificações com atributos raros (Abdulkadirov *et al.*, 2023).

A taxa de aprendizado adaptativa no *AdaGrad* é calculada conforme a Equação 3.

$$r_t = \frac{\eta}{\sqrt{G_t + \varepsilon}}, \text{ com } G_t = \sum_{\tau=0}^t (\nabla_{\theta} J(\theta_{\tau}))^2 \quad (3)$$

Na Equação 3,  $r_t$  representa o denominador que ajusta a taxa de atualização no tempo  $t$ , enquanto  $G_t$  é a soma acumulada dos quadrados dos gradientes calculados nas iterações anteriores (Abdulkadirov *et al.*, 2023).

Apesar de sua simplicidade e da eficiência em contextos específicos, o *AdaGrad* apresenta como limitação o crescimento acumulado de  $G_t$ , que pode fazer com que a taxa de aprendizado diminua drasticamente ao longo do tempo. Essa característica prejudica a capacidade de generalização da rede em treinamentos prolongados, sendo um dos principais fatores que motivaram o surgimento de variantes como o *RMSProp* e o *Adam*, que buscam mitigar esse efeito (Abdulkadirov *et al.*, 2023).

O *RMSProp* (*Root Mean Square Propagation*) foi proposto como uma solução para uma das principais limitações do *AdaGrad*: o esgotamento progressivo da taxa de aprendizado. Para contornar esse problema, o *RMSProp* substitui o acúmulo indefinido dos gradientes pelo uso de uma média móvel exponencial dos quadrados dos gradientes, permitindo que a taxa de aprendizado permaneça em níveis mais estáveis ao longo de todo o processo de treinamento (Abdulkadirov *et al.*, 2023).

Esse ajuste contínuo evita que os passos de atualização se tornem excessivamente pequenos, mantendo a capacidade de aprendizado do modelo

mesmo após muitas iterações. Matematicamente, o cálculo da média móvel exponencial no RMSProp pode ser representado pela Equação 4 (Abdulkadirov *et al.*, 2023).

$$E(g^2)_t = \gamma E(g^2)_{t-1} + (1 - \gamma) (\nabla J(\theta_t))^2 \quad (4)$$

Na Equação 4,  $E(g^2)_t$  representa a média móvel exponencial dos quadrados dos gradientes no instante  $t$ ,  $\nabla J(\theta_t)$  é o gradiente da função de custo em relação aos parâmetros na iteração atual, e  $\gamma$  é um fator de decaimento que determina o peso dado aos gradientes passados. Esse mecanismo suaviza a variação dos gradientes, promovendo uma adaptação mais equilibrada das taxas de aprendizado ao longo do tempo (Abdulkadirov *et al.*, 2023).

O *RMSProp* tem se mostrado particularmente eficaz em ambientes não estacionários, como no aprendizado de séries temporais ou em cenários com alta variabilidade e ruído nos dados. Sua robustez também é observada em tarefas diversas, como o treinamento de redes convolucionais com imagens ou modelos preditivos baseados em dados tabulares. Ao manter o controle sobre a magnitude das atualizações, o RMSProp contribui para trajetórias de aprendizado mais estáveis, com boa capacidade de generalização e convergência mais eficiente, mesmo em problemas complexos e de difícil otimização (Abdulkadirov *et al.*, 2023).

O *Adam (Adaptive Moment Estimation)* é um dos otimizadores mais populares e eficazes no treinamento de redes neurais profundas, sendo especialmente valorizado por sua capacidade de lidar com gradientes ruidosos, esparsos e de magnitudes variáveis. Ele combina as estratégias centrais do *AdaGrad*, que ajusta a taxa de aprendizado com base no histórico dos gradientes, e do RMSProp, que suaviza a variação dos gradientes ao longo do tempo (Abdulkadirov *et al.*, 2023).

A principal inovação do *Adam* está no uso simultâneo de estimativas dos momentos de primeira ordem (a média dos gradientes) e de segunda ordem (a variância dos gradientes), além da aplicação de correções de viés, fundamentais para estabilizar as atualizações nos estágios iniciais do treinamento, quando as estimativas ainda estão distorcidas pela inicialização (Kingma; Ba, 2015). A atualização dos parâmetros no *Adam* é definida pela Equação 5.

$$\theta_t = \theta_{t-1} - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad (5)$$

Na Equação 5,  $\hat{m}_t$  é a estimativa corrigida do momento de primeira ordem (média dos gradientes), e  $\hat{v}_t$  é a estimativa corrigida do momento de segunda ordem (variância dos gradientes). O termo  $\varepsilon$  é uma constante pequena adicionada para evitar divisão por zero (Kingma; Ba, 2015).

A correção de viés em  $\hat{m}_t$  e  $\hat{v}_t$  garante que, nas primeiras iterações, quando o número de amostras ainda é pequeno, as estimativas não subrepresentem os verdadeiros valores dos momentos, assegurando maior estabilidade (Abdulkadirov *et al.*, 2023).

O *Adam* tornou-se amplamente adotado na comunidade de aprendizado profundo por sua rapidez na convergência e por ser relativamente insensível à escolha inicial da taxa de aprendizado. Seu desempenho consistente em uma variedade de tarefas, incluindo classificação de imagens no banco de dados MNIST e otimização em redes complexas como LSTMs e CNNs, evidencia sua versatilidade e eficiência, mesmo em domínios desafiadores e com grande dimensionalidade (Kingma; Ba, 2015).

O Nadam (*Nesterov-accelerated Adaptive Moment Estimation*) é uma variação do otimizador *Adam* que incorpora os benefícios do *Nesterov Momentum*, uma técnica que antecipa a direção futura do gradiente, ajustando os parâmetros não apenas com base no gradiente atual, mas também levando em conta o comportamento esperado nas próximas iterações (Abdulkadirov *et al.*, 2023).

Essa abordagem visa aumentar a velocidade de convergência, especialmente nos estágios iniciais do treinamento, promovendo um movimento mais direcionado em direção ao mínimo da função de custo. A introdução dessa antecipação no cálculo da atualização permite ao modelo ganhar impulso de forma mais controlada, reduzindo oscilações e acelerando a descida em regiões planas do espaço de otimização (Dozat, 2016). A regra de atualização dos parâmetros no *Nadam* pode ser expressa pela Equação 6.

$$\theta_t = \theta_{t-1} - \frac{\gamma \hat{m}_t + \frac{(1-\gamma) \nabla J(\theta_t)}{(1-\gamma^t)}}{\sqrt{\hat{v}_t + \varepsilon}} \quad (6)$$

A expressão adiciona uma componente antecipada ao gradiente, representando a direção estimada do passo futuro, enquanto  $\varepsilon$  é uma constante que

evita instabilidade numérica. Essa formulação promove uma atualização mais responsiva e refinada, contribuindo para trajetórias de descida mais suaves e eficientes (Dozat, 2016).

Em experimentos com conjuntos de dados como o CIFAR-10, o *Nadam* demonstrou desempenho superior ao *Adam* nos estágios iniciais de treinamento, principalmente em redes mais profundas ou com funções de custo altamente não convexas. No entanto, estudos também apontam que, embora o *Nadam* otimize a velocidade inicial de aprendizagem, seu ganho em desempenho final pode variar conforme o tipo de tarefa, nem sempre superando o *Adam* nas fases mais avançadas do treinamento (Dozat, 2016).

### 2.13.5 Funções de Perda

As funções de perda desempenham um papel central no treinamento de redes neurais, pois mensuram o erro entre as previsões do modelo e os valores reais esperados, funcionando como um guia para a atualização dos pesos. Em tarefas de classificação multiclasse, uma das abordagens mais utilizadas é a entropia cruzada categórica (*categorical cross-entropy*), especialmente quando as classes são mutuamente exclusivas. Essa função mede o grau de similaridade entre a distribuição de probabilidades prevista pela rede (geralmente após uma camada softmax) e a distribuição verdadeira representada pelos rótulos, penalizando fortemente previsões incorretas com alta confiança (Mao; Mohri; Zhong, 2023).

Para problemas de regressão, o Erro Quadrático Médio (*Mean Squared Error* – MSE) é uma escolha comum, pois calcula a média das diferenças elevadas ao quadrado entre as previsões e os valores reais, favorecendo ajustes suaves ao longo de domínios contínuos. Já no campo da classificação, a minimização da entropia cruzada substituiu, de forma prática, a perda zero-um, cuja implementação direta é inviável por sua natureza não diferenciável (Zhou *et al.*, 2023).

Quando empregada em redes neurais com camadas de saída softmax, a entropia cruzada torna-se equivalente à perda logística multinomial, que apresenta bom desempenho teórico sob condições ideais — como em modelos suficientemente expressivos e dados bem distribuídos. No entanto, na prática, restrições arquitetônicas e a necessidade de soluções computacionalmente viáveis

levam à utilização de minimizadores aproximados, para os quais não há garantias formais de ótimo desempenho em cenários não-assintóticos (Jadon, 2020).

Apesar de seu sucesso empírico e ampla adoção em aplicações de deep learning, a fundamentação teórica da entropia cruzada em contextos realistas e finitos ainda está em desenvolvimento (Zhou *et al.*, 2023).

Outras funções de perda para classificação multiclasse, como *sum-losses* e aquelas com restrições explícitas, já contam com garantias teóricas não-assintóticas consolidadas. Essa lacuna reforça a necessidade de escolher criteriosamente a função de perda com base nas características específicas do problema, da arquitetura adotada e do comportamento esperado do modelo (Jadon, 2020).

## 2.14 MÉTRICAS DE AVALIAÇÃO DE CLASSIFICAÇÃO

A avaliação de modelos de classificação é uma etapa essencial na construção de sistemas de visão computacional confiáveis, especialmente em aplicações industriais que exigem alta precisão, como a análise de conformidade de estampas em chapas metálicas. Para medir o desempenho desses modelos, diferentes métricas são utilizadas, cada uma oferecendo uma perspectiva complementar sobre a eficácia do classificador (Kearns; Roth, 2020).

A acurácia é uma métrica básica que indica a proporção de classificações corretas em relação ao total de amostras analisadas. Apesar de sua simplicidade, ela pode ser enganosa em conjuntos de dados desbalanceados, onde a maioria das amostras pertence a uma única classe. Nesses casos, métricas adicionais tornam-se fundamentais para uma avaliação mais robusta (Kearns; Roth, 2020).

O *F1-score*, por exemplo, combina duas métricas importantes: precisão e revocação (ou *recall*). A precisão calcula quantas das previsões positivas realmente pertencem à classe positiva, enquanto a revocação mede a capacidade do modelo em identificar todos os exemplos relevantes. O *F1-score* é especialmente útil em contextos industriais, onde a detecção de peças defeituosas deve ser eficaz sem comprometer a identificação correta das peças em conformidade. Um alto *F1-score* indica equilíbrio entre minimizar falsos positivos (descartar peças boas) e falsos negativos (liberar peças defeituosas) (Kearns; Roth, 2020).

Outra ferramenta fundamental é a matriz de confusão, que organiza os resultados em uma tabela que mostra onde o modelo acerta e onde erra —

facilitando a identificação de padrões específicos de erro. Essa visualização permite ajustes direcionados nos parâmetros do modelo ou no conjunto de dados de treinamento (Vilela Junior *et al.*, 2022).

Além disso, a curva ROC (*Receiver Operating Characteristic*) e a AUC (Área sob a Curva) fornecem uma análise mais completa sobre o comportamento do classificador em diferentes limiares de decisão. A curva ROC traça a taxa de verdadeiros positivos contra a taxa de falsos positivos, e quanto mais próxima do canto superior esquerdo estiver a curva, melhor o desempenho do modelo. A AUC quantifica essa área e oferece um indicador numérico que resume o desempenho geral do modelo, independentemente do ponto de corte adotado (Vilela Junior *et al.*, 2022).

Em sistemas de visão computacional aplicados à indústria, a escolha e o monitoramento dessas métricas são indispensáveis para garantir a eficiência operacional, a redução de falhas e a confiabilidade na inspeção automatizada de padrões metálicos. A avaliação contínua das métricas contribui diretamente para manter a qualidade do produto final e reduzir perdas no processo produtivo (Vilela Junior *et al.*, 2022).

#### **2.14.1 Acurácia, Precisão, *Recall* e *F1-score***

No contexto da verificação de conformidade de padrões de estampa em chapas metálicas, a avaliação do desempenho dos modelos de visão computacional desempenha um papel decisivo para assegurar a eficiência e a confiabilidade dos sistemas de inspeção automatizada. Para isso, diferentes métricas são utilizadas, destacando-se entre elas a acurácia, a precisão, o *recall* e o *F1-score*. Cada uma dessas métricas oferece uma perspectiva específica sobre o comportamento do classificador, sendo fundamentais para uma análise abrangente e criteriosa (Mariano, 2021).

A acurácia é uma das métricas mais utilizadas e corresponde à razão entre o número de predições corretas — tanto das classes positivas quanto negativas — e o número total de amostras avaliadas (Dinga *et al.*, 2019). Essa métrica oferece uma visão geral da capacidade do modelo em classificar corretamente os dados. Sua formulação matemática é apresentada na Equação 7:

$$Acurácia = \frac{TP + TN}{TP + FP + TN + FN} \quad (7)$$

Na Equação 7, TP (*True Positives*) são os verdadeiros positivos, TN (*True Negatives*) os verdadeiros negativos, FP (*False Positives*) os falsos positivos, e FN (*False Negatives*) os falsos negativos.

Apesar de sua simplicidade e ampla adoção, a acurácia pode ser uma métrica limitada em contextos com dados desbalanceados, nos quais a distribuição entre as classes é desigual. Nesses casos, um modelo pode apresentar alta acurácia simplesmente por favorecer a classe majoritária, mesmo sem aprender adequadamente os padrões da classe minoritária (Chicco; Jurman, 2020).

Para superar essa limitação, outras métricas são frequentemente empregadas (Kearns; Roth, 2020). A precisão (*precision*), por exemplo, mensura a proporção de amostras que foram corretamente classificadas como positivas dentre todas aquelas preditas como pertencentes à classe positiva. Essa métrica avalia o grau de confiança do modelo em suas classificações positivas e é formalizada na Equação 8.

$$Precisão = \frac{TP}{TP + FP} \quad (8)$$

Essa métrica é particularmente importante em contextos industriais, nos quais a minimização de falsos alarmes (falsos positivos) é desejável para evitar o descarte indevido de peças em conformidade (Chicco; Jurman, 2020).

Por outro lado, o *recall* — também conhecido como sensibilidade — avalia a capacidade do modelo de identificar corretamente todas as amostras que pertencem à classe positiva, ou seja, aquelas que realmente apresentam não conformidades (Alkanan; Gulzar, 2023). Trata-se da proporção de verdadeiros positivos em relação ao total de amostras que deveriam ser classificadas como positivas, conforme representado na Equação 9.

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

Ele é essencial em aplicações onde é preferível errar pelo excesso, como na identificação de defeitos críticos em peças metálicas, priorizando a redução de falsos negativos.

O *F1-score*, por sua vez, representa a média harmônica entre precisão e *recall*. Essa métrica é especialmente útil quando existe um desbalanceamento entre

classes e há a necessidade de equilibrar a penalização entre falsos positivos e falsos negativos (Li *et al.*, 2022). O *F1-score* fornece uma avaliação única e consolidada do desempenho do modelo, considerando simultaneamente sua capacidade de ser preciso e abrangente na detecção de amostras positivas. A Equação 10 expressa o cálculo dessa métrica.

$$F1\text{-score} = \frac{2 \times \text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (10)$$

Essa métrica é especialmente útil em cenários industriais marcados por desbalanceamento entre classes ou por penalizações assimétricas associadas aos erros de classificação. Nesses contextos, o *F1-score* fornece uma medida mais representativa do desempenho real do modelo do que métricas isoladas.

