

**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**

LUCILEIDE AQUINO DO NASCIMENTO

**CLASSIFICAÇÃO DE TELHAS CERÂMICAS TIPO ROMANA NO PROCESSO DE
FABRICAÇÃO INDUSTRIAL COM REDES NEURAIAS CONVOLUCIONAIS.**

TERESINA

2025

LUCILEIDE AQUINO DO NASCIMENTO

**CLASSIFICAÇÃO DE TELHAS CERÂMICAS TIPO ROMANA NO PROCESSO DE
FABRICAÇÃO INDUSTRIAL COM 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: Processamento e Caracterização de Materiais

Linha de Pesquisa: Computação Aplicada

Orientador: Prof. Dr. Otílio Paulo da Silva Neto

TERESINA

2025

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

Nascimento, Lucileide Aquino do
N244c Classificação de telhas cerâmicas tipo romana no processo de fabricação industrial com redes neurais convolucionais / Lucileide Aquino do Nascimento. - 2025.
112 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. Redes neurais convolucionais. 2. Indústria 4.0. 3. Telhas cerâmicas. 4. Inspiração automatizada. I. Título.

CDD - 620.1

Elaborado por Tanize Maria Sales CRB 3/1024

LUCILEIDE AQUINO DO NASCIMENTO

**CLASSIFICAÇÃO DE TELHAS CERÂMICAS TIPO ROMANA NO PROCESSO DE
FABRICAÇÃO INDUSTRIAL COM 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: 29/08/2025.

BANCA EXAMINADORA

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

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

Prof. Dr. Ricardo de Andrade Lira Rabelo
Universidade Federal do Piauí (UFPI)

“A persistência é o caminho do êxito”

Charles Chaplin.

AGRADECIMENTOS

A Deus, minha eterna e maior gratidão. Sua presença silenciosa, porém constante, sustentou meus passos e iluminou meus caminhos em todos os momentos desta jornada.

Registro minha especial reverência ao meu orientador, Prof. Dr. Otilio Paulo da Silva Neto, e ao meu coorientador, Prof. Dr. Gilvan Moreira Paz, pela confiança depositada em meu potencial, pela dedicação incansável e por conduzirem este projeto com sabedoria, paciência e comprometimento.

Aos professores do Programa de Pós-Graduação em Engenharia de Materiais (PPGEM), expresso minha sincera gratidão pelo conhecimento compartilhado e pela formação sólida que me proporcionaram. Aos colegas de turma, agradeço pelas valiosas trocas de experiências, pelo companheirismo e pelos momentos que enriqueceram esta trajetória acadêmica e pessoal.

À Empresa Cerâmica Barro Forte, especialmente ao Sr. Antônio Carlos Forte, manifesto meu profundo agradecimento por acreditar no valor deste projeto. Aos meus pais, Pedro José e Maria da Conceição, agradeço com todo o amor que carrego no peito. Vocês são minha base, minha proteção e minha inspiração diária — um presente inestimável que Deus me concedeu.

Ao meu esposo, Wagjon Ribeiro, e aos meus filhos, Eros Fernandes, Yonara Domingues e Alexia, expresso minha mais terna gratidão pela compreensão diante das ausências que esta conquista exigiu.

Agradeço, em especial, a meu filho Eros Fernandes, por cada gesto de apoio, cada palavra de incentivo e por acreditar em mim, inclusive nos momentos em que até eu mesma duvidei: esta vitória também é sua.

Estendo meus agradecimentos ao meu irmão Lucélio Aquino, à minha cunhada Aparecida Moura e aos meus sobrinhos Laura Beatriz e Eduardo Moura, por todo o apoio e carinho recebidos ao longo deste percurso.

Às amigas Micherlane Rodrigues e Franciane Moreira, que, com seu suporte e amizade, tornaram mais leve o caminho da pesquisa e da escrita. E à querida Laila Raila, uma dádiva que o mestrado me trouxe: sua amizade, cuidado e generosidade suavizaram esta caminhada.

“Os rios não bebem sua própria água; as árvores não comem seus próprios frutos. O sol não brilha para si mesmo; e as flores não espalham sua fragrância para si. Viver para os outros é uma regra da natureza. A vida é boa quando você está feliz; mas a vida é muito melhor quando os outros estão felizes por sua causa”

Papa Francisco

RESUMO

A incorporação de tecnologias emergentes, como a Inteligência Artificial (IA), aos processos produtivos tem promovido avanços significativos na eficiência, automação e controle de qualidade em diversos setores industriais. No contexto da indústria cerâmica, a qualidade dos produtos é um requisito essencial para assegurar a integridade estrutural, a durabilidade e a competitividade no setor da construção civil. Entretanto, o controle de qualidade ainda é majoritariamente realizado por inspeção visual manual, sujeita à subjetividade e à fadiga dos operadores, o que compromete a confiabilidade dos resultados. Este trabalho teve como objetivo desenvolver e validar um modelo de Rede Neural Convolucional (*CNN*) para a classificação automática de defeitos visuais em telhas cerâmicas tipo romana, utilizando imagens capturadas diretamente da linha de produção, alinhado aos princípios da Indústria 4.0. Para isso, foi construída uma base balanceada com 1.600 imagens, sendo metade de telhas normais e metade defeituosas, que passaram por um pipeline de pré-processamento em 12 etapas, incluindo remoção de fundo, equalização de histograma, normalização e aumento de dados por meio da biblioteca *Albumentations*. A arquitetura da *CNN* foi composta por 12 camadas, incluindo convolucionais, de *pooling* e densas, com ativação final *sigmoid*. O desempenho foi avaliado por meio de métricas como acurácia, precisão, *recall*, F1-score e matriz de confusão. O modelo alcançou acurácia de 99,69% e F1-score de 0,997, registrando apenas um falso negativo e nenhum falso positivo, superando trabalhos correlatos da literatura e demonstrando alta robustez frente a variações morfológicas e de iluminação não controlada. Conclui-se que a proposta é eficaz para substituir inspeções manuais subjetivas por um sistema automatizado, proporcionando maior eficiência, rastreabilidade e redução de falhas humanas.

Palavras-chave: redes neurais convolucionais, indústria 4.0, telhas cerâmicas, inspeção automatizada, controle de qualidade.

ABSTRACT

The incorporation of emerging technologies, such as Artificial Intelligence (AI), into production processes has driven significant advances in efficiency, automation, and quality control across various industrial sectors. In the context of the ceramic industry, product quality is an essential requirement to ensure structural integrity, durability, and competitiveness in the construction sector. However, quality control is still predominantly performed through manual visual inspection, which is subject to operator subjectivity and fatigue, compromising the reliability of the results. This work aimed to develop and validate a Convolutional Neural Network (CNN) model for the automatic classification of visual defects in Roman-type ceramic roof tiles, using images captured directly from the production line, in alignment with the principles of Industry 4.0. To this end, a balanced dataset of 1,600 images was built, consisting of half normal tiles and half defective ones, which underwent a 12-step preprocessing pipeline, including background removal, histogram equalization, pixel normalization, and data augmentation using the Albumentations library. The CNN architecture was composed of 12 layers, including convolutional, pooling, and dense layers, with a final sigmoid activation function. The performance was evaluated using metrics such as accuracy, precision, recall, F1-score, and confusion matrix. The model achieved an accuracy of 99.69% and an F1-score of 0.997, recording only one false negative and no false positives, outperforming related works in the literature and demonstrating high robustness in the face of morphological and uncontrolled lighting variations. It is concluded that the proposed approach is effective in replacing subjective manual inspections with an automated system, providing greater efficiency, traceability, and a reduction in human errors.

Keywords: convolutional neural networks; industry 4.0; ceramic roof tiles; automated inspection; quality control.

LISTA DE ILUSTRAÇÕES

Figura 1:	Processo de fabricação de cerâmica Vermelha.....	22
Figura 2:	Classificação de telhas cerâmicas.....	25
Figura 3:	Extração da matéria – prima.....	26
Figura 4:	Depósito de massas preparadas (a), área de sazonalidade da argila(b).....	27
Figura 5:	Etapas do processo de preparação da matéria-prima.....	28
Figura 6:	Processo de conformação de telhas cerâmicas.....	29
Figura 7:	Vista geral do secador contínuo(a), detalhe do túnel de secador com vagonetes(b).....	30
Figura 8:	Carga de telhas cruas entrando no forno para o processo de queima(a), descarga de telhas saindo do forno após o processo de queima (b).....	31
Figura 9:	Trabalhador da fábrica realizando a inspeção visual.....	32
Figura 10:	Tipos de defeitos em telhas cerâmicas: trinca(a), empenamento(b), deformação(c).....	34
Figura 11:	Percentual de desperdício por etapa do processo produtivo cerâmico.....	35
Figura 12	Fluxograma das causas e efeitos de trincas e empenamentos.....	35
Figura 13:	Arquitetura de uma Rede Neural Convolucional(CNN).....	42
Figura 14:	Processo de convolução.....	43
Figura 15:	Ilustração de duas camadas convolucionais e seus mapas de ativação.....	44
Figura 16:	Max <i>pooling</i> retângulo 2x2 e <i>stride</i> 2.....	44
Figura 17:	Imagem monocromática e convenção do par de eixos (x, y)	53
Figura 18:	Etapas fundamentais no processamento de imagens digitais.....	54
Figura 19:	Estrutura do modelo RGB.....	55
Figura 20:	Aplicação de filtros para obtenção imagem colorida.....	56
Figura 21:	Processo de limiarização.....	57
Figura 22:	Fluxograma da metodologia.....	66
Figura 23:	Fluxograma do protocolo experimental.....	68
Figura 24:	Termografias obtidas pela Câmera A-BF RX 300: Antes da secagem(a); após a secagem(b).....	69
Figura 25:	Imagens Térmicas obtidas pela Câmera HT-02D. Antes da secagem(a); após a secagem(b).....	69

Figura 26: Amostras representativas das classes utilizadas no estudo: (a) telha defeituosa com trinca superficial; (b) telha sem defeitos visíveis.....	72
Figura 27: Representação de imagens presentes no banco de dados: (a) trinca; (b) deformação.....	73
Figura 28: Etapas do pipeline de pré-processamento de Imagem original da telha com defeito.....	77
Figura 29: Arquitetura da rede neural convolucional proposta.....	78
Figura 30: Arquitetura do protótipo.....	84
Figura 31: Tela de captura de imagem	85
Figura 32: Tela de classificação.....	86
Figura 33: Tela de resultados.....	87
Figura 34: Distribuição final da base de dados após <i>data augmentation</i>	88
Gráfico 1: Evolução da acurácia e da função de perda durante a validação cruzada (k=5).....	90
Gráfico 2: Evolução da acurácia nos conjuntos de treinamento e validação ao longo de 120.....	92
Gráfico 3: Evolução da função de perda nos conjuntos de treinamento e validação ao longo de 120 épocas.....	93
Figura 35: Matriz de confusão do modelo inicial proposto.....	94
Figura 36: Curva ROC do modelo proposto.....	96
Figura 37: Comparação gráfica do desempenho dos estudos revisados.....	98