A aplicação integrada de acurácia, precisão, *recall* e *F1-score* permite uma avaliação abrangente do sistema de classificação, viabilizando tanto a identificação de deficiências quanto a calibração criteriosa de seus parâmetros. Dessa forma, essas métricas tornam-se ferramentas fundamentais para o desenvolvimento de modelos robustos e confiáveis, assegurando a eficiência dos processos de inspeção e o rigor no controle de qualidade da conformidade de estampas metálicas (Chicco; Jurman, 2020).

#### 2.14.2 Matriz de confusão e análise de erros

A matriz de confusão é uma ferramenta estatística fundamental na avaliação de modelos de classificação, especialmente em aplicações industriais como a inspeção automatizada de padrões de estampa em chapas metálicas. Ela permite visualizar de forma estruturada os acertos e erros do modelo, organizando as predições em quatro categorias principais: verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN) (Vilela Junior *et al.*, 2022).

Entre essas categorias, os falsos negativos merecem atenção especial. Eles ocorrem quando o sistema classifica erroneamente uma peça defeituosa como conforme, comprometendo a eficácia do controle de qualidade. Em ambientes industriais, esse tipo de erro pode permitir que produtos fora do padrão avancem na linha de produção, impactando diretamente a segurança, a funcionalidade e a

satisfação do cliente final (Vilela Junior *et al.*, 2022).

Para mitigar a ocorrência de falsos negativos, é essencial uma análise aprofundada das causas subjacentes. Estratégias como validação cruzada, testes com diferentes conjuntos de dados e inspeção visual das imagens classificadas erroneamente podem oferecer *insights* relevantes. Além disso, técnicas de pré-processamento mais refinadas — como realce de bordas, ajuste de contraste ou extração de textura — ajudam a destacar padrões sutis que poderiam ser negligenciados pela rede (Zhou *et al.*, 2017).

O impacto dos falsos negativos pode ser quantificado e monitorado por meio de métricas como *recall* (sensibilidade), que mede a capacidade do modelo de identificar corretamente todas as amostras positivas, e acurácia, que reflete a proporção total de predições corretas. A relação entre essas métricas e a matriz de confusão é essencial para ajustar hiperparâmetros e melhorar a generalização do modelo (Vilela Junior *et al.*, 2022).

A análise crítica dos erros apresentados na matriz de confusão não apenas evidencia as limitações atuais do sistema, como também orienta aprimoramentos futuros. A compreensão detalhada dos falsos negativos e de seus efeitos operacionais permite o desenvolvimento de soluções mais robustas, elevando a confiabilidade da classificação automatizada e a qualidade dos processos industriais como um todo (Dinga *et al.*, 2019).

## 2.15 REDES NEURAI CONVOLUCIONAIS PARA CLASSIFICAÇÃO DE IMAGENS

As redes neurais convolucionais (CNNs) consolidaram-se como ferramentas fundamentais na classificação de imagens devido à sua habilidade intrínseca de extrair características hierárquicas diretamente dos dados visuais. Estruturadas em múltiplas camadas sequenciais, essas redes aplicam filtros convolucionais que capturam padrões em diversas escalas e contextos, permitindo uma representação eficiente de formas, texturas e cores (Li *et al.*, 2023a).

Uma das principais vantagens das CNNs é sua capacidade de aprender automaticamente representações relevantes a partir dos dados de entrada,

eliminando a necessidade de extração manual de características (Nicolau; Coelho, 2024).

O treinamento das CNNs para tarefas de classificação baseia-se na utilização de conjuntos de dados previamente rotulados, que servem para otimizar os pesos das conexões neuronais por meio do algoritmo de retropropagação do erro. Esse processo ajusta iterativamente os parâmetros da rede, minimizando a discrepância entre as previsões geradas e os rótulos reais. Após essa fase, o modelo é capaz de generalizar o conhecimento adquirido e classificar novas imagens com elevada precisão e rapidez (Li *et al.*, 2023a).

Para melhorar a robustez dos modelos e evitar o problema do *overfitting*, técnicas complementares, como regularização e aumento de dados (*data augmentation*), são amplamente empregadas. No contexto da classificação de imagens complexas, as CNNs mostram capacidade destacada para lidar com variabilidades visuais em padrões de cor, textura e morfologia. A adoção de arquiteturas com camadas de *pooling*, *dropout* e normalização contribui para aprimorar a eficácia dos modelos mesmo diante de alta variabilidade nos dados (Zhao *et al.*, 2024).

A evolução das redes neurais convolucionais é evidenciada por arquiteturas como AlexNet, VGG e ResNet, que alcançam desempenho superior em benchmarks de visão computacional. Seu uso vai além do setor industrial, abrangendo áreas como segurança alimentar e controle de qualidade, evidenciando o potencial das CNNs na modernização de processos e na garantia de produtos mais seguros e padronizados (Saeed *et al.*, 2023).

### **2.15.1 Arquiteturas Distribuídas para Sistemas de Visão Computacional**

A complexidade crescente das aplicações modernas em visão computacional tem impulsionado a adoção de arquiteturas distribuídas inovadoras, capazes de integrar de forma harmoniosa dispositivos variados em ambientes computacionais híbridos (Liyanage *et al.*, 2021).

Essas arquiteturas combinam recursos de computação de borda (*edge computing*), computação em nuvem (*cloud computing*) e dispositivos móveis, com o propósito de superar limitações relacionadas à latência, à largura de banda e à capacidade de processamento local. Essa configuração permite a realização de

análises em tempo real, garantindo respostas rápidas e eficientes em contextos dinâmicos (Silva *et al.*, 2025).

Dentro desse panorama, a sinergia entre aplicações móveis e as tecnologias de edge e cloud computing tem transformado significativamente a captura e o processamento de dados em sistemas de visão computacional aplicados à indústria (Cui *et al.*, 2024).

A demanda crescente por modelos industriais mais eficientes, sustentáveis e baseados em dados tem impulsionado o desenvolvimento de soluções tecnológicas que integram a conectividade de dispositivos inteligentes com a capacidade computacional escalável de servidores remotos. Essa integração viabiliza diagnósticos precisos e respostas rápidas nos processos produtivos, contribuindo para o monitoramento contínuo, a redução de falhas e a tomada de decisões ágeis no ambiente fabril (Liyanage *et al.*, 2021).

#### 2.15.1.1 Aplicações Móveis e *Edge Computing*

A implementação de visão computacional em dispositivos móveis enfrenta desafios significativos decorrentes das limitações inerentes ao *hardware*, tais como capacidade reduzida de processamento, memória restrita e consumo energético elevado. Essas restrições demandam a adoção de estratégias específicas de otimização algorítmica, que possibilitem a realização de inferências com baixa latência e desempenho satisfatório em tempo quase real (Cui *et al.*, 2024).

Nesse cenário, ressalta-se a relevância do desenvolvimento de modelos compactos e da aplicação integrada de técnicas de aceleração *hardware-software*, principalmente em contextos críticos que exigem respostas imediatas, como monitoramento industrial e sistemas de segurança (Yao; Li; Chen, 2020).

A *edge computing* surge como solução complementar, ao deslocar parte do processamento para dispositivos localizados próximos à origem dos dados. Essa abordagem descentralizada viabiliza a execução das inferências diretamente no ponto de captura, proporcionando benefícios como a operação em modo offline em ambientes com conectividade limitada e a redução significativa da latência, aspectos cruciais para decisões em tempo real (Gkonis *et al.*, 2023).

Dispositivos de borda equipados com aceleradores dedicados são capazes de processar fluxos contínuos de imagens sem depender da comunicação com

servidores remotos, garantindo respostas instantâneas em ambientes como linhas de produção e espaços públicos. Paralelamente, as aplicações móveis continuam a desempenhar papel estratégico dentro dos ecossistemas híbridos, combinando portabilidade, interfaces intuitivas e processamento inicial eficiente (Tang *et al.*, 2021).

No setor industrial, por exemplo, ferramentas móveis permitem que operadores capturem imagens diretamente nas linhas de produção por meio de smartphones ou tablets. A análise dessas imagens por algoritmos de aprendizado de máquina possibilita a detecção precoce de falhas, defeitos e anomalias, favorecendo intervenções rápidas e precisas (Li; Liu; Wu, 2020; Yao; Li; Chen, 2020).

Em ambientes industriais onde a infraestrutura de comunicação pode ser limitada, a computação de borda assegura a tomada de decisões em tempo real mesmo na ausência de conexão constante com a nuvem, consolidando uma arquitetura híbrida robusta que equilibra a responsividade local com a escalabilidade do processamento remoto (Gao, *et al.* 2022).

#### 2.15.1.2 *Cloud Computing* e Integração Híbrida

A computação em nuvem oferece uma base tecnológica robusta e escalável, fundamental para o desenvolvimento e treinamento de modelos avançados de visão computacional. Por meio de ambientes com alto poder de processamento — como clusters dotados de GPUs ou TPUs — a nuvem permite a manipulação eficiente de grandes volumes de dados provenientes de fontes variadas, assegurando o suporte necessário a tarefas computacionalmente intensivas (Alouffi *et al.*, 2021).

Essa infraestrutura facilita a evolução contínua de arquiteturas profundas, otimizadas a partir de conjuntos massivos de imagens e dados sensoriais, o que resulta em melhorias substanciais na acurácia e na capacidade de generalização dos modelos preditivos (Wang *et al.*, 2023).

A interação entre os dispositivos de captura (*frontend*) e os servidores em nuvem (*backend*) é viabilizada por interfaces padronizadas de comunicação, como APIs RESTful (*Representational State Transfer*) e gRPC (*Remote Procedure Call*). Essas tecnologias asseguram interoperabilidade entre sistemas distintos, garantem a segurança na transmissão de dados e permitem o envio assíncrono de informações para processamento em lote, promovendo escalabilidade e eficiência em sistemas distribuídos (Rapôso, 2025).

A integração entre computação em borda e computação em nuvem dá origem a arquiteturas híbridas que combinam responsividade local com poder analítico centralizado. Nesse modelo, a inferência é realizada diretamente em dispositivos edge, permitindo decisões rápidas no ponto de coleta, enquanto a nuvem é responsável por funções de maior complexidade, como o retreinamento periódico dos modelos com base em dados recém-adquiridos Carrión e Prohaska (2023).

Essa abordagem possibilita a redistribuição seletiva de modelos atualizados para os dispositivos de borda, adaptando-os conforme as demandas de cada aplicação. Além de garantir a continuidade das operações mesmo diante de limitações de conectividade, a arquitetura híbrida viabiliza o processamento eficiente de grandes volumes históricos de dados, contribuindo para o aprimoramento constante dos algoritmos (Rapôso, 2025).

A computação em nuvem também exerce papel estratégico no armazenamento e na integração de dados oriundos de múltiplas fontes, ampliando as possibilidades de aplicação de técnicas avançadas de aprendizado de máquina. Essa capacidade de consolidar informações em escala favorece a atualização contínua dos modelos com dados capturados diretamente no campo, elevando o desempenho preditivo e a precisão analítica (Strebel e Tahouri, 2024).

A capacidade de adaptação dinâmica dos modelos contribui significativamente para a precisão das análises em ambientes industriais. Esses avanços não apenas impulsionam a inovação tecnológica nos processos de monitoramento e controle de qualidade, como também promovem maior eficiência produtiva, redução de desperdícios e otimização do uso de recursos (Kattenborn *et al.*, 2021).

Neste trabalho, adotou-se uma arquitetura distribuída que separa a execução do modelo de visão computacional entre a nuvem e o dispositivo móvel. O treinamento da CNN foi realizado em uma estação com GPU, e o modelo resultante foi disponibilizado por meio de uma API em nuvem (*cloud computing*). O aplicativo móvel MetalSync, executado localmente (*edge computing*), realiza a captura das imagens e se comunica com a API para obter a inferência, exibindo os resultados ao usuário. Essa abordagem combina alto desempenho com portabilidade, adequada às exigências de ambientes industriais.

### 3 MATERIAIS E MÉTODOS

Para o desenvolvimento de uma solução computacional capaz de identificar automaticamente o padrão de conformidade de estampas em peças metálicas utilizadas como fundo de roupeiro, foi adotada uma abordagem baseada em visão computacional com redes neurais convolucionais (CNN). A metodologia foi estruturada em duas etapas principais: (i) preparação e treinamento do modelo de classificação, e (ii) desenvolvimento e integração da solução em um aplicativo móvel.

Na primeira etapa, realizou-se a aquisição de imagens das peças metálicas em diferentes condições visuais, contemplando variações no padrão de estampa. As imagens foram submetidas a um processo de pré-processamento, que incluiu etapas como redimensionamento, conversão para escala de cinza e normalização, com o objetivo de padronizar a entrada para a rede neural. Em seguida, os dados foram organizados em três subconjuntos: treino, validação e teste, garantindo uma distribuição equilibrada das classes e permitindo a avaliação do desempenho do modelo em diferentes fases.

O treinamento da CNN foi conduzido com ajustes iterativos nos hiperparâmetros, incluindo taxa de aprendizagem, número de épocas e tamanho do *batch*, além do monitoramento contínuo de métricas como acurácia, precisão e *recall*. Ao final dessa etapa, selecionou-se o modelo com melhor desempenho para ser incorporado à solução final.


Na segunda etapa, com o modelo treinado e validado, foi desenvolvido um aplicativo móvel com interface gráfica intuitiva, voltado para a captura prática de imagens em ambiente industrial. O aplicativo realiza o envio das imagens para uma infraestrutura de processamento em nuvem, onde são executadas as etapas de pré-processamento e classificação por meio do modelo de CNN. O sistema, então, retorna automaticamente o diagnóstico da conformidade da estampa analisada, oferecendo suporte à automação do processo de inspeção de qualidade na linha de produção.

### 3.1 CARACTERIZAÇÃO DA PEÇA

A peça analisada neste estudo é utilizada como fundo estrutural em roupeiros metálicos, exercendo papel fundamental na estabilidade e no fechamento do móvel. Essa aplicação exige precisão dimensional, padronização e robustez mecânica, características que devem ser asseguradas ao longo de todo o processo de fabricação.

Na Figura 21, é possível observar três modelos distintos de roupeiros industriais que utilizam essa mesma peça como componente traseiro, evidenciando sua padronização e ampla aplicabilidade.

Figura 21 - Três modelos de roupeiros: (a) Coluna única, (b) Duas colunas e (c) Quatro colunas



Fonte: Adaptado de Só Aço Industrial Ltda, 2024.

A peça, fabricada em chapa de aço laminado, é produzida pela empresa Só Aço Industrial Ltda, localizada em Teresina-PI. Sua geometria é definida por projeto técnico específico, que orienta a conformação do material de modo a garantir encaixe preciso com as demais partes do móvel, facilitando a montagem e assegurando resistência estrutural.

A estampa da peça segue um padrão geométrico definido, originado no processo de corte e conformação, com função tanto funcional quanto estética. A Figura 22 ilustra uma unidade recém-fabricada da peça, logo após o processo de estampagem.

Figura 22 - Peça estampada recém fabricada



Fonte: Acervo pessoal.

Após a conformação, as peças são organizadas em lotes para armazenamento temporário antes das etapas subsequentes da linha de produção. Na Figura 23, observa-se o empilhamento ordenado de um lote de peças metálicas recém-fabricadas, prontas para expedição ou integração com outras etapas do processo fabril.

Figura 23 - Lote de peças recém fabricadas



Fonte: Acervo pessoal.

A operação de estampagem, etapa fundamental para a conformação da peça, é realizada por meio da prensa modelo CMSLP1000, ilustrada na Figura 24. Esse equipamento é fabricado pela empresa Camasi, reconhecida por sua especialização em soluções voltadas à conformação de chapas metálicas.

A máquina aplica uma força mecânica precisamente controlada, capaz de moldar a chapa conforme o desenho técnico previamente estabelecido. Esse processo garante não apenas a fidelidade ao projeto, mas também elevada repetibilidade, padronização dimensional das peças e níveis de produtividade compatíveis com as exigências da fabricação seriada, assegurando eficiência e qualidade no ambiente industrial.


Figura 24 - Prensa modelo CMSLP1000, Camasi.



Fonte: Camasi, 2025.

Em termos dimensionais, conforme ilustrado na Figura 25, a peça possui 318 mm de largura e 1850 mm de comprimento. As estampas — regiões conformadas destinadas ao encaixe — estão distribuídas longitudinalmente ao longo da chapa, com espaçamentos variando entre 430,9 mm e 433,0 mm. Essa variação é mínima, mas tecnicamente relevante, pois influencia diretamente no alinhamento correto da peça com a estrutura do roupeiro metálico.

Figura 25 - Dimensões e detalhes da peça



Fonte: Adaptado de Só Aço Industrial Ltda, 2024.

A Figura 25 também detalha as dimensões específicas das estampas. Observa-se que o espaçamento entre os encaixes é de 60 mm, e a primeira estampa encontra-se posicionada a 10 mm da borda superior da peça. Essa distância é crítica para a correta fixação e estabilidade do conjunto, sendo estabelecida uma tolerância máxima de 5% para mais ou para menos em relação a essa medida. Qualquer desvio além desse intervalo caracteriza a peça como não conforme, uma vez que compromete o encaixe preciso com os demais componentes do mobiliário metálico.

Diante da relevância dimensional da distância entre a primeira estampa e a borda superior da peça, parâmetro crítico para a aceitação ou rejeição durante a inspeção de qualidade, optou-se por concentrar a análise e o treinamento do modelo de visão computacional na região da extremidade superior da chapa. Essa decisão teve como finalidade direcionar o aprendizado do algoritmo para a identificação precisa da primeira estampa em relação à borda, uma vez que desvios nessa posição podem comprometer o encaixe adequado da peça no conjunto do roupeiro metálico.

Para isso, todas as imagens utilizadas nas etapas de treinamento, validação e teste foram previamente recortadas, de forma a contemplar exclusivamente essa área de interesse. Ao restringir a região de análise, buscou-se aumentar a eficiência do modelo na detecção de não conformidades, reduzindo ruídos visuais e aumentando a capacidade de generalização da rede neural convolucional quanto ao reconhecimento de variações críticas no posicionamento das estampas.


### 3.2 AQUISIÇÃO DO BANCO DE IMAGENS

A aquisição das imagens foi realizada nas instalações da empresa Só Aço Industrial Ltda., localizada em Teresina–PI. Para a coleta dos dados visuais, utilizou-se um smartphone equipado com câmera de 108 megapixels, garantindo alta resolução e riqueza de detalhes nas imagens capturadas — fator importante para a análise de pequenas variações no posicionamento das estampas.

Inicialmente, foram registradas imagens de peças com não conformidades no processo de estampagem, ou seja, fora da faixa de tolerância estabelecida pela empresa, totalizando 107 imagens defeituosas. Em seguida, capturaram-se 101 imagens de peças conforme o padrão de qualidade. Todas as imagens foram obtidas em condições industriais reais, buscando representar fielmente o ambiente de produção e os desafios visuais decorrentes da variabilidade das peças.

A Figura 26 representa exemplos visuais de duas peças: uma considerada fora do padrão de conformidade e outra classificada como conforme, ilustrando as diferenças visíveis no posicionamento da estampa em relação à borda superior da chapa.

Figura 26 - Amostras de peças fora e dentro padrão de conformidade



Fonte: Acervo pessoal.

Nessa Figura é possível notar uma sutil, porém significativa, diferença na distância entre a estampa e a extremidade da peça. Para que a peça seja considerada conforme, essa distância deve ser de 10 mm, admitindo-se uma tolerância de  $\pm 5\%$ . Qualquer valor que ultrapasse esse intervalo — seja inferior a 9,5 mm ou superior a 10,5 mm — caracteriza a peça como não conforme, uma vez que esse desvio compromete o encaixe adequado com os demais componentes do roupeiro metálico.

### 3.3 PRÉ-PROCESSAMENTO DAS IMAGENS


Na etapa de pré-processamento, as imagens capturadas foram inicialmente convertidas para escala de cinza, com o objetivo de padronizar a representação visual e reduzir a complexidade computacional do modelo. Essa conversão de três canais (RGB) para um único canal (tons de cinza) é uma prática comum em aplicações de visão computacional, uma vez que redes neurais convolucionais (CNNs) são mais sensíveis às formas, bordas e contornos dos objetos do que às suas cores. Além disso, essa transformação contribui para a redução do tamanho dos arquivos e para o aumento da eficiência no processamento dos dados.

Na sequência, as imagens foram redimensionadas para uma largura fixa de 300 pixels, mantendo-se a proporção original da imagem por meio do ajuste proporcional da altura. Essa estratégia foi adotada para evitar distorções geométricas, que poderiam comprometer a integridade visual dos padrões de estampa e, conseqüentemente, afetar a acurácia do modelo. No entanto, como a altura resultante variava entre as imagens após esse redimensionamento proporcional, tornou-se necessária uma etapa adicional de padronização, visando assegurar uniformidade nas dimensões de entrada da rede neural.

Para isso, estabeleceu-se que todas as imagens deveriam apresentar altura final de 180 pixels. Considerando que nenhuma das imagens alcançava essa altura naturalmente, foi aplicado um preenchimento (*padding*) com pixels de valor zero (cor preta) na região inferior das imagens, até atingir a dimensão desejada. Com isso, garantiu-se que todas as imagens utilizadas no treinamento, validação e teste do modelo apresentassem dimensões padronizadas de  $300 \times 180$  pixels, preservando ao mesmo tempo a proporção dos elementos visuais relevantes para a tarefa de

classificação. Na Figura 27 é mostrado o resultado do pré-processamento de uma imagem utilizada no treinamento.

Figura 27 - Exemplo de imagem de peça: (a) original e (b) após o pré-processamento



Fonte: Acervo pessoal.

### 3.4 COMPOSIÇÃO DAS LISTAS DE TREINO, VALIDAÇÃO E TESTE

Para a construção do modelo baseado em redes neurais convolucionais (CNN), as imagens foram organizadas em três subconjuntos distintos: treinamento, validação e teste. A divisão dos dados seguiu a proporção de aproximadamente 64% para o treinamento do modelo, 16% para validação, utilizada durante o ajuste de hiperparâmetros, e 20% para teste, etapa responsável por avaliar o desempenho final da rede sobre dados não vistos.

A alocação das imagens foi realizada de forma estratificada e balanceada, respeitando a proporção entre as duas classes de interesse: “Dentro do Padrão” (classe 0) e “Fora do Padrão” (classe 1). No caso da classe “Dentro do Padrão”, foram utilizadas 65 imagens no conjunto de treino, 15 para validação e 21 para teste, totalizando 101 imagens. Para a classe “Fora do Padrão”, foram atribuídas 68 imagens ao treino, 18 à validação e 21 ao teste, somando 107 imagens.

Dessa forma, o conjunto completo utilizado nos experimentos foi composto por 208 imagens, distribuídas em 133 para o treinamento (64%), 33 para a validação (16%) e 42 para o teste (20%). Essa distribuição foi cuidadosamente planejada para garantir representatividade e equilíbrio entre as classes, o que é essencial para evitar viés durante o treinamento e assegurar a generalização do modelo.

A Tabela 1 apresenta a distribuição detalhada das imagens entre os subconjuntos e classes, assegurando a transparência e a reprodutibilidade do processo de preparação dos dados.

Tabela 1 - Distribuição das imagens nas listas de treino, validação e teste

| <b>Classe</b>        | <b>0</b>                | <b>1</b>              |              |                     |
|----------------------|-------------------------|-----------------------|--------------|---------------------|
| <b>Classificação</b> | <b>Dentro do Padrão</b> | <b>Fora do Padrão</b> | <b>Total</b> | <b>Distribuição</b> |
| <b>Treino</b>        | 65                      | 68                    | 133          | 64%                 |
| <b>Validação</b>     | 15                      | 18                    | 33           | 16%                 |
| <b>Teste</b>         | 21                      | 21                    | 42           | 20%                 |
| <b>Total</b>         | <b>101</b>              | <b>107</b>            | <b>208</b>   | <b>100%</b>         |

Fonte: Acervo pessoal.

### 3.5 PARAMETRIZAÇÃO DO ALGORITMO

O desenvolvimento do modelo de rede neural convolucional (CNN) teve como objetivo a classificação automática de peças metálicas utilizadas como fundos de roupeiros, de acordo com a conformidade de suas estampas. O modelo foi configurado para distinguir entre duas classes: peças dentro do padrão (classe 0) e peças fora do padrão (classe 1), utilizando técnicas de visão computacional para extrair e aprender características relevantes das imagens.

O treinamento foi conduzido com um conjunto de imagens organizado em lotes de 32 amostras (*batch size*), ao longo de 15 épocas. Essa configuração buscou equilibrar a eficiência computacional com a convergência do modelo durante o processo de otimização.

A arquitetura da rede compreende três camadas convolucionais sequenciais, cada uma seguida por camadas de *MaxPooling* e *Dropout*, além de uma camada totalmente conectada (*Dense*) antes da camada de saída. Especificamente, a primeira camada convolucional aplica 512 filtros com um *kernel* de tamanho 5×5, utilizando a função de ativação ReLU (*Rectified Linear Unit*).

Para preservar as dimensões espaciais da imagem, essa camada utiliza preenchimento (*padding*) do tipo “same”. Em seguida, uma camada de *MaxPooling* com janela de 3×3 é aplicada, reduzindo a dimensionalidade dos mapas de ativação e destacando as características mais relevantes da imagem. Complementarmente, uma camada de *Dropout* com taxa de 20% foi inserida para mitigar o risco de sobreajuste (*overfitting*), promovendo maior robustez e generalização do modelo.

A segunda camada convolucional emprega 256 filtros com *kernel* de tamanho 5×5, utilizando a função de ativação ReLU. Esta camada é seguida por uma camada de *MaxPooling* com janela de 3×3 e uma camada de *Dropout* com taxa de 20%, mantendo o padrão da primeira camada para controle do sobreajuste e redução da dimensionalidade.

A terceira camada convolucional contém 128 filtros e segue a mesma sequência de ativação, *pooling* e *dropout*, consolidando a extração progressiva das características relevantes das imagens enquanto diminui a complexidade espacial dos mapas de ativação.

Após as camadas convolucionais e de *pooling*, o modelo utiliza uma camada de Flatten, responsável por converter a saída bidimensional das convoluções em um vetor unidimensional, adequado para a entrada nas camadas densas. A primeira camada densa é composta por 64 neurônios, empregando novamente a ativação ReLU para introduzir não linearidades ao modelo.

A camada de saída possui dois neurônios, correspondentes às classes “Dentro do Padrão” e “Fora do Padrão”, e utiliza a função de ativação Softmax para gerar uma distribuição probabilística sobre as categorias.

O modelo foi compilado com o otimizador *Adam*, reconhecido por sua eficiência em problemas de classificação, e a função de perda utilizada foi a *categorical\_crossentropy*. Para avaliação, foram consideradas métricas abrangentes, incluindo acurácia, precisão, *recall* e *F1-score*, que permitem uma análise detalhada do desempenho do modelo na identificação correta das peças.

Durante o processo de treinamento, os parâmetros do modelo foram ajustados iterativamente com base nos dados de treino e validação. Ao término, a avaliação final foi realizada em um conjunto de teste, onde as predições do modelo foram comparadas aos rótulos verdadeiros, possibilitando a análise da capacidade de distinção entre peças conformes e não conformes. As principais configurações e parâmetros adotados estão resumidos no Quadro 1.

Quadro 1 - Resumo Estrutural e Paramétrico da Rede Neural Convolucional

|                                         |                                                                                                                                                                                                                                                                     |
|-----------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Conjunto de dados</b>                | 208 imagens<br>Dimensões: 300 x 180 <i>pixels</i> ,<br>1 canal (Escala de cinza)                                                                                                                                                                                    |
| <b>Divisão dos Dados</b>                | Treinamento: 133 imagens<br>Validação: 33 imagens<br>Teste: 42 imagens                                                                                                                                                                                              |
| <b>Arquitetura da CNN</b>               | 3 camadas convolucionais com:<br>- 1ª camada: 512 filtros, <i>kernel</i> 5x5, ReLU, <i>padding</i> “same”;<br>- 2ª camada: 256 filtros, <i>kernel</i> 5x5, ReLU, <i>padding</i> “same”;<br>- 3ª camada: 128 filtros, <i>kernel</i> 5x5, ReLU, <i>padding</i> “same” |
| <b>Pooling e Regularização</b>          | <i>MaxPooling</i> após cada camada convolucional:<br>- <i>Pool size</i> : 3x3.<br><i>Dropout</i> após cada camada de <i>pooling</i> com uma taxa de 20%.                                                                                                            |
| <b>Camadas Densas (Fully Connected)</b> | - Camada <i>Flatten</i> para converter a saída 2D em um vetor 1D.<br>- 1ª camada densa: 64 neurônios, ReLU.<br>- Camada de saída: 2 neurônios, softmax.                                                                                                             |
| <b>Hiperparâmetros</b>                  | Épocas: 15<br>Tamanho do <i>batch</i> : 32 imagens por <i>batch</i><br>Otimização: <i>Adam</i><br>Função de Perda: <i>Categorical Crossentropy</i>                                                                                                                  |
| <b>Avaliação do Modelo</b>              | Métricas:<br>Acurácia, Precisão, <i>Recall</i> , <i>F1-score</i>                                                                                                                                                                                                    |

Fonte: Acervo pessoal.

### 3.6 MÉTRICAS DE AVALIAÇÃO

A avaliação do desempenho do modelo de rede neural convolucional (CNN) proposto foi realizada com base em métricas amplamente reconhecidas na literatura de aprendizado de máquina: acurácia, precisão, *recall* e *F1-score*. Cada uma dessas métricas oferece uma perspectiva complementar sobre a eficácia do modelo na tarefa de classificação, permitindo uma análise robusta e detalhada de seu comportamento frente ao conjunto de dados de teste.

A acurácia (Equação 7) representa a proporção de predições corretas em relação ao total de amostras avaliadas, fornecendo uma visão geral do desempenho global do modelo. No entanto, essa métrica pode ser sensível ao desequilíbrio entre

classes, tornando-se menos informativa em contextos nos quais uma classe é significativamente mais representada do que a outra.

A precisão (Equação 8) mensura a proporção de amostras corretamente classificadas como pertencentes a uma determinada classe, em relação ao total de predições atribuídas a essa mesma classe. Essa métrica indica o grau de confiabilidade do modelo ao realizar uma predição positiva e é particularmente relevante em cenários nos quais se deseja minimizar a ocorrência de falsos positivos.