LISTA DE TABELAS

Tabela 1:	Características principais dos defeitos em telhas cerâmicas.....	34
Tabela 2:	Matriz de Confusão.....	63
Tabela 3:	Resultados de Classificações Possíveis.....	63
Tabela 4:	Características técnicas das câmeras utilizadas	67
Tabela 5:	Comparação dos dados térmicos obtidos pelas câmeras A-BF RX 300 e HT-02D antes e após o processo de secagem.....	70
Tabela 6:	Técnicas de aumento de dados aplicadas (via biblioteca <i>Albumentations</i>).....	74
Tabela 7:	Distribuição estratificada dos conjuntos de dados.....	75
Tabela 8:	Sumário do Classificador.....	79
Tabela 9:	Hiperparâmetros usados no modelo.....	80
Tabela 10:	Organização da base de dados por classe e finalidade.....	88
Tabela 11:	Estabilidade do modelo na validação cruzada (k=5).....	89
Tabela 12:	Métricas de Avaliação do Modelo Inicial Proposto.....	94
Tabela 13:	Comparação de resultados com estudos relacionados.....	98

LISTA DE ABREVIATURAS E SIGLAS

ABCERAM	Associação Brasileira de Cerâmica
ABNT	Associação Brasileira de Normas Técnicas
ANFACER	Associação Nacional dos Fabricantes de Cerâmica para Revestimento
ANICER	Associação Nacional da Indústria Cerâmica
CNNs	Redes Neurais Convolucionais
DNNs	Redes Neurais Profundas
FN	Falso Negativo
FP	Falso Positivo
IA	Inteligência Artificial
MME	Ministério de Minas e Energia
PIB	Produto Interno Bruto
RBG	<i>Red, Blue, Green</i>
SGD	Gradiente descendente estocástico
SVM	Máquina de Vetores de Suporte
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

LISTA DE SÍMBOLOS

% Porcentagem

° C Grau Celsius

ΔT Amplitude Térmica

SUMÁRIO

1	INTRODUÇÃO.....	16
1.1	PROBLEMA DE PESQUISA.....	18
1.2	PERGUNTAS DE PESQUISA.....	18
1.3	OBJETIVO GERAL	19
1.4	OBJETIVOS ESPECÍFICOS.....	19
1.5	DELIMITAÇÃO DA PESQUISA.....	19
1.6	ORGANIZAÇÃO DO TRABALHO.....	20
2	REFERENCIAL TEÓRICO.....	21
2.1	FABRICAÇÃO DE CERÂMICA VERMELHA.....	21
2.2	ARGILA.....	23
2.3	TELHAS CERÂMICAS.....	23
2.3.1	Classificação de Telhas Cerâmicas	24
2.3.2	Processo de Produção de Telhas Cerâmicas	25
2.3.2.1	Extração da Matéria-prima.....	26
2.3.2.2	Preparação da Matéria-prima.....	26
2.3.2.3	Conformação das Peças.....	28
2.3.2.4	Secagem.....	29
2.3.2.4.1	O Processo de Secagem da Fábrica Cerâmica Forte.....	30
2.3.2.5	Queima.....	31
2.3.2.6	Inspeção de Qualidade.....	31
2.3.2.7	Defeitos no Processo Produtivo de Telhas Cerâmicas.....	33
2.4	INTELIGÊNCIA ARTIFICIAL.....	36
2.4.1	Visão Computacional.....	38
2.4.1.1	Estrutura do Processo de Visão Computacional.....	39
2.4.1.2	Aplicações da Visão Computacional em Diversos Setores.....	40
2.4.2	Redes Neurais Convolucionais-CNNs.....	41
2.4.2.1	Aplicações das CNNs na Indústria.....	46
2.4.2.2	Aplicações em Classificação de Imagens.....	47
2.4.2.3	Inspeção Automatizada	48
2.5	PROCESSAMENTO DIGITAL DE IMAGENS.....	50
2.5.1	Aquisição de Imagens.....	51
2.5.2	Pré-Processamento de Imagem.....	53
2.5.2.1	Modelo RGB.....	54
2.5.3	Segmentação.....	58
2.5.4	Extração de Características e Classificação de Imagens.....	58

2.6	TREINAMENTO DO MODELO.....	60
2.7	MÉTRICAS DE VALIDAÇÃO.....	62
3	MATERIAIS E MÉTODOS.....	66
3.1	AQUISIÇÃO DE DADOS.....	66
3.1.1	Protocolo Termográfico.....	67
3.1.2	Protocolo Experimental.....	67
3.1.3	Análise Termografica.....	69
3.1.4	Transição para Espectro Visível.....	70
3.2	BANCO DE DADOS.....	61
3.3	AMBIENTE DE DESENVOLVIMENTO.....	72
3.4	PREPARAÇÃO DOS DADOS.....	72
3.5	DIVISÃO DA BASE DE DADOS.....	73
3.5.1	Divisão Inicial da Base de Dados.....	73
3.5.2	Divisão da Base de Dados para Treinamento, Validação e Teste.....	74
3.6	PRÉ PROCESSAMENTO DE DADOS.....	75
3.7	ARQUITETURA DA CNN.....	78
3.8	TREINAMENTO DO MODELO.....	79
3.8.1	Validação Cruzada K-Fold(k=5).....	80
3.9	METRICAS DE VALIDAÇÃO.....	81
4	PROTÓTIPO DE APLICAÇÃO DA METODOLOGIA.....	83
4.1	IMPLEMENTAÇÃO DO PROTÓTIPO DE APLICAÇÃO.....	83
4.2	ARQUITETURA DO SISTEMA.....	83
4.3	FUNCIONALIDADES DO APLICATIVO.....	84
4.3.1	Tela de Captura.....	84
4.3.2	Tela de Classificação.....	85
4.3.3	Tela de Resultados.....	86
5	RESULTADOS E DISCUSSÕES.....	88
5.1	BASE DE IMAGENS.....	88
5.2	TREINAMENTO DO MODELO.....	89
5.2.1	Desempenho na Validação Cruzada.....	89
5.3	METRICAS DE VALIDAÇÃO.....	91
5.3.1	Curvas de Aprendizado.....	91
5.3.2	Matriz de Confusão.....	94
5.3.3	Análise da Curva ROC.....	95
5.4	DISCUSSÃO COMPARATIVA COM A LITERATURA.....	96
6	CONCLUSÕES.....	99

6.1	LIMITAÇÕES DO TRABALHO	100
6.2	TRABALHOS FUTUROS.....	101
6.3	PRODUTOS E PUBLICAÇÕES GERADAS.....	101
	REFERÊNCIAS.....	102

1 INTRODUÇÃO

A qualidade dos produtos cerâmicos constitui um requisito essencial para a integridade estrutural, durabilidade e competitividade no setor da construção civil. Entre esses produtos, as telhas cerâmicas ocupam uma posição estratégica e economicamente relevante (responsáveis por cerca de 90% das coberturas no mercado nacional - ANICER, 2024), por desempenharem simultaneamente funções estruturais e estéticas. Para atender às exigências normativas e ao mercado consumidor, é indispensável que esses componentes apresentem resistência mecânica adequada, regularidade dimensional e ausência de defeitos críticos, como trincas, empenamentos, lascamentos e falhas de queima (ASSOCIAÇÃO BRASILEIRA DE CERÂMICA, 2022).

No entanto, nas indústrias cerâmicas brasileiras, o controle de qualidade ainda é majoritariamente realizado por inspeção visual manual, o que introduz variabilidade subjetiva, limita a reprodutibilidade dos critérios de avaliação e expõe o processo à fadiga dos operadores. Estudos apontam que tais métodos podem comprometer entre 20% e 30% da produção devido a falhas no processo de inspeção (DRURY, 1975; JAMSHED, 2021).

No contexto da Indústria 4.0, a integração de tecnologias emergentes, como Inteligência Artificial (IA), Internet das Coisas (IoT), aprendizado profundo e sistemas ciberfísicos, remodela os processos produtivos, promovendo automação, rastreabilidade e inteligência operacional (SCHWAB, 2016). Em particular, as Redes Neurais Convolucionais (CNNs) destacam-se por sua robustez em tarefas de visão computacional, dado seu desempenho superior na extração automática de atributos relevantes de imagens, sem necessidade de intervenção manual (LECUN *et al.*, 1998; GOODFELLOW; BENGIO; COURVILLE, 2016). Essas redes vêm sendo amplamente utilizadas para inspeção não destrutiva de superfícies industriais, com estudos recentes incorporando técnicas de aprendizado autoexplicável e arquiteturas baseadas em atenção para ampliar interpretabilidade e eficácia (Archana & Jeevaraj, 2024).

Diversos estudos têm explorado o uso de CNNs em aplicações específicas do setor da construção. Castagno e Atkins (2018) aplicaram arquiteturas como ResNet50 e InceptionV3 para classificar formas de telhados a partir de dados LiDAR, obtendo acurácia superior a 83%. Jiang e Zhang (2020) implementaram um modelo para

detecção de fissuras em tempo real via dispositivos móveis, atingindo 94,48% de precisão. Islam (2022) propôs uma abordagem utilizando Redes Neurais Convolucionais (*CNN*), fundamentada em modelos de transferência de aprendizagem e técnicas de aumento e transformação de dados, para a detecção de trincas em concreto. Os melhores resultados foram obtidos com os modelos VGG16 e AlexNet, ambos apresentando acurácia de 99,90%. Chow (2020) desenvolveu uma *pipeline* baseada em inteligência artificial para inspeção por imagens de estruturas de concreto, alcançando uma acurácia média de 95,60% no conjunto de teste. Le *et al.* (2021) desenvolveram um classificador para superfícies de concreto com e sem fissuras, alcançando métricas superiores a 97%. Avanços similares foram observados em Luo *et al.* (2021), que introduziram o algoritmo *PADENet* para classificação de tipos de corrosão, e em Ottoni, Novo e Costa (2022), que aplicaram *CNNs* para diferenciação entre calhas limpas e sujas.