O *recall* (Equação 9), por sua vez, avalia a capacidade do modelo em identificar corretamente todas as amostras que realmente pertencem a uma determinada classe. Ao medir a proporção de verdadeiros positivos em relação ao total de amostras relevantes, essa métrica torna-se essencial em situações que exigem a redução de falsos negativos, garantindo que elementos de interesse não sejam negligenciados.

Por fim, o F1-score (Equação 10) corresponde à média harmônica entre precisão e *recall*, combinando essas duas métricas em um único indicador. Trata-se de uma medida especialmente útil em cenários com desequilíbrio entre classes, pois permite avaliar simultaneamente a exatidão das predições e a capacidade de recuperação de amostras relevantes, equilibrando o controle de falsos positivos e falsos negativos.

### 3.7 APLICATIVO DE CLASSIFICAÇÃO DAS PEÇAS

#### 3.7.1 Desenvolvimento e Estrutura

O desenvolvimento do aplicativo MetalSync, destinado à classificação automatizada da conformidade de peças metálicas utilizadas como fundos de roupeiro, foi baseado em uma arquitetura descentralizada, que assegura a independência entre as camadas de interface (*frontend*) e de processamento (*backend*). Essa abordagem promove maior flexibilidade para manutenções, ampliações e futuras integrações com outras soluções industriais, além de contribuir significativamente para a escalabilidade e evolução contínua do sistema.

Para a implementação da interface do usuário, optou-se pela utilização do *framework* Flutter, devido à sua robustez no desenvolvimento de interfaces gráficas

responsivas e multiplataforma. Essa escolha proporciona consistência visual, desempenho eficiente e compatibilidade ideal com dispositivos *Android*, ambiente-alvo do sistema proposto.

A estruturação do aplicativo foi organizada com base no padrão *MaterialApp*, elemento central do *Flutter* que fornece recursos fundamentais como temas, gerenciamento de estados e navegação. Além disso, foi empregada a biblioteca *FlutterModular*, que oferece suporte à modularização de rotas e à injeção de dependências, favorecendo a separação de responsabilidades e facilitando a manutenção da base de código.

Cada módulo do aplicativo — como a tela de captura da imagem, o componente de pré-visualização da peça e o painel de exibição do resultado da classificação — foi desenvolvido de forma encapsulada, conferindo maior organização, escalabilidade e robustez ao sistema como um todo.

A separação entre as camadas de *frontend* e *backend* permite que o aplicativo *MetalSync* seja executado de forma homogênea em dispositivos móveis com diferentes versões do sistema *Android*, sem a necessidade de recompilação do código-fonte nem de reconfiguração local do modelo de aprendizado de máquina. Essa abordagem é viabilizada pela delegação integral do processamento intensivo ao servidor, concentrando a lógica de inferência e classificação em um ambiente centralizado e escalável.

No lado servidor, a API foi desenvolvida em Python 3, utilizando o *microframework Flask* para gerenciar o roteamento das requisições e a comunicação via protocolo HTTP (*Hypertext Transfer Protocol*). Para operação em ambiente de produção, emprega-se o servidor *WSGI Unicorn*, que assegura alta disponibilidade, escalabilidade e desempenho por meio do gerenciamento eficiente de múltiplos workers em paralelo, otimizando o tempo de resposta mesmo sob demanda elevada.

A arquitetura da API segue o padrão MVC (*Model-View-Controller*), adaptado ao contexto de um serviço web. Nesse modelo, o Controller é responsável por receber a imagem enviada pelo aplicativo, realizar eventuais etapas adicionais de pré-processamento, e acionar a camada *Model*, que encapsula o carregamento e a execução do modelo de rede neural convolucional (CNN) previamente treinado e otimizado para inferência. Após a classificação, o Controller estrutura a resposta em formato JSON, que é retornada ao cliente. A *View*, nesse contexto, corresponde aos endpoints REST que entregam as respostas formatadas, fornecendo ao aplicativo

todas as informações necessárias para exibição clara e objetiva dos resultados ao usuário final.

A comunicação entre o *frontend* do aplicativo MetalSync e a API em nuvem é realizada por meio de chamadas HTTP assíncronas, utilizando endpoints seguros que seguem os princípios da arquitetura RESTful. Quando o usuário realiza o envio de uma imagem por meio do formato multipart/form-data, o servidor processa a requisição e retorna uma resposta estruturada no formato JSON, contendo o resultado da classificação da peça metálica quanto à conformidade da estampa — identificando se a peça está dentro ou fora do padrão, conforme os critérios técnicos estabelecidos pela empresa Só Aço Industrial Ltda.

Com base nessa resposta, o aplicativo exibe imediatamente uma interface gráfica interativa, sobrepondo à própria fotografia da peça o resultado da classificação automatizada, de forma clara e objetiva. Esse retorno em tempo real é fundamental para a atuação eficiente dos operadores na linha de produção, permitindo decisões rápidas sobre o destino da peça, como sua liberação, retrabalho ou descarte, além de possibilitar ações corretivas imediatas no processo produtivo.

A escolha pelo *framework Flutter* foi motivada pela necessidade de desenvolver um aplicativo leve, fluido e responsivo, capaz de operar de forma eficiente mesmo em dispositivos com limitações de *hardware*, cenário comum em ambientes industriais. Adicionalmente, o *Flutter* oferece portabilidade nativa entre plataformas, viabilizando, futuramente, a expansão do sistema para iOS, aplicações web ou desktop, com o aproveitamento de uma única base de código.

A utilização da biblioteca FlutterModular reforça essa arquitetura modular, escalável e sustentável, promovendo uma clara separação de responsabilidades entre os componentes do sistema. Essa estrutura permite que cada funcionalidade — como captura de imagens, comunicação com a API, visualização de resultados e controle de estados — seja desenvolvida e testada de forma independente. Além disso, o FlutterModular provê um mecanismo robusto de injeção de dependências, essencial para gerenciar clientes HTTP, controladores de estado e provedores de autenticação, garantindo uma comunicação eficiente e segura entre o *frontend* e o *backend*.

No lado servidor, a adoção da arquitetura MVC (*Model-View-Controller*) garante uma separação clara de responsabilidades, permitindo que modificações no modelo de aprendizado de máquina sejam implementadas exclusivamente na

camada *Model*, sem a necessidade de alterações na lógica de roteamento (Controller) ou na apresentação das respostas (*View*). Essa organização modular favorece a manutenibilidade, escalabilidade e versionamento do sistema, especialmente em contextos que demandam atualizações frequentes no modelo de inferência.

A utilização do servidor WSGI Gunicorn contribui significativamente para a escalabilidade horizontal do sistema, permitindo a execução concorrente de múltiplos processos (*workers*). Esse recurso assegura baixa latência, alta disponibilidade e resposta eficiente mesmo sob elevada demanda, garantindo que o serviço MetalSync mantenha desempenho estável e confiável em ambiente de produção.

Além da otimização de desempenho, o *backend* foi projetado com suporte a logs centralizados e configuráveis, utilizando bibliotecas especializadas para o monitoramento detalhado das requisições HTTP e a identificação de gargalos ou falhas durante o processo de inferência. Esse monitoramento é essencial para o diagnóstico ágil de erros e para a análise de desempenho do modelo ao longo do tempo.

A organização em camadas bem definidas também facilita a implantação de testes automatizados. A camada *Model* pode ser avaliada de forma isolada por meio de imagens de referência, permitindo a verificação da precisão e estabilidade do modelo. Já os Controllers são submetidos a testes de integração, que simulam requisições reais e verificam o comportamento do sistema em cenários completos, assegurando a robustez e confiabilidade da aplicação.

### **3.7.2 Design da Interface e Funcionalidades**

O aplicativo MetalSync foi desenvolvido com ênfase na simplicidade, objetividade e eficiência, visando oferecer uma experiência prática e intuitiva para a classificação automatizada da conformidade de peças metálicas utilizadas como fundo de roupeiro.


Desde a tela inicial, o aplicativo apresenta uma interface clara e funcional, exibindo o histórico das análises já realizadas. As peças processadas são organizadas em formato de lista ou grade, acompanhadas de informações essenciais, como o identificador da amostra, a data da análise e o resultado da

classificação, que indica se a peça está dentro ou fora dos padrões de conformidade estabelecidos pela fábrica.

Essa estrutura contribui para o rastreamento eficiente e o gerenciamento organizado das análises realizadas, atendendo tanto usuários com perfil técnico, como engenheiros e operadores da produção, quanto profissionais da área de controle de qualidade. A flexibilidade da interface permite que o aplicativo seja utilizado de forma eficiente em diversos contextos industriais, desde o chão de fábrica até ambientes administrativos ou de inspeção técnica.

A Figura 28 ilustra a tela inicial do aplicativo MetalSync, destacando o registro das análises anteriores e o botão de ação flutuante, que permite ao usuário iniciar uma nova análise de forma imediata, otimizando o fluxo de trabalho no ambiente industrial.

Figura 28 – Tela inicial do aplicativo MetalSync



Fonte: Acervo pessoal.

No canto inferior direito da tela inicial, um botão flutuante com o ícone “+” permite ao usuário iniciar rapidamente uma nova análise. Ao ser acionado, o aplicativo apresenta duas opções de entrada de imagem: selecionar uma foto já armazenada no dispositivo ou capturar uma nova imagem utilizando a câmera do smartphone. Essa funcionalidade visa agilizar o processo de inspeção, permitindo a classificação em tempo real com base na imagem submetida.


## 4 RESULTADOS E DISCUSSÕES

### 4.1 TREINAMENTO DO MODELO

O modelo desenvolvido por meio da arquitetura de rede neural convolucional (CNN) foi submetido a um processo de treinamento ao longo de 15 épocas, utilizando os dados previamente organizados nos conjuntos de treino, validação e teste. Ao final da etapa de avaliação com o conjunto de teste, o modelo obteve acurácia de 95,24%, precisão de 98,33%, *recall* de 90,31% e um índice *F1-score* de 94,14%. Esses resultados evidenciam a eficiência e a robustez do modelo na tarefa de classificação binária das peças metálicas quanto à conformidade de suas estampas.

A Figura 29 apresenta o gráfico de evolução da função de perda (loss) ao longo das épocas de treinamento. A análise da curva demonstra um comportamento estável e convergente, com redução consistente das perdas, indicando que o modelo foi capaz de aprender as características relevantes das amostras de forma eficaz. Ao final do treinamento, o valor de perda registrado foi de 0,2 aproximadamente, refletindo um nível satisfatório de generalização frente aos dados de validação e teste.

Figura 29 - Perdas por época do treino e validação do modelo




Fonte: Acervo pessoal.

O desempenho obtido pelo modelo é compatível com aplicações em ambientes industriais, onde se exige alta confiabilidade na detecção de não conformidades, reduzindo o risco de falsas classificações e otimizando o processo de inspeção automatizada.

A Figura 30 apresenta o gráfico que ilustra a evolução da acurácia durante as épocas de treinamento do modelo. Esse gráfico complementa a análise da curva de perda, reforçando a interpretação positiva da curva de aprendizado. Observa-se que tanto a acurácia do conjunto de treinamento quanto a do conjunto de validação aumentam de forma rápida e consistente nas primeiras iterações.

Figura 30 - Acurácia por época do treino e validação do modelo



Fonte: Acervo pessoal.

A partir da sexta época, ambas as curvas se estabilizam acima de 90%, demonstrando que o modelo alcançou um patamar de desempenho elevado com baixa variabilidade entre os dados de treino e validação. Esse comportamento indica boa generalização, reduzido risco de *overfitting* e robustez na identificação dos padrões visuais de conformidade nas peças metálicas analisadas.


## 4.2 TESTE DO MODELO

Após o treinamento, o modelo foi submetido à etapa de teste com dados não vistos, a fim de avaliar sua capacidade de generalização e precisão na classificação

das peças metálicas quanto à conformidade de suas estampas. Como parte dessa avaliação, foi gerada uma matriz de confusão, que permite visualizar o desempenho do modelo na identificação correta das classes e na detecção de erros de classificação.

A Figura 31 apresenta a matriz de confusão obtida na fase de teste, na qual o valor “0” representa as peças dentro do padrão de estampa, e o valor “1” refere-se às peças fora do padrão.

A matriz fornece uma visão detalhada da distribuição entre verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos, elementos essenciais para a interpretação das métricas de desempenho como precisão, *recall* e *F1-score*. Essa análise reforça a confiabilidade do modelo na tarefa de inspeção automatizada, evidenciando sua eficácia em aplicações práticas no ambiente industrial.



Fonte: Acervo pessoal.

O desempenho do modelo foi avaliado utilizando um conjunto de 42 imagens de peças metálicas estampadas, previamente separadas para a fase de teste. Dentre essas amostras, 40 foram corretamente classificadas, resultando em uma acurácia global de 95,24%, o que evidencia a alta eficácia do modelo na tarefa de classificação binária.

Para a classe das peças dentro do padrão (classe 0), o modelo classificou corretamente 19 das 21 imagens, alcançando acurácia de 90,48%, precisão de 100%, *recall* de 90,48% e um *F1-score* de 95,00%. Esses resultados demonstram que o modelo apresenta alto desempenho na identificação de peças conformes, com capacidade de minimizar falsos positivos, ou seja, evitar classificar erroneamente uma peça fora do padrão como estando em conformidade.

Quanto à classe das peças fora do padrão (classe 1), o modelo obteve desempenho excelente, com a classificação correta das 21 imagens pertencentes a essa categoria. Contudo, ocorreram dois falsos negativos, nos quais peças conformes foram classificadas como fora do padrão. Com isso, a classe 1 obteve acurácia e precisão de 91,30%, *recall* de 100% e um *F1-score* de 95,45%, refletindo uma forte capacidade do modelo em detectar não conformidades, característica essencial para sistemas de inspeção automatizada que priorizam a eliminação de produtos defeituosos na linha de produção.

A Tabela 2 apresenta a síntese dos resultados obtidos com base na matriz de confusão, incluindo os valores de acurácia, precisão, *recall* e *F1-score* por classe, permitindo uma análise comparativa detalhada entre os desempenhos nas duas categorias avaliadas.

Tabela 2 - Resumo da acurácia, precisão, *recall* e *F1-score* por classe

| Classe       | Classificação    | Verdadeiro Positivo (VP) | Falso Positivo (FP) | Falso Negativo (FN) | Acurácia      | Precisão      | Recall        | <i>F1 score</i> |
|--------------|------------------|--------------------------|---------------------|---------------------|---------------|---------------|---------------|-----------------|
| 0            | Dentro do Padrão | 19                       | 0                   | 2                   | 90,48%        | 100,00%       | 90,48%        | 95,00%          |
| 1            | Fora do Padrão   | 21                       | 2                   | 0                   | 91,30%        | 91,30%        | 100,00%       | 95,45%          |
| <b>Total</b> |                  | <b>40</b>                | <b>2</b>            | <b>0</b>            | <b>95,24%</b> | <b>98,33%</b> | <b>90,31%</b> | <b>94,14%</b>   |

Fonte: Acervo pessoal.

#### 4.3 TESTE DO APLICATIVO


Com o aplicativo MetalSync finalizado e integrado ao *pipeline* de processamento em nuvem, foram realizados testes com o objetivo de avaliar sua funcionalidade, usabilidade e desempenho operacional. Essa etapa teve como foco verificar a estabilidade da aplicação, a fluidez da navegação, o tempo de resposta na

análise das imagens e a consistência dos resultados fornecidos.

Durante os testes práticos, foram simuladas interações reais no ambiente industrial, considerando o fluxo típico de uso por operadores e profissionais da qualidade. As etapas descritas a seguir representam o ciclo completo de utilização do MetalSync, desde a entrada da imagem até a obtenção do diagnóstico final.