No domínio cerâmico, Stephen, Maduh e Sain (2021) propuseram uma arquitetura eficiente de *CNN* voltada à detecção de trincas sutis em pisos cerâmicos, com integração das etapas de extração de atributos e classificação em um único modelo. Utilizando 4.181 imagens coloridas (150×150 pixels) e técnicas avançadas de aumento de dados e regularização, os autores alcançaram 99,43% de acurácia com baixo custo computacional — destacando o potencial das *CNNs* na inspeção automática de superfícies complexas.

Apesar desses avanços promissores em materiais afins, a aplicação robusta e escalável de *CNNs* especificamente para a inspeção automatizada de telhas cerâmicas em ambientes reais de produção permanece uma lacuna notável. Esta lacuna é exacerbada por desafios únicos como: escassez de bases públicas de imagens, variações morfológicas entre as peças, iluminação não uniforme (ex.: sombras projetadas pela geometria curvilínea das telhas) e presença de ruídos texturais (ex.: grânulos heterogêneos de argila, manchas de óxidos naturais) (HE *et al.*, 2016). Torna-se, portanto, premente o desenvolvimento de modelos robustos que atuem com acurácia, padronização e escalabilidade no reconhecimento de defeitos neste contexto específico.

Uma abordagem inicial com termografia foi testada e descartada devido à homogeneização térmica no processo de secagem, o que inviabilizou a detecção de microdefeitos. Diante disso, optou-se por uma abordagem robusta no espectro visível, utilizando Redes Neurais Convolucionais (*CNNs*) — abordagem que, conforme

demonstrado por Wan *et al.* (2022) e Wang *et al.* (2025), apresenta superior desempenho na detecção de padrões texturais e morfológicos em cerâmicas.

Diante dessa lacuna e das limitações das técnicas termográficas exploradas, este estudo tem como objetivo propor e avaliar um modelo baseado em Redes Neurais Convolucionais para a classificação automática de defeitos visuais em telhas cerâmicas tipo romana, utilizando imagens capturadas diretamente da linha de produção. A proposta alinha-se integralmente aos princípios da Indústria 4.0, visando contribuir para a modernização do controle de qualidade no setor cerâmico por meio da integração entre inteligência computacional e inspeção visual automatizada, superando as limitações dos métodos manuais e enfrentando os desafios do ambiente industrial real.

Espera-se que o modelo proposto sirva como base para sistemas de inspeção adaptáveis a outras cerâmicas estruturais, reduzindo perdas em $\geq 25\%$ e estabelecendo protocolos para IA em ambientes industriais adversos.

1.1 PROBLEMA DE PESQUISA

Como desenvolver um modelo automatizado, robusto e escalável, baseado em Redes Neurais Convolucionais (*CNNs*), capaz de classificar defeitos visuais em telhas cerâmicas do tipo romana, superando as limitações da inspeção visual manual e as variações de iluminação e morfologia inerentes a ambientes industriais reais?

1.2 PERGUNTAS DE PESQUISA

1. É possível desenvolver um modelo de *CNN* com desempenho igual ou superior à inspeção visual tradicional em telhas cerâmicas?
2. Quais técnicas de pré-processamento são mais eficazes na padronização de imagens industriais para inspeção automatizada?
3. Qual arquitetura de *CNN* é mais apropriada para classificar telhas normais e defeituosas com acurácia e robustez em ambiente fabril?
4. O modelo proposto é viável para implementação industrial, promovendo automação, rastreabilidade e eficiência conforme os preceitos da Indústria 4.0?

1.3 OBJETIVO GERAL

Desenvolver um modelo de *CNN* para a classificação automática de defeitos visuais em telhas cerâmicas do tipo romana, com imagens reais capturadas em ambiente fabril, visando a modernização do controle de qualidade na indústria cerâmica.

1.4 OBJETIVOS ESPECÍFICOS

- Construir uma base de dados balanceada com imagens reais de telhas cerâmicas normais e defeituosas, contemplando variabilidade morfológica e condições de iluminação adversas.
- Implementar um pipeline robusto de pré-processamento de imagens, incluindo técnicas de segmentação, equalização (para mitigar reflexos/sombras), normalização e aumento de dados (para generalização frente a ruídos texturais como grânulos ou resíduos)
- Desenvolver um modelo de *CNN*, para classificação de telhas cerâmicas tipo romana.
- Avaliar o desempenho do modelo por meio de métricas clássicas (acurácia, precisão, recall, F1-score e matriz de confusão), comparando com estudos da literatura.

1.5 DELIMITAÇÃO DA PESQUISA

O escopo deste estudo é delimitado pelos seguintes critérios:

I. DEFEITOS ANALISADOS

- Apenas defeitos superficiais visíveis: Trincas (rachaduras/fissuras), Deformações (alterações na geometria).
- Excluídos: Defeitos internos, químicos, de coloração ou outros não visíveis superficialmente.

II. MATERIAL E ETAPA DE PRODUÇÃO

- Exclusivamente telhas cerâmicas tipo romana.
- Foco na fase de pós-secagem (identificada como etapa crítica de perdas).

- Excluídos: Outros tipos de telhas (ex.: colonial, francesa) e demais fases do processo (ex.: prensagem, queima).

III. CONDIÇÕES DE INSPEÇÃO

- Controle de qualidade em linha (durante o fluxo produtivo).
- Validação sob condições reais de produção: Iluminação natural (sem controle artificial de luz); Variabilidade angular (observação em múltiplos ângulos).
- Excluídos: Inspeção em laboratório com iluminação controlada.

1.6 ORGANIZAÇÃO DO TRABALHO

Esta dissertação está estruturada em cinco capítulos:

- **Capítulo 1:** Introdução – apresenta a contextualização do tema, o problema de pesquisa, os objetivos, as perguntas investigativas e a justificativa do estudo.
- **Capítulo 2:** Fundamentação Teórica – descreve a produção de cerâmica vermelha, inspeção de qualidade, defeitos em telhas e aplicações de *CNNs* e visão computacional.
- **Capítulo 3:** Materiais e Métodos – detalha a metodologia empregada, incluindo aquisição de imagens, preparação dos dados, definição do modelo e métricas utilizadas.
- **Capítulo 4:** Resultados e Discussão – apresenta os resultados obtidos com o modelo de *CNN* proposto, análise crítica e comparação com outros estudos.
- **Capítulo 5:** Conclusão – sintetiza os principais achados, as contribuições da pesquisa, limitações e direções para estudos futuros.

2 REFERENCIAL TEÓRICO

O referencial teórico deste estudo está fundamentado em aspectos relevantes sobre fabricação de cerâmica vermelha, o processo de produção de telhas cerâmicas, e as inovações tecnológicas advindas do uso de IA, Visão Computacional e *CNNs*. O objetivo é oferecer uma base sólida para justificar o desenvolvimento do modelo proposto, contextualizando sua relevância acadêmica e industrial.

2.1 FABRICAÇÃO DE CERÂMICA VERMELHA

A fabricação de cerâmica vermelha é composta por várias etapas fundamentais, que podem ser organizadas em quatro principais fases: preparação da matéria-prima, preparação da massa cerâmica, formação das peças, tratamento térmico e finalização.

A etapa inicial envolve o beneficiamento das matérias-primas. Nesse processo, a argila, quando em estado "duro", passa por britagem e moagem para desagregar os grãos e alcançar uma granulometria adequada para a preparação das massas.

Em seguida, ocorre a preparação das massas, que inclui a dosagem e mistura. Normalmente, utiliza-se uma combinação de dois tipos de argilas com características distintas. Essa etapa tem como objetivo ajustar a composição para garantir boas condições de modelagem e propriedades finais desejadas nas peças.


A fase de formação das peças é responsável por dar forma aos produtos cerâmicos. Esse processo abrange operações como laminação, extrusão, corte e prensagem. Durante a laminação, a argila é compactada ao passar por rolos laminadores, submetendo o material a altas tensões compressivas. Já na extrusão, a massa cerâmica é introduzida em uma extrusora, onde é compactada e forçada a passar por um bocal que define o formato desejado. O resultado é uma coluna contínua, que posteriormente será cortada no formato das peças. No caso da fabricação de telhas, após a extrusão, ocorre a prensagem, que utiliza moldes específicos para conferir o formato final à peça.

O tratamento térmico, etapa de fundamental importância no processo, engloba a secagem e a queima dos corpos cerâmicos. A secagem remove gradualmente o excesso de água, evitando a formação de tensões e defeitos estruturais. Já a queima ou sinterização submete as peças a altas temperaturas, provocando reações químicas

e transformações que conferem suas características finais, como resistência e durabilidade.

Por fim, os materiais passam por uma inspeção criteriosa antes de serem estocados e destinados ao mercado. Nos próximos tópicos, algumas das etapas descritas serão abordadas em maior detalhe, e o fluxograma apresentado na Figura 1 ilustra todo o processo de fabricação de cerâmica vermelha.

Figura 1 - Processo de fabricação de cerâmica vermelha.



Fonte: ABCERAM, 2020.

2.2 ARGILA

As argilas, principais matérias-primas utilizadas na indústria cerâmica, são constituídas predominantemente por argilominerais, que conferem características fundamentais aos materiais cerâmicos. Além dos argilominerais, as argilas podem conter outros minerais que atuam como fundentes, promovendo a fusão parcial durante a queima, minerais inertes que desempenham a função de enchimento, bem como matéria orgânica e impurezas.

Os argilominerais são classificados como silicatos de alumínio hidratados, sendo que, em algumas composições, podem apresentar elementos adicionais, como magnésio, cálcio, sódio, potássio, ferro e lítio, entre outros. Esses elementos desempenham papéis importantes na modificação das propriedades físico-químicas da argila, impactando diretamente o desempenho do produto cerâmico final (MORAIS e SPOSTO, 2006).

No Brasil, o setor de cerâmica vermelha utiliza predominantemente argilas como matéria-prima na fabricação de diversos produtos, como tijolos, blocos e telhas. De acordo com o Ministério de Minas e Energia (MME, 2020), estima-se que cerca de 140 milhões de toneladas de argila sejam consumidas anualmente pela indústria cerâmica nacional, evidenciando a relevância desse insumo para o setor e para a economia brasileira.