O procedimento se inicia na tela principal do aplicativo, onde o usuário pode visualizar o histórico de análises anteriores. Ao selecionar o botão “+”, localizado no canto inferior direito da interface — como ilustrado na Figura 32 — o usuário é direcionado a uma tela com duas opções: importar uma imagem previamente armazenada no dispositivo (ou em serviço de nuvem conectado) ou capturar uma nova fotografia da peça diretamente com a câmera do *smartphone*.

Figura 32 – Tela inicial do aplicativo MetalSync com opções para captura ou importação de imagem da peça metálica




Fonte: Acervo pessoal.

Após a seleção ou captura da imagem, o sistema conduz o usuário a uma tela de confirmação, permitindo que a fotografia seja avaliada visualmente antes de ser enviada para análise. Essa etapa tem como objetivo garantir a qualidade da imagem submetida ao processamento, evitando erros decorrentes de enquadramento inadequado, iluminação deficiente ou foco impreciso.

A interface dessa etapa — ilustrada na Figura 33 — apresenta a imagem selecionada e disponibiliza duas opções: “Confirmar” para prosseguir com a análise ou “Refazer” para retornar à câmera ou à galeria e selecionar outra imagem. Essa funcionalidade proporciona maior controle sobre os dados de entrada, assegurando que o modelo de classificação receba imagens com qualidade suficiente para uma inferência confiável.

Figura 33 – Interface de confirmação da imagem selecionada



Fonte: Acervo pessoal.


Após a confirmação da imagem, o aplicativo solicita ao usuário a inserção de um nome identificador para a amostra, facilitando o rastreamento e a organização dos resultados no histórico. Esse campo permite que o operador atribua uma nomenclatura personalizada à peça analisada, como um código, número de lote ou local de produção.

Em seguida, o MetalSync realiza o envio da imagem para o servidor em nuvem, ativando o *pipeline* de processamento baseado em redes neurais convolucionais. Esse *pipeline* executa automaticamente as etapas de pré-processamento, segmentação e classificação da imagem, conforme os parâmetros definidos durante o desenvolvimento do modelo.

O resultado da análise é retornado em poucos segundos e exibido de forma clara na interface do aplicativo. A tipificação da peça — se está dentro ou fora do padrão de conformidade — é destacada de forma visual e textual, proporcionando uma resposta rápida e objetiva ao usuário. Além disso, todas as análises realizadas são armazenadas automaticamente no histórico da aplicação, permitindo consultas futuras, rastreabilidade e auditoria do processo.

A Figura 34 apresenta essas duas etapas finais: a tela de inserção do nome da amostra e a interface de exibição do resultado da classificação.

Figura 34 – Etapas finais do processo: (a) inserção do identificador da amostra e (b) exibição do resultado da classificação de conformidade



Fonte: Acervo pessoal.

Durante os testes de uso, o MetalSync apresentou desempenho eficiente, compatível com os objetivos estabelecidos no projeto. O aplicativo manteve estabilidade nas interações, respondeu com agilidade às solicitações e demonstrou

alta consistência entre as imagens processadas e os resultados de classificação retornados pela nuvem.

A clareza das informações exibidas, a fluidez da navegação e a precisão nas análises confirmaram a eficácia do MetalSync como ferramenta prática para a inspeção automatizada de peças metálicas, consolidando seu potencial como suporte à tomada de decisão nos processos industriais de controle de qualidade e conformidade de estampas.

#### 4.4 COMPARATIVO COM TRABALHOS RELACIONADOS

Os resultados obtidos neste trabalho superaram aqueles relatados em estudos anteriores sobre inspeção visual de superfícies metálicas com redes neurais convolucionais. Bouguettaya *et al.* (2024) avaliaram diferentes modelos pré-treinados — como ResNet50 e VGG16 — obtendo acurácia máxima de 93,81%. De forma semelhante, Pratama *et al.* (2025) propuseram uma CNN simples que atingiu 94,6% de acurácia, embora com limitações frente a ruídos industriais. Em comparação, o modelo desenvolvido neste estudo alcançou 95,24% de acurácia, 98,33% de precisão e *recall* de 100% para a classe “fora do padrão”, demonstrando maior eficiência mesmo com arquitetura enxuta.

Outro destaque é a comparação com o trabalho de Li *et al.* (2022), que utilizou RepVGG com módulo de atenção CBAM para detectar falhas em perfis de alumínio, atingindo 92,5% de precisão em um ambiente controlado. Ainda que os mecanismos de atenção tenham auxiliado na identificação das regiões defeituosas, os resultados foram inferiores aos da presente abordagem. O desempenho superior deste trabalho evidencia a eficácia de estratégias simples, quando bem ajustadas ao contexto da aplicação.

Por fim, destaca-se a relevância prática dos dados utilizados. Ao contrário de estudos baseados em imagens públicas ou ambientes controlados, este trabalho empregou imagens reais capturadas em ambiente fabril, refletindo as variabilidades do processo produtivo. Isso reforça a aplicabilidade industrial do modelo proposto, que alia alto desempenho com viabilidade de implementação em cenários reais.

O Quadro 2 apresenta uma síntese comparativa entre os principais trabalhos relacionados, destacando as abordagens adotadas, os contextos de aplicação, os tipos de defeitos analisados e os respectivos desempenhos obtidos.

Quadro 2 - Síntese do comparativo entre trabalhos relacionados

| <b>Critério</b>              | <b>Bouguettaya et al. (2024)</b>           | <b>Li et al. (2022)</b>      | <b>Pratama et al. (2025)</b>                         | <b>Modelo Proposto</b>                                 |
|------------------------------|--------------------------------------------|------------------------------|------------------------------------------------------|--------------------------------------------------------|
| <b>Arquitetura / Técnica</b> | CNNs pré-treinadas (ResNet50, VGG16, etc.) | RepVGG com atenção (CBAM)    | CNN customizada simples                              | CNN simples customizada (treinada do zero)             |
| <b>Base de Dados</b>         | Imagens públicas de aço laminado a quente  | Perfis de alumínio extrudado | Superfícies metálicas industriais (diversas classes) | Imagens reais de chapas metálicas estampadas           |
| <b>Tipo de Defeito</b>       | Diversos defeitos superficiais             | Defeitos em perfis metálicos | Riscos, furos e trincas                              | Conformidade de estampa ("padrão" ou "fora do padrão") |
| <b>Acurácia</b>              | Até 93,81%                                 | -                            | 94,6%                                                | 95,24%                                                 |
| <b>Precisão</b>              | -                                          | 92,5%                        | -                                                    | 98,33%                                                 |

Fonte: Acervo pessoal.

#### 4.5 CONTRIBUIÇÕES DO TRABALHO

As principais contribuições deste trabalho concentram-se no desenvolvimento e disponibilização do MetalSync, um aplicativo de inspeção automatizada baseado em Redes Neurais Convolucionais (CNNs) para análise da conformidade de estampas em chapas metálicas. O sistema representa um avanço no controle de qualidade industrial, ao oferecer maior precisão, padronização e eficiência em relação aos métodos manuais tradicionalmente utilizados.

Outra contribuição relevante foi o registro oficial do software MetalSync, apresentado no Anexo A, o que garante a proteção da propriedade intelectual da solução e fortalece sua aplicação prática em ambientes industriais. Complementarmente, a pesquisa resultou na submissão do artigo científico "*Analysis of Pattern Conformity in Metal Sheets Using Computer Vision*" à revista *Materials Research*, promovendo a difusão dos resultados junto à comunidade científica e consolidando o caráter acadêmico e inovador da proposta.

Destaca-se ainda a publicação do *dataset* de imagens utilizadas no estudo,

contendo 208 amostras de chapas metálicas estampadas — 107 fora do padrão e 101 em conformidade — disponível sob o DOI: 10.17632/5yjbsnm8fg.1. Esse repositório constitui uma valiosa contribuição à área de visão computacional, permitindo a replicação dos experimentos realizados e incentivando novas pesquisas voltadas ao aprimoramento de sistemas de inspeção industrial.

## 5 CONCLUSÃO

O desenvolvimento do MetalSync demonstrou a viabilidade do uso de Redes Neurais Convolucionais como ferramenta de inspeção automatizada para análise da conformidade de estampas em chapas metálicas, especificamente em fundos de roupeiros. A solução atende à necessidade industrial de padronização e confiabilidade em processos que, tradicionalmente, dependem de inspeções manuais sujeitas a falhas humanas. Os resultados obtidos reforçam o potencial da visão computacional para aumentar a precisão, a rastreabilidade e a eficiência nos sistemas de controle de qualidade.

O modelo proposto alcançou métricas satisfatórias, como acurácia, precisão e *recall*, confirmando robustez na detecção de peças não conformes. As etapas de pré-processamento e aumento de dados mostraram-se decisivas para a capacidade discriminativa da rede, garantindo desempenho consistente mesmo em um cenário industrial real, com imagens coletadas diretamente na linha de produção. Esses resultados comprovam a viabilidade técnica da abordagem para aplicações em tempo real, possibilitando sua integração em ambientes industriais que demandam agilidade e confiabilidade.

A implementação do sistema em um aplicativo móvel, com interface intuitiva e histórico de inspeções, amplia sua aplicabilidade prática e o torna alinhado à Indústria 4.0. A integração entre inteligência artificial e dispositivos móveis gera ganhos em eficiência, redução de custos e retrabalhos, consolidando o MetalSync como recurso estratégico para o setor. Em comparação com trabalhos relacionados, a solução mostrou-se competitiva e, em alguns pontos, superior, alcançando resultados expressivos mesmo com uma arquitetura enxuta treinada do zero.

Como contribuição prática, este trabalho oferece uma ferramenta acessível, padronizada e escalável para o controle de qualidade em processos industriais. No campo científico, reforça a aplicabilidade das CNNs em cenários industriais e abre caminho para novas investigações. Trabalhos futuros podem explorar a ampliação da base de dados com condições variadas de iluminação e ângulo, o uso de arquiteturas mais avançadas, como Vision Transformers, bem como a integração do MetalSync a sistemas de manufatura em nuvem e Internet das Coisas (IoT), permitindo análises em tempo real em larga escala e expandindo sua utilização para diferentes peças metálicas e setores industriais.

## REFERÊNCIAS

- ABANDA, A.; ARROYO, A.; BOTO, F.; *et al.* Combining physics-based and data-driven methods in metal stamping. **Journal of Intelligent Manufacturing**, v. 36, p. 2583–2599, abr. 2025. Disponível em: <https://link.springer.com/article/10.1007/s10845-024-02374-7>. Acesso em: 20 jun. 2025.
- ABDULKADIROV, Ruslan; LYAKHOV, Pavel; NAGORNOV, Nikolay. Survey of Optimization Algorithms in **Modern Neural Networks. Mathematics**, v. 11, n. 11, art. 2466, 2023. Disponível em: <https://www.mdpi.com/2227-7390/11/11/2466>. Acesso em: 12 mai. 2025.
- ABNT. NBR ISO 16630:2021 – **Chapas e tiras metálicas – Ensaio de estampabilidade por expansão de furo**. Rio de Janeiro: ABNT, 2021.
- ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. In: **International Conference on Engineering and Technology**, 2017, Antalya, Turkey. Anais... [S. l.]: IEEE, 2017. p. 1–6. Disponível em: <https://ieeexplore.ieee.org/document/8308186>. Acesso em: 12 mai. 2025.
- ALBUQUERQUE, M.P. & ALBUQUERQUE, M.P. 2000. Processamento de imagens: métodos e análises. Rio de Janeiro – Brasil. **Centro Brasileiro de Pesquisas Físicas MCT**, 1-12. Disponível em: <https://www.cbpf.br/cat/pdsi/pdf/ProcessamentoImagens.PDF>. Acesso em: 23 jun. 2025.
- ALKANAN, M.; GULZAR, Y. Enhanced corn seed disease classification: leveraging MobileNetV2 with feature augmentation and transfer learning. **Frontiers in Applied Mathematics and Statistics**, Lausanne, v. 9, 2023. Acesso em: <https://www.frontiersin.org/journals/applied-mathematics-and-statistics/articles/10.3389/fams.2023.1320177/full>. Acesso em: 16 mai 2025
- ALOUFFI, B.; HASNAIN, M.; ALHARBI, A.; ALOSAIMI, W.; ALYAMI, H.; AYAZ, M. A systematic literature review on cloud computing security: threats and mitigation strategies. **IEEE Access**, v. 9, p. 57792–57807, 2021. Disponível em: <https://ieeexplore.ieee.org/document/9407464>. Acesso em: 20 abr. 2025.
- ALZAROONI, A.; IQBAL, E.; KHAN, S. U.; JAVED, S.; MOYO, B.; ABDULRAHMAN, Y. Anomaly detection for industrial applications, its challenges, solutions, and future directions: a review. **arXiv**, 2025. Disponível em: <https://arxiv.org/abs/2501.11310>. Acesso em: 20 jan. 2025.
- ARNAUD, F.; LAMMA, E.; RIGUZZI, F. Vision inspection with neural networks. **Ferrara: Dipartimento di Matematica e Informatica**, University of Ferrara, 2018.

Disponível em:

[https://www.academia.edu/76146073/Vision\\_Inspection\\_with\\_Neural\\_Networks?uc-sb-sw=7019426](https://www.academia.edu/76146073/Vision_Inspection_with_Neural_Networks?uc-sb-sw=7019426). Acesso em: 16 jun. 2025.

ASHOUR, M. W.; KHALID, F.; ABDUL HALIN, A.; ABDULLAH, L. N.; DARWISH, S. H. Surface defects classification of hot-rolled steel strips using multi-directional shearlet features. **Arabian Journal for Science and Engineering**, v. 44, p.

2925–2932, 2019. Disponível em:

[https://www.researchgate.net/publication/364112055\\_Surface\\_Defects\\_Classification\\_of\\_Hot-Rolled\\_Steel\\_Strips\\_Using\\_Multi-directional\\_Shearlet\\_Features](https://www.researchgate.net/publication/364112055_Surface_Defects_Classification_of_Hot-Rolled_Steel_Strips_Using_Multi-directional_Shearlet_Features). Acesso em: 25 mar. 2025.

ASTM E18-20 — **Standard Test Methods for Rockwell Hardness of Metallic Materials**. West Conshohocken: ASTM, 2020.

\_\_\_\_\_. E8/E8M-21 — **Standard Test Methods for Tension Testing of Metallic Materials**. West Conshohocken: ASTM, 2021.

\_\_\_\_\_. E2014-99 – Standard Guide on Metallographic Laboratory Safety. **West Conshohocken: ASTM International**, 2018.

\_\_\_\_\_. E384-17 – Standard Test Method for Microindentation Hardness of Materials. **West Conshohocken: ASTM International**, 2017.

AUST, J.; PONS, D. Comparative analysis of human operators and advanced technologies in the visual inspection of aero engine blades. **Applied Sciences**, [S.l.], v. 12, n. 4, p. 2250, 2022. Disponível em:

<https://www.mdpi.com/2076-3417/12/4/2250>. Acesso em: 20 abr. 2025.

AZEVEDO, E.; CONCI, A.; LETA, F. **Computação gráfica: teoria e prática: geração de imagens** (Volume 2). [S. l.]: Alta Books, 2022. 352 p. ISBN: 978-6555208160.