2.3 TELHAS CERÂMICAS

As telhas cerâmicas desempenham um papel fundamental como elementos de cobertura em construções em todo o Brasil. Elas são produzidas a partir de argilas, predominantemente do tipo ilita e montmorilonita. O processo de preparação da massa argilosa envolve a conformação por extrusão, com um teor de umidade entre 20% e 25%. Nesse estágio, a argila é moldada em bastões, posteriormente cortados e prensados para adquirir o formato final desejado. Após a secagem, as telhas são submetidas a um processo de queima em temperaturas que variam de 900°C a 1100°C (SELHORST, 2001).

Para atender às exigências de desempenho e qualidade, as telhas cerâmicas devem apresentar superfícies lisas, capazes de facilitar o escoamento da água, além de estarem isentas de fissuras, microfissuras, esfoliações, quebras, rebarbas ou

qualquer outro defeito que comprometa o perfeito encaixe entre os componentes. Telhas conformes atendem a limites específicos, tanto máximos quanto mínimos, relacionados a dimensões, formas, resistência mecânica, impermeabilidade e absorção de água. Esses requisitos são regulamentados por um conjunto de normas complementares estabelecidas pela Associação Brasileira de Normas Técnicas (ABNT), garantindo a padronização e a qualidade do produto (ANICER, 2023).

2.3.1 Classificação de telhas cerâmicas

De acordo com a norma ABNT NBR 15310/2009, as telhas cerâmicas são classificadas em quatro categorias principais: planas de encaixe, planas de sobreposição, compostas de encaixe e simples de sobreposição. A seguir, são descritas as características de cada tipo:

I - Planas de encaixe: Telhas cerâmicas planas que se conectam por meio de sulcos e saliências, geralmente equipadas com pinos ou com pinos e furos de amarração, que garantem a fixação na estrutura de apoio.

II - Planas de sobreposição: Telhas planas que se sobrepõem sem necessidade de encaixe direto. Essas podem conter pinos para fixação na estrutura de apoio ou ainda pinos e furos de amarração para melhor fixação.

III - Compostas de encaixe: Telhas cuja geometria combina capa e canal em um único componente, permitindo o encaixe direto entre as peças. Assim como nas anteriores, são dotadas de pinos ou pinos e furos de amarração para fixação na estrutura de apoio.

IV - Simples de sobreposição: Constituídas por componentes separados de capa e canal, onde a concavidade ou convexidade determina a função de canal ou capa, respectivamente. Os canais apresentam pinos, furos ou ambos para a fixação, enquanto as capas podem dispensar esses elementos.

A Figura 2, conforme ilustrado pela ANICER (2013), apresenta exemplos dessas telhas cerâmicas, detalhando suas características com base nas especificações da NBR 15310/2009.

Figura 2 - Classificação das telhas cerâmicas.



Fonte: Anicer, 2013

2.3.2 Processo de Produção de Telhas Cerâmicas

A fabricação de telhas cerâmicas constitui um processo complexo e multivariado, cuja qualidade final depende intrinsecamente do controle rigoroso de todas as etapas produtivas, desde a seleção da matéria-prima até o tratamento térmico final. De acordo com a ANFACER (2018), o processo inicia-se com a extração da argila, que após umedecida, adquire propriedades plásticas e moldáveis essenciais para a conformação.

O processo fabril compreende cinco etapas principais: extração da matéria-prima (argila), preparação da matéria-prima, conformação, secagem e queima. Na fase de preparação, a argila é homogeneizada e temperada, sendo fundamental garantir a uniformidade da mistura para evitar defeitos estruturais no produto final. Durante a conformação, o material é modelado para adquirir o formato desejado através de métodos como extrusão ou prensagem.

A secagem representa uma etapa crítica onde é eliminada a umidade residual das peças moldadas, prevenindo a formação de trincas e deformações. Posteriormente, as telhas são submetidas à queima em temperaturas elevadas, variando entre 900°C e 1100°C (SELHORST, 2001), processo que confere rigidez e resistência mecânica ao material através da fusão dos componentes cerâmicos e,

quando aplicável, da fixação de esmaltes superficiais.

Cada fase do processo é determinante para a qualidade final do produto. O controle rigoroso das condições de queima assegura propriedades mecânicas adequadas, resultando em produtos resistentes e duráveis, enquanto a homogeneidade da massa cerâmica é fundamental para prevenir defeitos e garantir a integridade estrutural das telhas.

2.3.2.1 Extração da matéria-prima

Após a extração, a argila é transportada em caminhões caçamba até o pátio da empresa, onde permanece em repouso em um processo chamado sazonalamento. Essa etapa é essencial para melhorar a homogeneidade e a estabilidade da matéria-prima, permitindo que ocorram reações físico-químicas importantes, como a decomposição de matéria orgânica, a dissolução de sais e a desagregação de aglomerados. A Figura 3 ilustra um exemplo desse processo de extração e preparo inicial da argila na empresa do estudo.

Figura 3 - Extração da matéria-prima.



Fonte: Autora (2025)

2.3.2.2 Preparação da Matéria-Prima

A preparação da matéria-prima para a produção de peças cerâmicas é um processo detalhado e essencial para garantir a qualidade e a uniformidade do produto final. Essa etapa compreende diferentes subprocessos, cada um com uma função específica, como descrito a seguir:

I - Sazonamento (Estocagem): A etapa inicial do tratamento da argila é conhecida

como sazonalidade. Essa prática envolve a estocagem da argila recém-extraída de uma jazida, deixando-a exposta ao ambiente natural por um período que pode variar de alguns meses a vários anos. O principal objetivo desse processo é tornar o material mais homogêneo, aumentar sua plasticidade e minimizar a ocorrência de trincas durante a secagem. Além disso, o sazonalidade contribui para a redução ou até mesmo eliminação do conteúdo de matéria orgânica presente na argila, garantindo uma matéria-prima de melhor qualidade para o uso industrial.

Depois do sazonalidade, a massa é armazenada em depósitos cobertos, como mostrado na Figura 4, antes de seguir para as próximas etapas.

Figura 4 - Depósito de massas preparadas(a), e área de sazonalidade da argila(b).



Fonte: Autora (2025)

II - Dosagem: Nesta fase, as matérias-primas são alimentadas em proporções controladas no caixão alimentador e dosador, utilizando correias transportadoras. A dosagem é ajustada com base nas propriedades específicas de cada material, garantindo uma mistura balanceada que atenda às exigências do produto final.

III- Desintegração: Se a argila apresentar alta dureza, ela passa por um desintegrador para triturar aglomerados maiores. Esse processo é essencial para tornar a matéria-prima mais uniforme e fácil de manejar, além de otimizar as etapas subsequentes.


IV- Mistura: A argila desintegrada é levada ao misturador, onde é combinada com água de forma homogênea. Movimentos circulares do equipamento garantem que o material atinja uma umidade ideal, geralmente entre 18% e 30%, além de adquirir a plasticidade necessária para o processo de

conformação.

V - Laminação: Por fim, o material passa pela etapa de laminação, que compacta a mistura e elimina bolhas de ar e aglomerados residuais. O uso do laminador assegura que a argila tenha uma consistência uniforme e esteja pronta para as etapas posteriores da produção.

A Figura 5 apresenta uma visão geral das etapas de preparação da matéria-prima, destacando a sequência de procedimentos que garantem a produção eficiente e de qualidade de telhas cerâmicas.

Figura 5 - Etapas do processo de preparação da matéria-prima.



Fonte: Autora (2025).

2.3.2.3 Conformação das peças

Após a preparação da massa cerâmica, realiza-se a etapa de conformação, que é precedida por uma mistura adicional e um processo de laminação. Esses procedimentos garantem a uniformidade da massa, permitindo que o produto adquira sua forma final. Durante essa fase, podem ocorrer pequenas variações dimensionais e de cor, que serão ajustadas na etapa de queima.

A conformação é realizada predominantemente pelo método de extrusão de uma massa plástica, cujas propriedades são influenciadas tanto pelo tipo de argila utilizada quanto pelos métodos aplicados na preparação da composição (SANTOS, 2021). Nesse processo, a massa cerâmica é inserida em uma extrusora, também conhecida como maromba. Dentro desse equipamento, a massa é compactada e forçada por um pistão ou eixo helicoidal através de um molde, chamado de boquilha.

Assim, forma-se uma coluna extrudada com a seção transversal, formato e dimensões desejados. Em seguida, essa coluna é cortada para produzir as peças cerâmicas. A Figura 6 ilustra o processo de conformação aplicado na fabricação de telhas cerâmicas.

Figura 6 - Processo de conformação de telhas cerâmicas.



Fonte: Autora (2025).

2.3.2.4 Secagem

Após a etapa de conformação, as peças ainda úmidas são transportadas para secadores artificiais, onde são cuidadosamente empilhadas em blocos. A secagem, uma etapa essencial que antecede a queima, requer uma quantidade significativa de energia para remover a umidade de forma gradual e uniforme, processo realizado por difusão mássica. Normalmente, utiliza-se uma corrente de ar quente, que transfere calor para as peças e facilita a saída progressiva da umidade (ABAJO, 2000).

Para evitar desgastes e deformações, essa umidade é removida gradualmente em secadores, com temperaturas variando entre 50°C e 150°C (ABceram, 2022). Após essa etapa, o material deve apresentar resistência suficiente para suportar os esforços associados ao manuseio e transporte até a queima (SOARES *et al.*, 2004). Entretanto, cerca de 5% do volume total das peças pode ser perdido durante o processo, indicando a necessidade de melhorias nos controles operacionais.

O principal objetivo da secagem é reduzir a umidade das peças de cerca de 20% para menos de 10%, promovendo contrações volumétricas que variam entre 4% e 10%. Essa redução é muito importante para as etapas subsequentes da fabricação.

Por ser uma das fases mais delicadas, o controle inadequado da secagem pode gerar tensões internas, levando ao surgimento de defeitos decorrentes do processo fabril, como trincas e empenamentos (CROZETTA *et al.*, 2016).


Portanto, compreender as dinâmicas da secagem é indispensável para assegurar a qualidade do produto final, uma vez que essa etapa influencia diretamente as propriedades mecânicas e estéticas das peças cerâmicas.

2.3.2.4.1 O Processo de Secagem da Fábrica Cerâmica Forte

Na fábrica Cerâmica Forte, especializada na produção de telhas cerâmicas, utiliza-se um secador contínuo em formato de túnel, equipado com vagonetes que se deslocam sobre trilhos. Essas vagonetas são posicionadas de forma a eliminar espaços livres entre elas, minimizando a dispersão de calor durante o processo.