BARELLI, F. **Introdução a visão computacional. Uma abordagem prática com Python e OpenCV**. 1. Ed. São Paulo: Casa do Código, 2018. ISBN:978-85-94188-57-1

BOUGUETTAYA, Abdelmalek; ZARZOUR, Hafed; MESSAADIA, Mohamed-Cherif. CNN-based hot-rolled steel strip surface defects classification: a comparative study between different pre-trained CNN models. **The International Journal of Advanced Manufacturing Technology**, v. 132, n. 1-2, p. 1–21, mar. 2024. Disponível em: [https://www.researchgate.net/publication/378872493\\_CNN-based\\_hot-rolled\\_steel\\_strip\\_surface\\_defects\\_classification\\_a\\_comparative\\_study\\_between\\_different\\_pre-trained\\_CNN\\_models](https://www.researchgate.net/publication/378872493_CNN-based_hot-rolled_steel_strip_surface_defects_classification_a_comparative_study_between_different_pre-trained_CNN_models). Acesso em: 26 jan. 2025.

CARDINALI, L. C. B.; SILVA, V. S.; POKER JUNIOR, J. H. Gerenciamento da

qualidade: implementação de melhorias em uma distribuidora de aço. **Revista de Tecnologia Aplicada (RTA)**, São Paulo, v. 11, n. 1, p. 3-20, jan./abr. 2022. ISSN 2237-3713. Disponível em: [https://www.researchgate.net/publication/364475479\\_Gerenciamento\\_da\\_qualidade\\_implementacao\\_de\\_melhorias\\_em\\_uma\\_distribuidora\\_de\\_aco](https://www.researchgate.net/publication/364475479_Gerenciamento_da_qualidade_implementacao_de_melhorias_em_uma_distribuidora_de_aco). Acesso em: 20 abr. 2025.

CARRIÓN, Diego Sanmartín; PROHASKA, Vera. Exploration of TPUs for AI applications. **arXiv preprint**, 2023. Disponível em: <https://arxiv.org/abs/2309.08918>. Acesso em: 16 jun. 2025.

CARON, Etienne J.F.R; DAUN, Kyle J.; WELLS, Mary A. Experimental heat transfer coefficient measurements during hot forming die quenching of boron steel at high temperatures. **International Journal of Heat and Mass Transfer**, v. 71, [s.n], p. 396-404, 2014. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0017931013010831>. Acesso em: 28 jan. 2025.

CHEN, R. Y.; YEUN, W. Y. D. Review of the high-temperature oxidation of iron and carbon steels in air or oxygen. **Oxidation of Metals**, v. 59, n. 5–6, p. 433–468, 2003. Disponível em: <https://link.springer.com/article/10.1023/A:1023685905159>. Acesso em: 25 mar. 2025.

CHIAVERINI V., **Tecnologia Mecânica**, 2.a ed., vol. III. São Paulo: McGraw Hill, 1995. ISBN: 0074500899

CHICCO, Davide; JURMAN, Giuseppe. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. **BMC Genomics**, [s. l.], v. 21, n. 6, 2020. Disponível em: [https://www.researchgate.net/publication/338351315\\_The\\_advantages\\_of\\_the\\_Matthews\\_correlation\\_coefficient\\_MCC\\_over\\_F1\\_score\\_and\\_accuracy\\_in\\_binary\\_classification\\_evaluation](https://www.researchgate.net/publication/338351315_The_advantages_of_the_Matthews_correlation_coefficient_MCC_over_F1_score_and_accuracy_in_binary_classification_evaluation). Acesso em: 12 mai. 2025.

COLTRE, Juliana; MARTINS, Luís Marcelo. A indústria 4.0 na gestão estratégica: desafios e oportunidades para as empresas brasileiras. **Revista Terra & Cultura: Cadernos de Ensino e Pesquisa**, [S.l.], v. 34, n. esp., p. 110-128, abr. 2019. ISSN 2596-2809. Disponível em: <http://periodicos.unifil.br/index.php/Revistatestes/article/view/1012>. Acesso em: 25 mar. 2025.

CONCI, A; AZEVEDO, E; LETA, F. R. **Computação Gráfica: Teoria e Prática**. 2. ed. CAMPUS, 2008. ISBN: 8535223290

CUI, J.; LEI, C.; XING, Z.; *et al.* Predictions of the mechanical properties and microstructure evolution of high strength steel in hot stamping. **Journal of Materials Engineering and Performance**, v. 21, p. 2244–2254, 2012. Disponível em:

[https://www.researchgate.net/publication/257712850\\_Predictions\\_of\\_the\\_Mechanical\\_Properties\\_and\\_Microstructure\\_Evolution\\_of\\_High\\_Strength\\_Steel\\_in\\_Hot\\_Stamping](https://www.researchgate.net/publication/257712850_Predictions_of_the_Mechanical_Properties_and_Microstructure_Evolution_of_High_Strength_Steel_in_Hot_Stamping). Acesso em : 16 jun. 2025.

CUI, H.; LI, Q.; WANG, H.; JIANG, Y. CloudEye: A New Paradigm of Video Analysis System for Mobile Visual Scenarios. **arXiv**, out. 2024. Disponível em: <https://arxiv.org/abs/2410.18399>. Acesso em: 25 mar. 2025;

DINGA, Richard; PENNINX, Brenda W.J.H.; VELTMAN, Dick J.; SCHMAAL, Lianne; MARQUAND, Andre F. Beyond accuracy: measures for assessing machine learning models, pitfalls and guidelines. **bioRxiv**, [s. l.], 2019. Disponível em: <https://www.biorxiv.org/content/10.1101/743138v1>. Acesso em: 16 jul. 2025.

DONG, Xingjun; ZHANG, Changsheng; WANG, Dawei; GUO, Qi; DENG, Xinrui; LI, Chenyu. Inspection of cracking in stamping parts surfaces using anomaly detection. **Engineering Applications of Artificial Intelligence**, v. 143, 110006, 2025. ISSN 0952-1976. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0952197625000065>. Acesso em: 10. jul. 2025.

DOZAT, T. Incorporating Nesterov Momentum into Adam. In: **INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS – ICLR**, 4., 2016, San Juan. Proceedings [...]. San Juan: [s.n.], 2016. p. 1–4. Disponível em: <https://openreview.net/pdf?id=OM0jvwB8Jlp57ZJjtNEZ>. Acesso em 08 jun. 2025.

FANG, X.; LUO, Q.; ZHOU, B.; LI, C.; TIAN, L. Research progress of automated visual surface defect detection for industrial metal planar materials. **Sensors**, [S.l.], v. 20, n. 18, art. 5136, 2020. DISPONÍVEL EM: <https://www.mdpi.com/1424-8220/20/18/5136>. Acesso em: 25 mar. 2025.

FELISBINO, G.; MILANEZ, A.; RIBEIRO, G. R. Desenvolvimento de uma Matriz de Corte por Estampagem para Perfil Complexo. **Revista Vincci – Periódico Científico da UniSATC**, edição especial Engenharia Mecânica, p. 80-104, 2021. Disponível em: <https://revistavincci.satc.edu.br/index.php/Revista-Vincci/article/view/203>. Acesso em: 16 jun. 2025.

FERREIRA, L. S.; JAIMES, B. R. A. Aplicação de visão computacional para automatização do processo de reconhecimento de placas de aço bruto. **Prêmio Mercosul de Ciência e Tecnologia**, n. 1, p. 193-227, 2018. Disponível em: [Desenvolvimento-de-um-estudo-e-construcao-de-um-bastaosolar-para-obtencao-de-dados-periodicos-do-solo.pdf \(researchgate.net\)](#). Acesso: 01 ago. de 2024.

GAO, G.; DONG, Y.; WANG, R.; ZHOU, X. EdgeVision: Towards Collaborative Video Analytics on Distributed Edges for Performance Maximization. **arXiv**, nov. 2022. Disponível em: <https://arxiv.org/abs/2211.03102>. Acesso em: 01 ago. 2024.

GATEA, S.; OU, H.; MCCARTNEY, G. Review on the influence of process parameters in incremental sheet forming, **International Journal of Advanced Manufacturing Technology**. vol. 87, n. 1–4, pp. 479–499, Out. 2016. Disponível em: <https://link.springer.com/article/10.1007/s00170-016-8426-6>. Acesso em: 16 jan. 2025.

GKONIS, Panagiotis; GIANNOPOULOS, Anastasios; TRAKADAS, Panagiotis; MASIP-BRUIN, Xavi; D'ANDRIA, Francesco. A survey on IoT-Edge-Cloud continuum systems: status, challenges, use cases, and open issues. **Future Internet**, v. 15, n. 12, p. 383, 2023. Disponível em: <https://www.mdpi.com/1999-5903/15/12/383>. Acesso em: 16 jun. 2025.

GONZALEZ, R .; WOODS, R . **Digital Image Processing**. [S.l.]: Pearson, 2018. ISBN 9780133356724.

GRONOSTAJSKI, Z.; PATER, Z.; MADEJ, L.; GONTARZ, A.; LISIECKI, L.; ŁUKASZEK-SOŁEK, A.; ŁUKSZA, J.; MRÓZ, S.; MUSKALSKI, Z.; MUZYKIEWICZ, W.; PIETRZYK, M.; ŚLIWA, R. E.; TOMCZAK, J.; WIEWIÓROWSKA, S.; GU. Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354–377, mar. 2018. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0031320317304120>. Acesso em: 25 mar. 2025.

GUIMARÃES, Alex Carrijo; PINHEIRO, Débora Cristina Serra; FONSECA, João Paulo da Silva; XAVIER, João Vitor Menegon. Estudo referencial bibliográfico sobre visão computacional na indústria. In: **CONGRESSO NACIONAL DE ESTUDANTES DE ENGENHARIA MECÂNICA (XXIX CONEM)**, 2023, Goiânia. Anais [...]. Goiânia: Universidade Federal de Goiás, 2023. Disponível em: <https://www.researchgate.net/publication/372334800>. Acesso em 16 jun. 2025.

HE, Zihan; LIAN, Yudong; WANG, Yulei; LU, Zhiwei. A comprehensive review of research on surface defect detection of PCBs based on machine vision. **Results in Engineering**, [S. l.], In press, Journal pre-proof, 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S259012302502506X>. Acesso em: 30 jul. 2025.

HUANG, R.; PEDOEEM, J.; CHEN, C. YOLO-LITE: a real-time object detection algorithm optimized for non-gpu computers. In: **2018 IEEE International Conference on Big Data (Big Data)**. [S.l.]: IEEE, 2018. p. 2503–2510. Disponível em: [https://www.researchgate.net/publication/328953083\\_YOLO-LITE\\_A\\_Real-Time\\_Object\\_Detection\\_Algorithm\\_Optimized\\_for\\_Non-GPU\\_Computers](https://www.researchgate.net/publication/328953083_YOLO-LITE_A_Real-Time_Object_Detection_Algorithm_Optimized_for_Non-GPU_Computers) Acesso em: 12 abr. 2025.

HUSSAIN, M. YOLO-v1 to YOLO-v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection. **Machines**, v. 11, n. 7, p.

677, 2023. Disponível em: <https://www.mdpi.com/2075-1702/11/7/677>. acesso em: 16 jun. 2025

HÜTTEN, N. *et al.* Deep learning for automated visual inspection in manufacturing. **Sensors**, [S. l.], v. 24, n. 3, 2024. MDPI. Disponível em: <https://www.mdpi.com/1424-8220/24/3/733>. Acesso em: 28 jan. 2025.

IBRAHIM, A. A. M. S.; TAPAMO, J.-R. A Survey of VisionBased Methods for Surface Defects' Detection and Classification in Steel Products. **Informatics**, v. 11, n. 2, p. 25, abr. 2024. Disponível em: <https://www.mdpi.com/2227-9709/11/2/25>. Acesso em: 28 jan. 2025.

IOFFE, Sergey; SZEGEDY, Christian. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. In: **Proceedings of the 32nd International Conference on Machine Learning (ICML-15)**, 2015. p. 448–456. Disponível em: <https://proceedings.mlr.press/v37/ioffe15.html>. Acesso em: 25 mar. 2025.

ISO 1302:2002 — **Indication of surface texture in technical product documentation**. Geneva: ISO, 2002. Disponível em: <https://www.sharificadcam.ir/uploaded/8ed0498b-0ddb-4d36-8914-03459fa70e1c.pdf>. Acesso em: 27 set. 2024.

JADON, S. A survey of loss functions for semantic segmentation. In: **IEEE CONFERENCE ON COMPUTATIONAL INTELLIGENCE IN BIOINFORMATICS AND COMPUTATIONAL BIOLOGY (CIBCB)**, 2020, Via del Mar, Chile. Proceedings [...]. Piscataway: IEEE, 2020. Disponível em: <https://arxiv.org/abs/2006.14822>. Acesso em: 16 jun. 2025.

JUNIOR, Ivar Benazzi; CAVERSAN, Elpidio Gilson. **Tecnologia de estampagem: corte e conformação**. Sorocaba: Fatec Sorocaba, Centro Paula Souza, 2023. Apostila digital. Disponível em: <https://pt.scribd.com/document/688618429/Apostila-de-Tecnologia-de-Estampagem-Revisao-Marco-2023>. Acesso em: 28 set. 2024.

KATTENBORN, T.; LEITLOFF, J.; SCHIEFER, F.; HINZ, S. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 173, p. 24-49, 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271620303488>. Acesso em 25 mar. 2025.

KEARNS, Michael; ROTH, Aaron. **The ethical algorithm: the science of socially aware algorithm design**. New York: Oxford University Press, 2020. ISBN: 9780190948207

KINGMA, Diederik P.; BA, Jimmy. Adam: A Method for Stochastic Optimization. **arXiv**

**Preprint**, 2014. Disponível em: <https://arxiv.org/abs/1412.6980>. Acesso em 18 jul. 2025.

KEELER, S. e KIRNCHI, M. Advanced High-Strength Steels Application Guidelines V6. **WorldAutoSteel, World Steel Association**: Brussels, Belgium, 2017. ISBN: 1627080058

KHEMASUWAN, Danai; SORENSEN, Jeffrey S.; COLT, Henrique. Artificial intelligence in pulmonary medicine: computer vision, predictive model and COVID-19. **European Respiratory Review**, v. 29, n. 157, Oct. 2020. Disponível em: [https://www.researchgate.net/publication/344677533\\_Artificial\\_intelligence\\_in\\_pulmonary\\_medicine\\_computer\\_vision\\_predictive\\_model\\_and\\_COVID-19](https://www.researchgate.net/publication/344677533_Artificial_intelligence_in_pulmonary_medicine_computer_vision_predictive_model_and_COVID-19). Acesso em: 25 mar. 2025.

KONOVALENKO, Ihor; MARUSCHAK, Pavlo; BREZINOVÁ, Janette; VIŇÁŠ, Ján; BREZINA, Jakub. Steel surface defect classification using deep residual neural network. **Metals**, Basel, v. 10, n. 6, p. 846, 2020. Disponível em: <https://www.mdpi.com/2075-4701/10/6/846>. Acesso em 28 jan. 2025.

LANKHORST MOULDINGS. Sistemas de armazenamento de bobinas. **Sneek**: Lankhorst Mouldings BV, 2025. 36 p. Disponível em: <http://www.coilstorage.com>. Acesso em: 16 jul. 2025.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **Nature**, Londres, v. 521, n. 7553, p. 436–444, 2015. Acesso em: [https://www.researchgate.net/publication/277411157\\_Deep\\_Learning](https://www.researchgate.net/publication/277411157_Deep_Learning). Acesso em: 18 jul. 2025.

LI, C.; CHEN, Z.; JING, W.; WU, X.; ZHAO, Y. A lightweight method for maize seed defects identification based on convolutional block attention module. **Frontiers in Plant Science**, Lausanne, v. 14, 2023a. Acesso em: <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2023.1153226/full>. Acesso em 16 mai. 2025.

LI, Z.; LIU, X.; WU, J. Mobile edge computing and its application in precision agriculture: A review. **Computers and Electronics in Agriculture**, v. 178, 2020. Disponível em: [https://www.researchgate.net/publication/356352911\\_Mobile\\_Edge\\_Computing\\_Based\\_Internet\\_of\\_Agricultural\\_Things\\_A\\_Systematic\\_Review\\_and\\_Future\\_Directions](https://www.researchgate.net/publication/356352911_Mobile_Edge_Computing_Based_Internet_of_Agricultural_Things_A_Systematic_Review_and_Future_Directions). Acesso em: 25 mar. 2025.

LI, Z.; LIU, F.; YANG, W.; PENG, S.; ZHOU, J. A survey of convolutional neural networks: analysis, applications, and prospects. **IEEE Transactions on Neural Networks and Learning Systems**, [S. l.], v. 33, n. 12, p. 6999-7019, dez. 2022. Disponível em: <https://ieeexplore.ieee.org/document/9451544>. Acesso em: 16 jun. 2025.

LI, J.; SU, Z.; GENG, J.; YIN, Y. Real-time detection of steel strip surface defects based on improved YOLO detection network. **IFAC-PapersOnLine**, v. 51, n. 21, p. 76-81, 2018. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S2405896318321001>. Acesso em: 28 jan. 2025.

LI, Wenhao; ZHANG, Haiou; WANG, Guilan; XIONG, Gang; ZHAO, Meihua; LI, Guokuan; LI, Runsheng. Deep learning based online metallic surface defect detection method for wire and arc additive manufacturing. **Robotics and Computer-Integrated Manufacturing**, [S.l.], v. 80, p. 102470, abr. 2023b. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0736584522001521>. Acesso em: 16 jul. 2025.

LI, Z.; LI, B.; NI, H.; REN, F.; LV, S.; KANG, X. An effective surface defect classification method based on RepVGG with CBAM attention mechanism (RepVGG-CBAM) for aluminum profiles. **Metals**, v. 12, n. 11, p. 1809, 2022. Disponível em: <https://www.mdpi.com/2075-4701/12/11/1809>. Acesso em 22 jul. 2025.

LIU, Y.; ZHANG, C.; DONG, X. A survey of real-time surface defect inspection methods based on deep learning. **Artificial Intelligence Review**, [S.l.], v. 56, p. 12131–12170, 2023. Disponível em: <https://dl.acm.org/doi/abs/10.1007/s10462-023-10475-7>. Acesso em: 25 mar. 2025.

LIYANAGE, M.; PORAMBAGE, P.; DING, A. Y.; KALLA, A. Driving forces for multi-access edge computing (MEC) IoT integration in 5G. **ICT Express**, [S. l.], v. 7, n. 2, p. 127-137, 2021. Disponível em: [https://www.researchgate.net/publication/351303283\\_Driving\\_forces\\_for\\_Multi-Access\\_Edge\\_Computing\\_MEC\\_IoT\\_integration\\_in\\_5G](https://www.researchgate.net/publication/351303283_Driving_forces_for_Multi-Access_Edge_Computing_MEC_IoT_integration_in_5G). Acesso em 28 jan. 2025.

LONG, Jonathan; SHELHAMER, Evan; DARRELL, Trevor. Fully convolutional networks for semantic segmentation. In: **IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR)**, 2015, Boston. Anais [...]. Piscataway: IEEE, 2015. p. 3431–3440. Disponível em: <https://ieeexplore.ieee.org/document/7298965>. Acesso em 16 jun. 2025.

LUO, Ming; YUAN, Yuan; ZHANG, Lixin. Surface defect classification of steels with a new semi-supervised learning method. **Optics & Laser Technology**, v. 131, 106439, 2020. Disponível em: [https://www.researchgate.net/publication/330897416\\_Surface\\_defect\\_classification\\_of\\_steels\\_with\\_a\\_new\\_semi-supervised\\_learning\\_method](https://www.researchgate.net/publication/330897416_Surface_defect_classification_of_steels_with_a_new_semi-supervised_learning_method). Acesso em: 25 mar. 2025.

MAACK, R. F.; TERCAN, H.; MEISEN, T. Deep learning based visual quality inspection for industrial assembly line production using normalizing flows. In: **IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL INFORMATICS (INDIN)**, 20.,

2022, Perth. Anais... [S.l.]: IEEE, 2022. p. 329–334. Disponível em: [https://www.researchgate.net/publication/366338932\\_Deep\\_Learning\\_based\\_Visual\\_Quality\\_Inspection\\_for\\_Industrial\\_Assembly\\_Line\\_Production\\_using\\_Normalizing\\_Flows](https://www.researchgate.net/publication/366338932_Deep_Learning_based_Visual_Quality_Inspection_for_Industrial_Assembly_Line_Production_using_Normalizing_Flows). Acesso em: 28 jan. 2025.

MAAS, A. L.; HANNUN, A. Y.; NG, A. Y. Rectifier Nonlinearities Improve Neural Network Acoustic Models. In: **Proceedings of the 30th International Conference on Machine Learning (ICML)**, 2013. Disponível em: [https://ai.stanford.edu/~amaas/papers/relu\\_hybrid\\_icml2013\\_final.pdf](https://ai.stanford.edu/~amaas/papers/relu_hybrid_icml2013_final.pdf). Acesso em: 25 mar. 2025.

MACHADO, T. S. S.; LEAL, P. H. A. da C.; CARDOSO, T. A. S.; BORGES, L. da S.; SANTOS, C. J. de M.; SANT'ANNA, A. M. O. Avaliação de risco e segurança no processo de fundição na indústria metalúrgica. **Revista Produção Online**, [S. l.], v. 23, n. 3, p. 5104, 2024. Disponível em: <https://www.producaoonline.org.br/rpo/article/view/5104>. Acesso em: 16 jul. 2025.

MAO, A.; MOHRI, M.; ZHONG, Y. Cross-Entropy Loss Functions: Theoretical Analysis and Applications. **Proceedings of the 40th International Conference on Machine Learning**. [S. l.]: PMLR, 2023. Disponível em: <https://arxiv.org/abs/2304.07288>. Acesso em: 28 jan. 2025.

MARIANO, D. Métricas de avaliação em machine learning: acurácia, sensibilidade, precisão, especificidade e F-score. **BIOINFO – Revista Brasileira de Bioinformática**, [S. l.], n. 1, jul. 2021. Disponível em: [https://www.researchgate.net/publication/353001655\\_Metricas\\_de\\_avaliacao\\_em\\_machine\\_learning\\_acuracia\\_sensibilidade\\_precisao\\_especificidade\\_e\\_F-score](https://www.researchgate.net/publication/353001655_Metricas_de_avaliacao_em_machine_learning_acuracia_sensibilidade_precisao_especificidade_e_F-score). Acesso em: 28 jul. 2025.

MARIN, Igor; KUZMANIC SKELIN, Andrea; GRUJIC, Tatjana. Empirical Evaluation of the Effect of Optimization and Regularization Techniques on the Generalization Performance of Deep Convolutional Neural Network. **Applied Sciences**, v. 10, n. 21, art. 7817, 2020. Disponível em: <https://www.mdpi.com/2076-3417/10/21/7817>. Acesso em: 16 jul. 2025.

MARSHALL, A. D. *Image Acquisition – Computer Vision, Models and Inspection*. In: *Machine Vision: Models, Algorithms, Applications*. Singapore: World Scientific, 2018. 456 p. ISBN 978-9810207724.

MARTINS, L.A.O; PÁDUA, F.L.C; ALMEIDA, P.E.M. Sistema baseado em rede som para inspeção visual automática de defeitos em aços laminados. **Revista da Sociedade Brasileira de Redes Neurais**, Belo Horizonte, Vol 7, n 2, p. 71-82, jan. 2009. Disponível em: [https://www.researchgate.net/publication/268326035\\_Sistema\\_Baseado\\_em\\_Rede\\_SOM\\_para\\_Inspecao\\_Visual\\_Automatica\\_de\\_Defeitos\\_em\\_Acos\\_Laminados](https://www.researchgate.net/publication/268326035_Sistema_Baseado_em_Rede_SOM_para_Inspecao_Visual_Automatica_de_Defeitos_em_Acos_Laminados). Acesso em: 13 jul. 2025.

MERY, D. Aluminum casting inspection using deep object detection methods and simulated ellipsoidal defects. **Machine Vision and Applications**, v. 32, n. 3, p. 72, 2021. Disponível em:  
[https://www.researchgate.net/publication/350924975\\_Aluminum\\_Casting\\_Inspection\\_using\\_Deep\\_Object\\_Detection\\_Methods\\_and\\_Simulated\\_Ellipsoidal\\_Defects](https://www.researchgate.net/publication/350924975_Aluminum_Casting_Inspection_using_Deep_Object_Detection_Methods_and_Simulated_Ellipsoidal_Defects).  
 Acesso em: 16 jun. 2025.

MIRANDA, M.A. *et al.* **Identificação automática de defeitos em produtos laminados por meio de inspeção visual**. 2015. Disponível em:  
<http://swge.inf.br/SBAI2015/anais/118.pdf>. Acesso em: 25 mar. 2025.

MUSLIMIN, A. M.; LUQYANA, D.; MUHAMAD, A. M.; ROSYIDI, C. Nur. Application of Quality Function Deployment (QFD) in die redesign to lowering rework of stamping parts. **International Journal of Industrial Engineering and Management**, Novi Sad, v. 14, n. 3, p. 257–270, set. 2023. Disponível em:  
<http://doi.org/10.24867/IJIEEM-2023-3-337>. Acesso em: 28 jan. 2025.

MY, Chu A. The Role of Big Data Analytics and AI in Smart Manufacturing: An Overview. In: **ADVANCES in Intelligent Systems and Computing**. [SI]: Springer, 2021. Disponível em:  
[https://www.researchgate.net/publication/348225866\\_The\\_Role\\_of\\_Big\\_Data\\_Analytics\\_and\\_AI\\_in\\_Smart\\_Manufacturing\\_An\\_Overview](https://www.researchgate.net/publication/348225866_The_Role_of_Big_Data_Analytics_and_AI_in_Smart_Manufacturing_An_Overview). Acesso em: 16 jun. 2025.

NBR ISO 2768-1:2009 — **Tolerâncias gerais** - Parte 1: Tolerâncias para dimensões lineares e angulares sem indicação individual de tolerância. Rio de Janeiro: ABNT, 2009.

\_\_\_\_\_. 9001:2015 — **Sistemas de gestão da qualidade** – Requisitos. Rio de Janeiro: ABNT, 2015.

NICOLAU, I. da S.; COELHO, S. de S. Inteligência artificial no setor elétrico: monitoramento da qualidade da energia por meio de redes neurais. **Revista FT**, v. 29, n. 140, 2024. Disponível em:  
<https://revistافت.com.br/inteligencia-artificial-no-setor-eletrico-monitoramento-da-qualidade-da-energia-por-meio-de-redes-neurais/>. Acesso em: 25 mar. 2025.

NJIKAM, A. N. S.; ZHAO, H. A novel activation function for multilayer feed-forward neural networks. **Applied Intelligence**, v. 45, n. 1, p. 75–82, 2016. Disponível em:  
[https://www.researchgate.net/publication/291813157\\_A\\_novel\\_activation\\_function\\_for\\_multilayer\\_feed-forward\\_neural\\_networks](https://www.researchgate.net/publication/291813157_A_novel_activation_function_for_multilayer_feed-forward_neural_networks). Acesso em: 28 jul. 2025.

NOSRATI, R. *et al.* Advancing industrial inspection with an automated computer vision solution for orthopedic surgical tray inspection. **Scientific Reports**, v. 15, n. 1, p. 7867, 2025. Disponível em: <https://www.nature.com/articles/s41598-025-88974-6>. Acesso em: 06 mar. 2025.

OLIVEIRA, Bruno Vicente Nunes de; MELO, Filipe Torres de. Fundamentos da visão computacional: arcabouço teórico do reconhecimento artificial de imagens e vídeos. **Revista Humanidades e Inovação**, v.10, n.17, 2020. ISSN 2358-8322. Disponível em: <https://revista.unitins.br/index.php/humanidadeseinovacao/article/view/908>. Acesso em: 16 jun. 2025.

OTTER, D. W.; MEDINA, J. R.; KALITA, J. K. A survey of the usages of deep learning for natural language processing. **IEEE Transactions on Neural Networks and Learning Systems**, v. 32, n. 2, p. 604–624, 2021. Disponível em: <https://ieeexplore.ieee.org/document/9075398>. Acesso em: 25 mar. 2025.

PARTEL, V.; KAKARLA, S. C.; AMPATZIDIS, Y. Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence. **Computers and Electronics in Agriculture**, v. 157, p. 339-350, 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169918316612>. Acesso em: 16 jun. 2025.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**. São Paulo: Cengage Learning, 2008. Ebook. ISBN 9788522128365. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788522128365>. Acesso em: 25 mar. 2025.

PENUMURU, D. P.; MUTHUSWAMY, S.; KARUMBU, P. Identification and classification of materials using machine vision and machine learning in the context of industry 4.0. **Journal of Intelligent Manufacturing**, v. 31, n. 5, p. 1229-1241, 2020. Disponível em: [https://www.researchgate.net/publication/337311173\\_Identification\\_and\\_classification\\_of\\_materials\\_using\\_machine\\_vision\\_and\\_machine\\_learning\\_in\\_the\\_context\\_of\\_industry\\_40](https://www.researchgate.net/publication/337311173_Identification_and_classification_of_materials_using_machine_vision_and_machine_learning_in_the_context_of_industry_40). Acesso em: 16 jun. 2025.

PONTI, Moacir Antonelli; COSTA, Gabriel B. Paranhos da. Como funciona o Deep Learning. In: **Tópicos em Gerenciamento de Dados e Informações**. Porto Alegre: SBC, 2017. Cap. 3, p. 63–93. Disponível em: <https://arxiv.org/abs/1806.07908>. Acesso em: 28 jan. 2025.

PRATAMA, Dhika Wahyu; ISMAIL, Muchammad; NURRAUDAH, Restu; RIFAI, Achmad Pratama; THO, Nguyen Huu. Classification of metal surface defects using convolutional neural networks (CNN). **Green Intelligent Systems and Applications**, Yogyakarta, v. 5, n. 1, p. 93–105, 2025. Disponível em: <https://tecnoscientifica.com/journal/gisa/article/view/581>. Acesso em: 26 jul. 2025.

QATTAWI, A.; MAYYAS, AHMAD; THIRUVENGADAM, H.; KUMAR, V.; DONGRI, S. AND OMAR, M. Design considerations of flat patterns analysis techniques when applied for folding 3-D sheet metal geometries, USA, 2012. Disponível em:

<https://link.springer.com/article/10.1007/s10845-012-0679-9>. Acesso em: 25 mar. 2025.

QIAO, Qi; HU, Huiying; AHMAD, Azlin; WANG, Ke. A review of metal surface defect detection technologies in industrial applications. **IEEE Access**, [S.l.], v. 13, p. 1–17, 21 fev. 2025. Disponível em:

[https://www.researchgate.net/publication/389212488\\_A\\_Review\\_of\\_Metal\\_Surface\\_Defect\\_Detection\\_Technologies\\_in\\_Industrial\\_Applications](https://www.researchgate.net/publication/389212488_A_Review_of_Metal_Surface_Defect_Detection_Technologies_in_Industrial_Applications). Acesso em 26 jul. 2025.