O sistema opera com fluxo de ar quente em contracorrente ao movimento das vagonetes: o ar é introduzido pela extremidade de saída e aspirado por chaminés localizadas ao longo da estrutura. A velocidade do ar é rigorosamente controlada, assegurando uma secagem homogênea e reduzindo a probabilidade de deformações nas peças(SOUZA, 2020). A Figura 7 mostra o secador contínuo com as vagonetas deslizando sobre os trilhos.

Figura 7 - Vista geral do secador contínuo(a); e detalhe do túnel de secador com vagonetes(b).



Fonte: Autora (2025).

2.3.2.5 Queima

A queima representa a etapa final no processo de produção de telhas cerâmicas, sendo responsável por conferir às peças as propriedades físico-químicas e mecânicas essenciais para o produto acabado. Nessa fase, as telhas são dispostas em fornos industriais de grande porte, onde são submetidas a temperaturas que podem atingir até 1200°C. Esse tratamento térmico desencadeia uma série de transformações físico-químicas que alteram a estrutura, a porosidade, a cor e o tamanho das telhas. A Figura 8 mostra o processo de queima das telhas cerâmicas.

Figura 8 - Carga de telhas cruas entrando no forno para o processo de queima(a), descarga de telhas saindo do forno após o processo de queima(b).



Fonte: Autora (2025).

Além das mudanças estruturais, a queima promove significativas melhorias nas propriedades mecânicas do material, como o aumento da resistência à compressão, tração e abrasão, características que são fundamentais para garantir a durabilidade e a qualidade do produto final (AGUIAR *et al.*, 2022).

2.3.2.6 Inspeção de qualidade

Como demonstrado nas etapas anteriores, o processo de fabricação é suscetível a variáveis que podem gerar defeitos. Portanto, a inspeção de qualidade é a etapa final e indispensável para garantir que apenas produtos dentro dos padrões alcancem o mercado.

O controle de qualidade em telhas cerâmicas tem sido tradicionalmente realizado por meio de inspeções visuais conduzidas por trabalhadores experientes. Embora amplamente utilizado, esse método apresenta limitações significativas, como a subjetividade das avaliações e a possibilidade de fadiga dos operadores, fatores que comprometem a confiabilidade e a precisão do processo.

De acordo com Santos e Almeida (2019), a automação do controle de qualidade, por meio de tecnologias como a visão computacional, pode reduzir substancialmente tanto a taxa de erros quanto o tempo necessário para a inspeção. Contudo, mesmo métodos convencionais de automação enfrentam desafios, particularmente na identificação de defeitos mais complexos nas peças cerâmicas.

Na prática atual, a inspeção de qualidade na indústria de telhas cerâmicas ainda é predominantemente manual, com operadores avaliando individualmente cada peça em busca de defeitos visuais e anomalias de formato. Apesar de amplamente difundido, esse processo está sujeito a variações na detecção de falhas devido às interpretações subjetivas dos operadores, além de dificuldades em manter a precisão ao longo de períodos prolongados de trabalho. A Figura 9 ilustra um trabalhador realizando a inspeção visual, uma etapa essencial no processo de controle de qualidade do produto final. Essa prática tem como objetivo identificar possíveis defeitos nas peças, garantindo que os produtos atendam aos padrões estabelecidos antes de serem disponibilizados ao mercado.

Figura 9 - Trabalhador da fábrica realizando a inspeção visual



Fonte: Autora (2025)

Para superar essas limitações, pesquisas recentes têm investigado o uso de Redes Neurais Convolucionais, como uma abordagem inovadora para o controle de qualidade em processos de manufatura. As *CNNs*, reconhecidas por sua eficácia em setores como manufatura aditiva, têm demonstrado alta precisão na detecção de defeitos como porosidade, rachaduras e falta de fusão. Estudos pioneiros realizados por (Tian *et al.* 2017, Cui *et al.* 2018, Caggiano *et al.* 2019 e Yan *et al.* 2020) validaram a eficiência das *CNNs* quando comparadas aos métodos tradicionais, estabelecendo-as como uma solução promissora para a inspeção de qualidade no setor cerâmico.


2.3.2.7 Defeitos no processo produtivo de telhas cerâmicas

A ocorrência de defeitos no processo produtivo de telhas cerâmicas constitui um desafio significativo, com implicações diretas na qualidade do produto final e na eficiência econômica do processo. Conforme demonstrado por Oliveira *et al.* (2005), muitos defeitos que se manifestam nas etapas de secagem e queima frequentemente têm sua origem em fases anteriores do processamento, tornando estas etapas fundamentais para identificar os indicadores operacionais da qualidade de todo o processo.

Durante o processo de fabricação de telhas cerâmicas, é recorrente o surgimento de defeitos como trincas, empenamentos e deformações, os quais comprometem significativamente a qualidade do produto final. Esses defeitos, em sua maioria, resultam de variações nos parâmetros de produção, incluindo fatores como temperatura, umidade e composição química e mineralógica da argila utilizada.

Estudos conduzidos por Silva *et al.* (2018) e Oliveira (2020) destacam os desafios enfrentados pelas indústrias cerâmicas na busca pela manutenção de elevados padrões de qualidade, considerando a influência desses fatores nos processos produtivos. Conforme ilustrado na Figura 10, os três principais tipos de defeitos podem ser visualmente identificados: as trincas, os empenamentos e as deformações.

Figura 10 - Tipos de Defeitos em Telhas Cerâmicas: (a) trinca, (b) empenamento, (c) deformação



Fonte: Autora(2025)

A Tabela 1 detalha sistematicamente as características específicas e os impactos desses defeitos na qualidade final do produto, sintetizando as principais manifestações dessas não-conformidades.

Tabela 1 - Características principais dos defeitos em telhas cerâmicas

Tipo de Defeito	Características Principais	Impactos na Qualidade
Trincas	Fraturas superficiais ou profundas; podem ser visíveis ou microscópicas	Comprometimento da integridade estrutural
Empenamentos	Encurvamento irregular; tombamento lateral	Impedimento do encaixe adequado
Deformações	Alteração da forma original; perda de alinhamento dimensional	Irregularidades na superfície


Fonte: Autora(2025)

A ocorrência de defeitos em corpos cerâmicos é um elemento crítico, pois afeta diretamente a integridade estrutural e a durabilidade das telhas. Grande parte dessas falhas origina-se durante a fase de prensagem, principalmente devido a parâmetros inadequados de processamento ou ao uso de matérias-primas de baixa qualidade. Defeitos como delaminações, materiais heterogêneos e aglomerados estão entre os mais comuns e têm impacto significativo na resistência mecânica das telhas cerâmicas.

Dentre os fatores que contribuem para a formação de defeitos, a umidade exerce papel de destaque. Ao interferir nos processos de conformação e secagem, a umidade inadequada promove o surgimento de trincas, empenamentos e outras deformações. Segundo Araújo, Duarte e Prado (2019), os percentuais de peças defeituosas nas etapas de conformação, secagem e queima foram de 1,19%, 3,01% e 8,54%, respectivamente, sendo a etapa de queima a mais crítica. Nessa fase, peças

com defeitos não podem ser reaproveitadas, resultando em perdas irreversíveis para o processo produtivo.

Figura 11 - Percentual de desperdício por etapa do processo produtivo cerâmico




Fonte: Adaptado de Araújo, Duarte e Prado (2019)

Tais dados reforçam a necessidade de métodos eficazes para a detecção precoce de defeitos ao longo do processo de fabricação. A adoção de tecnologias e estratégias de controle de qualidade avançadas pode minimizar os impactos desses problemas, promovendo maior eficiência produtiva e assegurando que os produtos finais atendam aos requisitos técnicos e normativos exigidos pelo mercado.

A Figura 12 detalha as relações de causas e efeitos destes defeitos ao longo do processo produtivo. Em conjunto, estas análises proporcionam uma visão integrada dos fatores críticos que impactam a qualidade final do produto.

Figura 12 - Fluxograma das Causas e Efeitos de Trincas e Empenamentos



Fonte: Adaptado de Araújo, Duarte e Prado (2019).

Para minimizar esses defeitos e otimizar o processo produtivo, são

recomendadas as seguintes ações:

I - Inspeção Periódica da Matéria-Prima: Realizar testes frequentes de plasticidade, umidade e granulometria da argila para identificar variações na composição e ajustar a proporção de mistura de modo a minimizar falhas (ARAÚJO; DUARTE; PRADO, 2019).

II - Gerenciamento de Resíduos Sólidos: Implementar práticas para o reaproveitamento dos resíduos sólidos, como seu uso em obras internas, doação, venda mediante aceitação do cliente ou como aterro em áreas de extração esgotadas. Alternativamente, os resíduos podem ser utilizados na fabricação de agregados graúdos, como combustível em fornos de cimento ou na vedação de portas de fornos (GUIMARÃES *et al.*, 2018).

III - Garantia da Secagem Completa: Assegurar que as peças passem por um processo de secagem completo antes da queima. Recomenda-se a realização de testes de umidade nas peças. Na secagem natural, proteger as peças da chuva e, na secagem artificial, considerar o reaproveitamento de calor gerado durante a queima em estufas (ARAÚJO; DUARTE; PRADO, 2019).

IV - Monitoramento do Processo Produtivo: Acompanhar a capacidade produtiva e o índice de defeitos em cada etapa do processo, identificando pontos de melhoria. Sugere-se também a realização de paradas programadas para manutenção preventiva das máquinas de moagem, laminação e extrusão.

V - Controle do Processo de Queima: Implementar um sistema de alimentação contínua do forno para maior controle da temperatura. Conforme RÊGO e SOARES (2015), o gerenciamento da velocidade de aquecimento e resfriamento é essencial para evitar trincas, principalmente quando o forno atinge 573 °C, ponto em que ocorre a transformação do quartzo alfa para beta.

Estas medidas, quando aplicadas de forma integrada e sistemática, contribuem significativamente para a redução de defeitos e o aprimoramento da qualidade dos produtos cerâmicos, promovendo uma produção mais eficiente e sustentável.

2.4 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) configura-se como um campo científico dedicado ao desenvolvimento de sistemas capazes de reproduzir aspectos da cognição humana

(S. K. BADUGE *et al.*, 2022). Em sua fase inicial, as soluções dependiam exclusivamente do conhecimento de especialistas, obtido por meio de entrevistas e sistematizado em regras lógicas – abordagem que deu origem aos sistemas especialistas, hoje associados à IA simbólica. Contudo, essa metodologia revelou limitações críticas: sua eficácia estava intrinsecamente vinculada à qualidade do especialista consultado (frequentemente inconsistente) e enfrentava a resistência dos profissionais, que temiam substituição por máquinas, prejudicando a coleta de dados (FACELI, LORENA *et al.*, 2021).