RAHMAN, M.; JAHAN, I.; TULE, S.; IQBAL, A.; HOSSAIN, M.; HASHEM, M. Quality assessment of broiler meat using computer vision technology. **Meat Research**, [S. l.], v. 4, n. 6, 2024. Disponível em:

<https://bmsa.info/meatresearch/home/article/view/125>. Acesso em: 16 jun. 2025.

RAMACHANDRAN, P.; ZOPH, B.; LE, Q. V. Swish: a Self-Gated Activation Function. **arXiv preprint arXiv:1710.05941**, 2017. Disponível em:

<https://arxiv.org/abs/1710.05941>. Acesso em: 28 jan. 2025.

RAPÔSO, C. F. L. Desafios e conformidade de cloud computing com a LGPD: uma revisão sistemática. **Revista Tópicos**, 2025. Disponível em:

<https://revistatopicos.com.br/artigos/desafios-e-conformidade-de-cloud-computing-com-a-lgpd-uma-revisao-sistemica>. Acesso em: 28 jul. 2025.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. In: **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. [S.l.: s.n.], 2016. p. 779–788. Disponível em:

<https://arxiv.org/pdf/1506.02640>. Acesso em 28 jul. 2025.

RIZZO, Ernandes Marcos da Silveira. Processos de decapagem, laminação a frio e recozimento de produtos planos de aço. São Paulo: Blucher, 2022. 370 p. ISBN: 9786555064544.

ROCHA, Rafael Pandolfo da; RIFFEL, Matheus Henrique; SCHAEFFER, Lirio. Evaluation of forming limit diagrams of stainless Steel AISI 304 and AISI 430.

**Desenvolvimento em Questão**, [S. l.], v. 21, n. 59, p. e14301, 2023. DOI:

10.21527/2237-6453.2023.59.14301. Disponível em:

<https://www.revistas.unijui.edu.br/index.php/desenvolvimentoemquestao/article/view/14301>. Acesso em: 25 mar. 2025.

SAEED, F.; ALDERA, S.; ALKHATIB, M.; AL-SHAMMA'A, A. A.; FARH, H. M. H. A data-driven convolutional neural network approach for power quality disturbance signal classification (DeepPQDS-FKNet). **Mathematics**, v. 11, p. 4726, 2023.

Disponível em: <https://www.mdpi.com/2227-7390/11/23/4726>. Acesso em 28 jun. 2025.

SCHAEFFER, Lirio. **Conformação mecânica**: 2. ed. Porto Alegre: Imprensa Livre, 2011. 167 p. ISBN: 8576970732.

SCHAEFFER, Lirio; CAVALER, Luiz Carlos de Cesaro. **Fundamentos da Estampagem Incremental de Chapas Aplicados ao Aço AISI 304L**. Curitiba: Appris, 2018. Editora: Appris Editora. ISBN: 8547311645.

SHÃO, S.; ZHANG, W.; ZHANG, Z. A survey on edge computing for real-time applications: challenges and solutions. **IEEE Access**, v. 8, p. 24460-24478, 2020. Disponível em: <https://ieeexplore.ieee.org/document/8973443>. Acesso em: 16 jun. 2025.

SI, Binglong; YASENGJIANG, Musha; WU, Huawei. Deep learning-based defect detection for hot-rolled strip steel. **Journal of Physics: Conference Series**, [S.l.], v. 2246, n. 1, p. 012073, abr. 2022. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-6596/2246/1/012073>. Acesso em: 16 jun. 2025.

SILVA, R. L.; CANGIOLIERI JUNIOR, O.; RUDEK, M. A road map for planning-deploying machine vision artifacts in the context of industry 4.0. **Journal of Industrial and Production Engineering**, p. 1-14, 2021. Disponível em: [https://www.researchgate.net/publication/354035675\\_A\\_road\\_map\\_for\\_planning-deploying\\_machine\\_vision\\_artifacts\\_in\\_the\\_context\\_of\\_Industry\\_40\\_first\\_page](https://www.researchgate.net/publication/354035675_A_road_map_for_planning-deploying_machine_vision_artifacts_in_the_context_of_Industry_40_first_page). Acesso em: 25 mar. 2025.

SILVA, M. V. B. da; BARBOSA, M.; QUEIROZ, A.; Dias, K. L. A 5G-Edge Architecture for Computational Offloading of Computer Vision Applications. **arXiv**, 2025. Disponível em: <https://arxiv.org/pdf/2501.04267>. Acesso em: 28 jul. 2025.

SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. In: **INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS (ICLR)**, 2015, San Diego, USA. Anais [...]. San Diego: ICLR, 2015. Disponível em: <https://arxiv.org/abs/1409.1556>. Acesso em: 16 jun. 2025.

SINGH, A. R.; BASHFORD-ROGERS, T.; DEBATTISTA, K.; HAZRA, S. Deep learning approach for automatic detection of split defects on sheet metal stamping parts. Proceedings of the Institution of Mechanical Engineers, Part B: **Journal of Engineering Manufacture**, v. 239, n. 1-2, p. 29–39, 2024. Disponível em: <https://journals.sagepub.com/doi/full/10.1177/09544054241236224>. Acesso em 28 jul. 2025.

SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. **Journal of Machine Learning Research**, v. 15, n. 56, p. 1929–1958, 2014. Disponível em: <https://jmlr.org/papers/volume15/srivastava14a/srivastava14a.pdf>. Acesso em: 16

jun. 2025.

SKARDŽIUS, Juras; GARGASAS, Justinas. Alternative real-time part quality monitoring method by using stamping force in progressive stamping process. **Journal of Manufacturing and Materials Processing**, v. 9, n. 4, art. 104, 2025. Disponível em: <https://www.mdpi.com/2504-4494/9/4/104>. Acesso 02 ago. 2025.

STREBEL, Daniel; TAHOURI, Omid. From gRPC to RESTful APIs: Expose your gRPC Services to the REST of the World. **Google Cloud Blog**, 2024. Disponível em: [https://cloud.google.com/blog/products/api-management/bridge-the-gap-between-grpc-and-rest-http-apis?utm\\_source=thejuice&utm\\_medium=content-distribution&utm\\_campaign=thejuice-distribution](https://cloud.google.com/blog/products/api-management/bridge-the-gap-between-grpc-and-rest-http-apis?utm_source=thejuice&utm_medium=content-distribution&utm_campaign=thejuice-distribution). Acesso em 28 jan. 2025.

SZELISKI, R. **Computer vision: algorithms and applications**. 2. Ed. Springer Science & Business Media, 2020. ISBN: 3030343715.

TANG, F. *et al.* Efficient deep learning model for mobile vision applications with edge computing. **Journal of Systems Architecture**, v. 114, 2021. Disponível em: [https://www.researchgate.net/publication/340123883\\_Deep\\_Learning\\_for\\_Edge\\_Computing\\_Applications\\_A\\_State-of-the-Art\\_Survey](https://www.researchgate.net/publication/340123883_Deep_Learning_for_Edge_Computing_Applications_A_State-of-the-Art_Survey). Acesso em 25 mar. 2025.

TAVARES, A. R.; RIBEIRO, H. A.; CAMPOS, H. B.; OLIVEIRA, C. S.; SILVA, R. R.; BISSACO, M. A. S.; MARTINI, S. C.; MENEGIDIO, F. B. Visão computacional na saúde: revisão de métodos e desafios educacionais para integração multidisciplinar. **Cuadernos de Educación y Desarrollo**, v. 16, n. 13, 2024. Disponível em: <https://ojs.cuadernoseducacion.com/ojs/index.php/ced/article/view/7088>. Acesso em: 16 jun. 2025.

VILELA JUNIOR, G. B.; LIMA, B. N.; PEREIRA, A. A.; RODRIGUES, M. F.; OLIVEIRA, J. R. L.; SILIO, L. F.; CARVALHO, A. S.; FERREIRA, H. R.; PASSOS, R. P. Determinação das métricas usuais a partir da matriz de confusão de classificadores multiclases em algoritmos inteligentes nas ciências do movimento humano. **Revista CPAQV- Centro de Pesquisas Avançadas em Qualidade de Vida** -, [S. l.], v. 14, n. 2, 2022. Disponível em: <https://revista.cpaqv.org/index.php/CPAQV/article/view/939/674>. Acesso em: 25 mar. 2025.

WANG, S.; XIA, J.; YE, L.; YANG, B. Automatic detection and classification of steel surface defect using deep convolutional neural networks. **Metals**, Basel, v. 11, n. 3, p. 388, 2021. Disponível em: <https://www.mdpi.com/2075-4701/11/3/388>. Acesso em: 13 abr. 2025.

WANG, Wenyan; LU, Kun; WU, Ziheng; LONG, Hongming; ZHANG, Jun; CHEN, Peng; WANG, Bing. Surface defects classification of hot rolled strip based on improved convolutional neural network. **ISIJ International**, v. 61, n. 5, p. 1579–1583, 2021. Disponível em:

[https://www.jstage.jst.go.jp/article/isijinternational/61/5/61\\_ISIJINT2020451/\\_html](https://www.jstage.jst.go.jp/article/isijinternational/61/5/61_ISIJINT2020451/_html). Acesso em: 16. jun. 2025.

WANG, Yun-Cheng; XUE, Jintang; WEI, Chengwei; KUO, C.-C. Jay. An Overview on Generative AI at Scale with Edge-Cloud Computing. **arXiv**, jun. 2023. Disponível em: <https://arxiv.org/pdf/2306.17170>. Acesso em: 25 mar. 2025.

XIAO, J.; FAN, Y.; SUN, R.; WANG, J.; LUO, Z. Stability analysis and generalization bounds of adversarial training. In: **CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS (NeurIPS)**, 36., 2022. Advances in Neural Information Processing Systems, v. 35. [S. l.]: Curran Associates, Inc., 2022. Disponível em: <https://arxiv.org/abs/2210.00960>. Acesso em: 28 jan. 2025.

XIE, Y.; DU, L.; ZHAO, J.; *et al.* Multi-objective optimization of process parameters in stamping based on an improved RBM–BPNN network and MOPSO algorithm. **Structural and Multidisciplinary Optimization, Heidelberg**, v. 64, p. 4209–4235, 2021. Disponível em: <https://www.mdpi.com/1996-1944/15/23/8350>. Acesso em: 13 jul. 2025.

XING, Junjie; JIA, Minping. A convolutional neural network-based method for workpiece surface defect detection. **Measurement**, [S.l.], v. 176, p. 109185, 2021. Disponível em: [https://www.researchgate.net/publication/349340437\\_A\\_Convolutional\\_Neural\\_Network-Based\\_Method\\_for\\_Workpiece\\_Surface\\_Defect\\_Detection](https://www.researchgate.net/publication/349340437_A_Convolutional_Neural_Network-Based_Method_for_Workpiece_Surface_Defect_Detection). Acesso em: 16 jun. 2025.

YANG, H.; ZHANG, J.; DONG, H.; INKAWHICH, N.; GARDNER, A.; TOUCHET, A.; WILKES, W.; BERRY, H.; LI, H. DVERGE: diversifying vulnerabilities for enhanced robust generation of ensembles. In: **CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS (NeurIPS)**, 34., 2020. Advances in Neural Information Processing Systems, v. 33. [S. l.]: Curran Associates, Inc., 2020. Disponível em: <https://arxiv.org/pdf/2009.14720>. Acesso em: 27 abr. 2025.

YAO, Y.; LI, Y.; CHEN, L. Edge computing for mobile vision applications: challenges and solutions. **IEEE Network**, v. 34, n. 5, p. 60-66, 2020. Disponível em: <https://ieeexplore.ieee.org/document/9174754>. Acesso em: 16 jun. 2025.

YUN J.P., SHIN W.C., KOO G., KIM M.S., LEE C., LEE S.J. Automated defect inspection system for metal surfaces based on deep learning and data augmentation. **J Manuf Syst**, 55 (2020), pp. 317-324. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S027861252030042X?via%3Di> hub. Acesso em: 25 mar. 2025.

ZAITSEV, A. I.; DAGMAN, A. I.; KOLDAEV, A. V.; STEPANOV, A. B.; *et al.* Investigation of production technology for hot rolled high strength low alloy automobile sheet steels to improve properties and quality indices at reduced cost.

**Metallurgist**, v. 66, p. 1497–1511, 2023. Disponível em:  
<https://www.springerprofessional.de/en/investigation-of-production-technology-for-hot-rolled-high-stren/25307402>. Acesso em: 25 mar. 2025.

ZENG, Li; WAN, Feng; ZHANG, Baiyun; ZHU, Xu. Automated visual inspection for precise defect detection and classification in CBN inserts. **Sensors**, [S.l.], v. 24, n. 23, p. 7824, 2024. DOI: 10.3390/s24237824. Disponível em:  
<https://www.mdpi.com/1424-8220/24/23/7824>. Acesso em: 28 jul. 2025.

ZHAO, X.; WANG, L.; ZHANG, Y.; HAN, X.; DEVECI, M.; PARMAR, M. A review of convolutional neural networks in computer vision. **Artificial Intelligence Review**, v. 57, p. 99, 2024. Disponível em:  
<https://link.springer.com/article/10.1007/s10462-024-10721-6>. Acesso em: 16 jun. 2025.

ZHENG, W. Current technologies and applications of digital image processing. **Journal of Biomedical and Sustainable Healthcare Applications**, v. 3, n. 1, 2023. Disponível em:  
<https://pdfs.semanticscholar.org/5f35/528a5568b22ccc995a60ebc078253cf01068.pdf>. Acesso em: 16 jun. 2025.:

ZHENG, X.; ZHENG, S.; KONG, Y. *et al.* Recent advances in surface defect inspection of industrial products using deep learning techniques. **International Journal of Advanced Manufacturing Technology**, [S.l.], v. 113, p. 35–58, 2021. Disponível em:  
[https://www.researchgate.net/publication/348792953\\_Recent\\_advances\\_in\\_surface\\_defect\\_inspection\\_of\\_industrial\\_products\\_using\\_deep\\_learning\\_techniques](https://www.researchgate.net/publication/348792953_Recent_advances_in_surface_defect_inspection_of_industrial_products_using_deep_learning_techniques). Acesso em: 16 jun. 2025.

ZHOU, Shiyang; CHEN, Youping; ZHANG, Dailin; XIE, Jingming; WANG, Jing. Classification of surface defects on steel sheet using convolutional neural networks. **Materials and Technologies**, Ljubljana, v. 51, n. 1, p. 123–131, 2017. Disponível em:  
[https://www.researchgate.net/publication/313896846\\_Classification\\_of\\_surface\\_defects\\_on\\_steel\\_sheet\\_using\\_convolutional\\_neural\\_networks](https://www.researchgate.net/publication/313896846_Classification_of_surface_defects_on_steel_sheet_using_convolutional_neural_networks). Acesso em: 18 abr. 2025.

ZHOU, Longfei; ZHANG, Lin; KONZ, Nicholas. Computer vision techniques in manufacturing. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 53, n. 1, p. 105–117, 2022. Disponível em:  
<https://ieeexplore.ieee.org/document/9761203>. Acesso em: 16 jun. 2025.

ZHOU, X.; LIU, X.; ZHAI, D.; JIANG, J.; JI, X. Asymmetric loss functions for noise-tolerant learning: theory and applications. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 45, n. 7, p. 8094–8109, jul. 2023. Disponível em  
[https://www.researchgate.net/publication/368348772\\_Asymmetric\\_Loss\\_Functions\\_f](https://www.researchgate.net/publication/368348772_Asymmetric_Loss_Functions_f)

or\_Noise-Tolerant\_Learning\_Theory\_and\_Applications. Acesso em: 16 jun. 2025.