Diante da crescente complexidade dos problemas computacionais, tornou-se imperativo desenvolver metodologias mais autônomas e menos dependentes da intervenção humana. Essa necessidade catalisou o surgimento do Aprendizado de Máquina (AM), impulsionado por dois fatores cruciais: a evolução na capacidade de processamento e armazenamento de grandes volumes de dados (*big data*) e o desenvolvimento de algoritmos bioinspirados no cérebro humano, como as redes neurais artificiais (BRAGA, CARVALHO e LUDERMIR, 2000; FACELI, LORENA *et al.*, 2021).

O AM permitiu avanços significativos em múltiplos domínios da IA, incluindo robótica, visão computacional, processamento de linguagem natural (PLN), raciocínio e representação do conhecimento (FACELI, LORENA *et al.*, 2021). A aceleração recente nesse campo deve-se sobretudo a avanços em *hardware* – como aceleradores especializados e arquiteturas versáteis –, que viabilizaram modelos com maior flexibilidade, aplicabilidade e escalabilidade (Y. LI and J. ZHAN, 2022).

A implementação contemporânea da IA integra metodologias diversificadas, tais como modelos cognitivos, sistemas baseados em regras, algoritmos de busca, além de técnicas para representação de conhecimento e planejamento (S. K. BADUGE *et al.*, 2022). Esses recursos revolucionaram setores estratégicos: na saúde, aprimoraram diagnósticos médicos (B. PRABHAKAR, R. K. SINGH, and K. S. YADAV, 2021); na mobilidade, impulsionaram veículos autônomos (X. DI and R. SHI, 2021); na agricultura, otimizaram processos produtivos (M. WAKCHAURE, B. K. PATLE, and A. K. MAHINDRAKAR, 2023); e na análise de dados, transformaram o processamento de sinais, o tratamento de *big data* e a manipulação de imagens (KURIC *et al.*, 2022).

2.4.1 Visão Computacional

A visão computacional é um campo emergente da inteligência artificial, caracterizado pelo constante desenvolvimento de tecnologias destinadas a capacitar sistemas robóticos a "enxergar", permitindo o reconhecimento e a interpretação de objetos e cenários em seu entorno (NEVES, 2022). Essa área tem demonstrado um impacto significativo na melhoria da eficiência, qualidade e confiabilidade de processos industriais, consolidando-se como uma ferramenta essencial para o controle de qualidade de produtos (FERGUSON *et al.*, 2018).

Conforme apontado por Recalcati e Mingori (2020), a visão computacional é uma peça-chave na transformação digital promovida pela Indústria 4.0. Sua capacidade de aprimorar processos produtivos, otimizar operações e melhorar a qualidade de serviços a posiciona como uma tecnologia indispensável para o futuro da automação. Ao transcender os limites da percepção humana, a visão computacional consolida-se como um dos pilares fundamentais da revolução tecnológica contemporânea.

Na indústria de manufatura, a visão computacional desempenha um papel crucial, sendo amplamente empregada em diversas aplicações, como a detecção de anomalias em processos de manufatura aditiva (SCIME e BEUTH, 2018; DAVTALAB *et al.*, 2020), inspeção de falhas em superfícies de aço (HAO *et al.*, 2020), identificação de defeitos em superfícies de telhas magnéticos (HUANG *et al.*, 2018).

Essas aplicações têm promovido avanços significativos no setor industrial, proporcionando melhorias substanciais na eficiência, qualidade e confiabilidade dos processos de inspeção e controle de qualidade. Tais progressos destacam a importância da visão computacional no contexto da automação industrial, consolidando sua relevância como uma ferramenta indispensável para a modernização e otimização dos processos produtivos (ZHONGHE *et al.*, 2021)

A visão computacional tem promovido avanços significativos no âmbito industrial, melhorando de maneira expressiva o escopo, a eficiência, a qualidade e a confiabilidade dos processos de inspeção. Esses progressos impulsionaram uma série de conquistas indispensáveis para a indústria contemporânea, consolidando sua relevância no contexto da automação e controle de qualidade (ZHONGHE *et al.*, 2021).

No entanto, ainda existem desafios e oportunidades de exploração nessa área de aplicação. A visão computacional, é amplamente empregada para detecção em tempo real, o que envolve o processamento de grandes volumes de dados, informações redundantes e espaços de recursos de alta dimensionalidade. Entre os principais gargalos dessa tecnologia está a velocidade de processamento de imagens, que impacta diretamente o desempenho em tempo real dos sistemas de visão.

Outro obstáculo significativo diz respeito ao nível de inteligência dos sistemas de detecção. Em ambientes de interferência complexa, onde a identificação manual pode ser realizada com relativa facilidade, as máquinas frequentemente enfrentam dificuldades para realizar a mesma tarefa com precisão. Esses desafios ressaltam a necessidade de avanços tecnológicos adicionais para aumentar a robustez e a capacidade adaptativa dos sistemas de visão computacional em cenários industriais mais exigentes.

2.4.1.1 Estrutura do processo de visão computacional

O processo de visão computacional pode ser dividido em etapas distintas, cada uma desempenhando um papel fundamental na análise de imagens. Essas etapas podem ser sintetizadas conforme descrito por Arnaud, Evelina e Fabrizio (2018).

I - Aquisição da Imagem: Captura de imagens bidimensionais ou tridimensionais por meio de câmeras e sensores, obtendo dados fundamentais, como intensidade luminosa e profundidade. Essa etapa inicial define a qualidade das informações processadas.

II - Pré-processamento: Tem o objetivo de eliminar ruídos, normalizar histogramas, ajustar contrastes e destacar informações úteis, para garantir que as imagens estejam em condições ideais para análise subsequente.

III - Extração de Características: Identificação de propriedades matemáticas relevantes, como texturas e formas, possibilitando a identificação de elementos significativos, como bordas e cantos.

IV - Detecção e Segmentação: Análise que destaca regiões de interesse, otimizando o foco nas áreas mais relevantes da imagem.

V- Processamento e Classificação: Categorização dos objetos detectados, replicando aspectos da visão humana com níveis superiores de precisão.

Esse fluxo estruturado permite que a visão computacional não apenas simule a percepção humana, mas também a amplie, identificando detalhes que frequentemente escapam à observação humana, especialmente em ambientes complexos e dinâmicos (RECALCATI & MINGORI, 2020).

2.4.1.2 Aplicações da visão computacional em diversos setores

Conforme destacado por Szeliski (2022), as aplicações da visão computacional abrangem uma gama vasta e diversificada de áreas, incluindo, mas não se limitando a reconhecimento óptico de caracteres, inspeção de máquinas, comércio varejista, logística, análise de imagens médicas, veículos autônomos e modelagem 3D. Essa ampla aplicabilidade destaca o impacto crescente e a relevância da visão computacional em diferentes esferas industriais e acadêmicas, destacando sua importância em setores específicos, como:

I – **Medicina:** A extração de informações detalhadas de exames, como radiografias e [ressonâncias magnéticas, tem otimizado o processo de diagnóstico e reduzido significativamente o tempo de análise (SOUZA, 2020).

II – **Agricultura:** A identificação de doenças em plantas, presença de pragas e outros problemas relacionados à saúde das culturas é facilitada por sistemas de visão computacional, contribuindo para o aumento da produtividade e sustentabilidade agrícola (SANTOS, 2020).

III – **Engenharia:** BAI *et al.* (2022) apresentaram uma rede neural profunda capaz de detectar automaticamente danos estruturais e rachaduras em imagens, revolucionando a forma como as inspeções são realizadas no campo da engenharia civil e estrutural.

IV – **Segurança:** O uso de reconhecimento facial, amplamente adotado, utiliza algoritmos de visão computacional para aprender e identificar rostos de forma autônoma, oferecendo soluções inovadoras e mais seguras para autenticação e controle de acesso (FERREIRA, 2021).

V – **Veículos Autônomos:** Sistemas de visão computacional permitem o reconhecimento de sinais de trânsito e obstáculos em tempo real, com precisão superior à percepção humana, além de desempenharem um papel fundamental em projetos de exploração espacial, como o *Mars Exploration Rover* da NASA (HAMMES, 2020).

Essa diversidade de aplicações reflete a transformação contínua que a visão computacional vem promovendo em vários campos, contribuindo para a evolução tecnológica e o avanço de soluções inovadoras.


2.4.2 Redes Neurais Convolucionais - CNNs

As Redes Neurais Convolucionais (*Convolutional Neural Networks – CNNs*) constituem uma classe de algoritmos de *deep learning* projetada especificamente para a análise e interpretação de imagens. Seu funcionamento baseia-se na aplicação de operações de convolução com filtros (ou *kernels*), que têm como principal objetivo extrair características relevantes diretamente dos dados de entrada. Essa capacidade torna as *CNNs* especialmente eficazes na identificação de padrões visuais complexos, como objetos, rostos e gestos, graças à sua habilidade em aprender representações hierárquicas e invariantes (CHAUHAN *et al.*, 2018; GOODFELLOW *et al.*, 2016).

De acordo com Chauhan *et al.* (2018), essas redes demonstram desempenho superior em tarefas de reconhecimento e detecção de imagens, consolidando-se como uma ferramenta robusta e amplamente empregada em múltiplas áreas da inteligência artificial. As *CNNs* integram, assim, o conjunto das arquiteturas de redes profundas mais eficazes e frequentemente aplicadas em tarefas de visão computacional, com destaque para problemas de classificação de imagens.

Sua principal distinção em relação às redes neurais tradicionais reside na utilização de camadas convolucionais — ao invés das operações de multiplicação matricial predominantes nas arquiteturas clássicas — o que confere maior eficiência e precisão na extração de atributos visuais (GOODFELLOW *et al.*, 2016). Segundo Gu *et al.* (2017) e Rawat e Wang (2017), a estrutura de uma CNN típica é organizada em três blocos funcionais fundamentais: (i) as camadas convolucionais, responsáveis pela extração hierárquica das características da imagem; (ii) as camadas de *pooling*, que promovem a redução da dimensionalidade dos mapas de ativação e atuam no controle do *overfitting*; e (iii) as camadas totalmente conectadas (*fully connected*), encarregadas da etapa decisória, atribuindo probabilidades às classes de saída. A Figura 12 ilustra, de forma esquemática, a estrutura de uma CNN aplicada à tarefa de classificação de imagens.


Figura 13 - Arquitetura de uma Rede Neural Convolucional.



Fonte: Penha, D. (2018).

A camada convolucional constitui o núcleo funcional das Redes Neurais Convolucionais (*CNNs*), sendo responsável pela extração automática de padrões locais presentes na imagem de entrada. Essa camada opera por meio de um conjunto de filtros (ou *kernels*), que percorrem a matriz de entrada ao longo dos eixos horizontal (*x*) e vertical (*y*), segundo deslocamentos definidos por parâmetros denominados *strides*. A cada operação de convolução, o filtro gera um mapa de características (*feature map*), o qual corresponde à matriz de saída associada àquele filtro específico.

A saída da camada convolucional é composta pela sobreposição dos diversos mapas de características obtidos a partir da aplicação sequencial dos filtros. Cada elemento do *feature map* representa a ativação de um neurônio que responde a uma região específica da imagem de entrada, sendo este conectado localmente e compartilhando os mesmos pesos com os demais neurônios do mesmo mapa. Após a convolução, aplica-se uma função de ativação não linear (geralmente a ReLU – *Rectified Linear Unit*) a fim de introduzir não linearidade ao modelo, permitindo a detecção de padrões mais complexos nas camadas subsequentes. A Figura 13 ilustra o processo de convolução, fundamental para o funcionamento das *CNNs*. Esse processo capacita a rede a identificar padrões visuais relevantes em diferentes escalas, contribuindo para a extração de características essenciais nas imagens analisadas.


Figura 14 - Processo de Convolução.

Fonte: PONTI, M. ET AL. (2017)

II - Função de Ativação: Após a convolução, as *CNNs* aplicam uma função de ativação não-linear, tais como: *ReLU (Rectified Linear Unit)*, *Sigmoid*, *Tanh* e *Softmax*. Essas funções possibilitam a modelagem de relações complexas entre as características extraídas. Essa camada é essencial para introduzir não-linearidades na rede, tornando-a mais adaptável a padrões intrincados.

III - Mapas de Ativação (ou de características): Cada neurônio convolucional gera um vetor, o qual é passado pela função de ativação e, a partir disso, é denominado mapa de ativação. Esses mapas são empilhados para formar um tensor que será utilizado como entrada para a próxima camada. A Figura 14 ilustra duas camadas convolucionais gerando mapas de características. Ao considerar uma imagem RGB com dimensões de 64x64x3, a primeira camada de convolução, utilizando 4 filtros de 5x5x3, gera um tensor de 64x64x4. Na segunda camada, a profundidade do tensor da camada anterior deve ser mantida. Cada filtro processa o tensor de maneira independente, gerando um único mapa de características.


Figura 15 - Ilustração de duas camadas convolucionais e seus mapas de ativação.



Fonte: Ponti, M. et al. (2017)

IV- Camada de Pooling: Frequentemente utilizado após algumas camadas convolucionais, o *pooling* reduz a resolução da imagem, diminuindo a dimensionalidade espacial do vetor. O método mais comum é o *max pooling*, onde apenas o valor máximo de cada unidade é transmitido para a saída. Nessa abordagem da Figura 15, para cada região percorrida, o valor máximo dentro do retângulo é retornado (GOODFELLOW; BENGIO; COURVILLE, 2016).

Figura 16 - Max pooling retângulo 2x2 e stride 2.



Fonte: RIZWAN, 2018.

Além dessas camadas principais, as *CNNs* podem incorporar outros componentes importantes:

I - Normalização: A normalização é outra técnica frequentemente aplicada aos dados de entrada e após as camadas convolucionais. Ela facilita o processo de otimização, pois ajuda a reduzir a variância do gradiente, tornando o

treinamento mais estável e eficiente.

II - Camada Totalmente Conectada (*Dense Layer*): Após várias camadas convolucionais, é comum adicionar camadas totalmente conectadas, que funcionam de forma semelhante às camadas ocultas de um *MLP* (*perceptron* multicamada). Essas camadas são responsáveis por aprender os pesos necessários para classificar a representação obtida até o momento.

III - Arquitetura CNN e seus Parâmetros: A arquitetura de uma rede neural convolucional descreve a organização típica das camadas convolucionais, incluindo os parâmetros de suas funções de ativação, *pooling* e, finalmente, uma série de camadas totalmente conectadas seguidas por funções de ativação. Um estudo aprofundado deve ser realizado para determinar a arquitetura que oferece o melhor desempenho para o projeto específico. As arquiteturas variam quanto à extração das características das imagens, ao tamanho e ao número de *kernels*, ao número de camadas e neurônios na fase de classificação, aos otimizadores utilizados, entre outros aspectos. Dentre as arquiteturas mais clássicas, destacam-se *AlexNet* (KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G.), (PONTI, M. *et al.*, 2017), *GoogLeNet* (SZEGEDY, C. *et al.*, 2016) e *ResNet* (HE, K.; ZHANG, X.; REN, S.; SUN, J.; 2015), VGG (SIMONYAN, K.; ZISSERMAN, A.; 2014).

IV - Função de Perda: A função de perda (ou custo) é uma medida utilizada para avaliar o desempenho do modelo. Durante o processo de otimização, a função de perda é escolhida para calcular o erro do modelo. As funções de erro médio quadrático (*mean squared error*) e entropia cruzada (*cross-entropy*) são algumas das mais utilizadas.

V - Otimização e Ajustes dos Algoritmos: Após a definição da função de perda, o objetivo é ajustar os parâmetros para minimizar a perda. O algoritmo de *gradient descent* (descida do gradiente) é o mais comum para essa tarefa, e o método de *backpropagation* é usado para calcular o gradiente dos pesos, aplicando a regra da cadeia. Esta etapa envolve o treinamento da rede, utilizando técnicas que buscam melhorar a eficiência e o tempo computacional do modelo, como inicialização de pesos, definição de *mini-batches*, *dropout*, normalização e *fine-tuning*. Para mais detalhes sobre essas técnicas, consulte Ponti, M. *et al.* (2017) e Haykin, S. (2009).

2.4.2.1 Aplicações das *cnns* na indústria

As Redes Neurais Convolucionais têm se destacado em aplicações industriais, principalmente no monitoramento de processos baseados em imagens e na previsão de qualidade de produtos. Em diversos processos industriais que envolvem dinâmicas térmicas ou a construção acelerada de peças, sensores de imagem em linha, como pirômetros e câmeras de alta velocidade, são utilizados para capturar imagens em tempo real. Esses dispositivos são essenciais para a avaliação da qualidade das peças durante a fabricação, permitindo ajustes imediatos no processo de produção. Entre as áreas que utilizam essa abordagem, destacam-se a manufatura aditiva, a soldagem por pontos de resistência e a fabricação de semicondutores.

Estudos recentes têm evidenciado a eficácia da aplicação de Redes Neurais Convolucionais na detecção e classificação de defeitos em contextos industriais, destacando sua relevância na automação e controle de qualidade. Weimer *et al.* (2016) desenvolveram um método automatizado de extração de características utilizando *CNNs*, com o objetivo de identificar e representar defeitos em processos de fabricação.

De forma complementar, Djenouri *et al.* (2017) aplicaram o modelo *FastRCNN* para construir um sistema de detecção de objetos capaz de identificar componentes com elevada precisão em imagens capturadas em fábricas inteligentes. Já Shi *et al.* (2018) implementaram uma *CNN* bidimensional voltada para a extração de informações geométricas a partir de projetos assistidos por computador (CAD), criando um esquema robusto para representação de características.

No setor de produção de revestimentos cerâmicos, a maioria dos defeitos é identificada na superfície dos produtos, demandando métodos específicos de inspeção (HANZAEI *et al.*, 2017). A detecção e classificação desses defeitos geralmente requerem a obtenção e processamento de imagens de superfície. Nesse contexto, Sanghadiya e Mistry (2015) analisaram e avaliaram diversas técnicas aplicáveis à detecção de defeitos superficiais em revestimentos cerâmicos, oferecendo uma visão abrangente sobre os métodos existentes.

Hanzaei *et al.* (2017) avançaram na área ao desenvolver um sistema automatizado para detecção e classificação de defeitos em revestimentos cerâmicos, integrando diferentes abordagens metodológicas. O sistema proposto combinou o operador de medida invariante de rotação de variância local, baseado em métodos

estatísticos, com o operador morfológico próximo, fundamentado em métodos estruturais, além de empregar uma Máquina de Vetores de Suporte (SVM) multiclasse. Essa combinação resultou em um sistema eficiente e adaptável para a identificação de falhas.

Por sua vez, Jajal e Dobariya (2021) propuseram um modelo baseado em visão artificial para a detecção de defeitos específicos localizados na área de borda de produtos cerâmicos. Embora limitado ao escopo das bordas, o modelo ilustra a viabilidade de sistemas especializados para análises direcionadas em produtos industriais.

Diniz *et al.* (2023) aplicaram redes neurais profundas para identificar diferentes patologias em estruturas de concreto, abrangendo problemas como rachaduras, fragmentação, eflorescências, manchas de corrosão e exposição de barras de aço. Essa abordagem automatizada mostrou-se eficiente na detecção e análise dessas falhas, contribuindo para a manutenção preventiva e corretiva em construções.

Esses estudos destacam a diversidade de abordagens tecnológicas desenvolvidas para atender às demandas de inspeção e controle de qualidade na indústria cerâmica. A aplicação de *CNNs* e outras técnicas de visão computacional tem demonstrado um impacto significativo na automação, promovendo maior eficiência e precisão na detecção e classificação de defeitos, consolidando essas ferramentas como indispensáveis no cenário industrial contemporâneo.

2.4.2.2 Aplicações em classificação de imagens

As Redes Neurais Convolucionais têm se destacado como uma das tecnologias mais eficazes para classificação de imagens, com aplicações que vão desde o reconhecimento facial até a análise de imagens médicas. Em um estudo pioneiro, Taigman *et al.* (2014) demonstraram que as *CNNs* podem alcançar uma precisão no reconhecimento facial comparável à precisão humana, um marco que ilustra o potencial dessas redes em aplicações que exigem alta acurácia e confiabilidade.

No ambiente industrial, as *CNNs* também têm sido amplamente aplicadas para identificar e classificar peças em linhas de produção. Ren *et al.* (2015), por exemplo, destacaram o uso de *CNNs* no desenvolvimento de sistemas de detecção de objetos, projetados especificamente para reconhecer componentes e produtos em tempo real dentro de fábricas. Essas redes permitem um controle de qualidade aprimorado e a

redução de erros durante a produção, tornando-se essenciais para processos industriais que demandam precisão e agilidade. As *CNNs* se destacaram em uma variedade de tarefas de classificação de imagens, incluindo:

I - Reconhecimento de Objetos: Identificação de objetos em imagens, como animais, veículos ou pessoas.

II - Reconhecimento Facial: Uso de *CNNs* para identificar e verificar rostos em imagens ou vídeos.

III - Diagnóstico Médico: Análise de imagens médicas, como raios-X, para detectar doenças ou condições.

IV - Visão em Veículos Autônomos: Classificação e detecção de objetos para navegação e tomada de decisão em veículos autônomos.

Esses exemplos evidenciam a versatilidade das *CNNs*, que desempenham um papel fundamental em setores diversos, tanto no uso cotidiano quanto em aplicações avançadas na Indústria 4.0. A capacidade de classificar imagens com precisão e rapidez transforma as *CNNs* em uma ferramenta indispensável para sistemas que exigem monitoramento e classificação automatizados, aumentando a eficiência e a confiabilidade dos processos industriais.

2.4.2.3 Inspeção automatizada

O desenvolvimento de métodos automáticos para a inspeção visual em sistemas industriais tem sido um foco crescente de pesquisa na área de Inteligência Artificial, com o objetivo de otimizar diversas tarefas, como a detecção de produtos defeituosos (WEIMER *et al.*, 2016), avaliação da qualidade de matérias-primas (Sun *et al.*, 2018), medições de formas e dimensionalidade (STAVROULAKIS *et al.*, 2019), montagens em linhas de produção (PITTINO *et al.*, 2020) e controle de qualidade de peças injetadas (DUARTE, 2019). Essas inovações são impulsionadas pela necessidade de maior eficiência e precisão nos processos de fabricação, alinhando-se às tendências industriais mais recentes, que buscam não apenas automação, mas também maior qualidade e produtividade no ciclo de produção.

O surgimento dos primeiros estudos sobre inspeção automatizada remonta ao início do século 20, quando os pesquisadores começaram a compreender os fatores que impactam no desempenho dos processos de inspeção (SEE, 2012; 2015). No

entanto, as maiores inovações na área só começaram a surgir na década de 1950, impulsionadas pela Revolução Industrial e pelo advento da automação. Naquela época, os processos industriais ainda dependiam fortemente da inspeção manual após a produção para garantir a qualidade, o que resultava em rendimentos ineficazes ou contraproducentes, uma vez que as inspeções manuais, apesar de necessárias, eram suscetíveis a erros humanos e ineficiência.

Essa limitação motivou a busca por soluções que pudessem inspecionar todo o ciclo de produção, não apenas no final do processo. A automação se tornou um fator chave para essa transformação, permitindo a implementação de técnicas de detecção e medição mais avançadas, além de facilitar o armazenamento e a análise de grandes volumes de dados de imagens (PONTI *et al.*, 2017).

Esse avanço tecnológico é refletido em pesquisas recentes que aplicam técnicas de aprendizado profundo na inspeção visual de materiais industriais. FLAH *et al.* (2020) propuseram um modelo automatizado de inspeção para detectar defeitos em áreas de difícil acesso em estruturas de concreto, utilizando processamento de imagem e aprendizado profundo. O modelo foi treinado com 10.000 imagens, divididas igualmente entre aquelas com rachaduras e sem rachaduras. A precisão obtida foi de 98,25%, evidenciando a eficácia do modelo na detecção de defeitos, sem evidências de *overfitting*. Esse estudo reforça a crescente tendência de utilizar redes neurais para aprimorar a eficiência da inspeção visual, especialmente em ambientes de difícil acesso, onde métodos manuais podem ser arriscados ou inviáveis.

Arafin *et al.* (2022), por sua vez, realizaram um estudo comparativo de diferentes modelos de redes neurais convolucionais (CNNs) na detecção de rachaduras e descamação em superfícies de concreto. Os modelos VGG-19, ResNet-50, InceptionV3, Xception e MobileNetV2 foram utilizados, com o modelo InceptionV3 se destacando, alcançando uma acurácia de 91%, precisão de 82% e *recall* de 100%. Esse estudo demonstra que, mesmo com uma grande variedade de modelos, as CNNs continuam sendo uma das abordagens mais eficazes para a inspeção de materiais, mostrando que sua implementação pode ter um impacto significativo na indústria da construção.

KIM *et al.* (2020) também exploraram a aplicação de deep learning para detectar rachaduras e analisar suas características, como comprimento e largura, em instalações de pequena escala. O estudo foi dividido em três estágios, sendo os dois primeiros focados na detecção de rachaduras utilizando um banco de 40.000 imagens,

divididas igualmente em duas classes: com e sem rachaduras. Após a detecção, algoritmos de desbaste e rastreamento foram aplicados para medir as dimensões das rachaduras.

Os resultados demonstraram uma acurácia de 99% na detecção das rachaduras. No entanto, os autores sugerem que o método seja validado com um conjunto de dados maior antes de sua aplicação prática. Este estudo sublinha o grande potencial das técnicas de *deep learning* para a detecção precisa de rachaduras, embora a validação em um contexto real seja essencial para garantir a robustez do modelo.

Dung e Anh (2019) apresentaram outra abordagem ao utilizar uma rede totalmente convolucional profunda (FCN) para a detecção de fissuras em imagens de concreto. O modelo foi treinado com um conjunto de dados público contendo 40.000 imagens de fissuras, utilizando as arquiteturas VGG16, *ResNet* e *InceptionV3*. O modelo baseado na arquitetura VGG16 obteve os melhores resultados, com uma precisão de 89,3% e *F1-score* de 89,3%. Esse trabalho reflete o avanço contínuo das *CNNs* na análise de defeitos em materiais de concreto, mostrando como diferentes arquiteturas podem ser aplicadas para otimizar os resultados dependendo do tipo de dado.

Esses estudos demonstram como a automação e a Inteligência Artificial, especialmente o uso de redes neurais convolucionais, têm se tornado fundamentais para a evolução das técnicas de inspeção visual na indústria. A implementação de métodos automatizados não só melhora a precisão e a eficiência do controle de qualidade, mas também reduz custos operacionais e aumenta a segurança, ao eliminar a necessidade de inspeções manuais em condições perigosas. Com o contínuo aprimoramento dessas tecnologias, a tendência é que cada vez mais processos industriais integrem essas soluções, tornando a inspeção visual mais inteligente, ágil e acessível, além de possibilitar sua aplicação em uma gama ainda maior de materiais e situações industriais.

2.5 PROCESSAMENTO DIGITAL DE IMAGENS

A área de processamento digital de imagens possui duas principais áreas de aplicação, conforme descrito por Marques Filho e Vieira Neto (1999) e Gonzalez e Woods (2018). A primeira área, conhecida como processamento de imagens,

concentra-se na melhoria da qualidade visual para facilitar a interpretação humana. Esse enfoque inclui o uso de técnicas e algoritmos que aprimoram atributos como nitidez, contraste e resolução, tornando as imagens mais claras e compreensíveis. Aplicações dessa área são frequentes em setores como medicina, análise de imagens de satélite e análise forense, onde a qualidade visual é essencial para interpretar detalhes relevantes.

A segunda área abrange a análise de imagens, visão computacional e reconhecimento de padrões. Nessa vertente, o processamento de dados de imagem é orientado a tarefas específicas, como armazenamento, transmissão e extração de informações visuais. Aqui, são aplicadas técnicas avançadas para identificar elementos essenciais nas imagens, incluindo detecção de objetos, segmentação de regiões de interesse e reconhecimento de padrões, o que possibilita uma análise automatizada. As aplicações desta área incluem inteligência artificial, processamento de imagens e vídeo, entre outros campos (GONZALEZ e WOODS, 2018).

Assim, o processamento digital de imagens abrange tanto o aprimoramento visual para a interpretação humana quanto a extração de informações para análise automatizada. Essas duas abordagens sustentam áreas dedicadas ao processamento de imagens, análise de imagens, visão computacional e reconhecimento de padrões.

Segundo Marques Filho e Vieira Neto (1999), um Sistema de Visão Artificial (SVA) é um sistema computadorizado capaz de adquirir, processar e interpretar imagens provenientes de cenas reais. As principais etapas de um SVA incluem: aquisição de imagens, pré-processamento, segmentação, extração de características, reconhecimento e interpretação, além de uma base de conhecimento que apoia o sistema.

2.5.1 Aquisição de Imagens

A aquisição de imagens é o processo de conversão de uma cena tridimensional real em uma representação bidimensional, inicial e analógica. Esse processo requer dois componentes principais: um sensor, responsável por converter a informação óptica em um sinal elétrico, e um digitalizador, que transforma esse sinal analógico em uma imagem digital. Dispositivos como câmeras fotográficas, câmeras de vídeo e termovisores desempenham esse papel ao capturar a cena tridimensional e traduzi-la para uma forma bidimensional (MARQUES FILHO e VIEIRA NETO, 1999;

GONZALEZ e WOODS, 2018).

Após essa conversão inicial, a imagem capturada passa por etapas essenciais de discretização espacial e de amplitude, denominadas amostragem e quantização, respectivamente. Essas etapas são indispensáveis para adequar a imagem ao processamento computacional (MARQUES FILHO e VIEIRA NETO, 1999; GONZALEZ e WOODS, 2018).

No processo de amostragem, a imagem analógica é convertida em uma matriz de M por N pontos, onde cada ponto é chamado de pixel ou elemento de imagem. Esse processo é descrito por uma função de intensidade, conforme indicado na Equação (1).


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

A quantização, por sua vez, atribui a cada pixel um valor inteiro dentro de uma faixa de 0 a 2^n-1 , onde n representa a profundidade de bits. Quanto maior o valor de n, maior é a quantidade de níveis de cinza disponíveis na imagem digitalizada. A função de intensidade $f(x, y)$ pode assumir diferentes faixas de valores, de acordo com o tipo de imagem:

- Imagens Binárias: $f(x, y) \in \{0, 1\}$;
- Níveis de Cinza: $0 \leq f(x, y) \leq 255$ (correspondente a 2^8 , onde 8 é a resolução ou profundidade de bit);
- Imagens Coloridas: $f(x, y)$ representa um índice em uma tabela de cores.

Assim, uma imagem monocromática pode ser descrita matematicamente pela função $f(x, y)$, que indica a intensidade luminosa em um ponto específico. O valor de $f(x, y)$ em qualquer coordenada (x, y) é proporcional ao brilho ou nível de cinza da imagem naquele ponto (MARQUES FILHO e VIEIRA NETO, 1999). A Figura 17 apresenta uma imagem monocromática junto com a convenção dos eixos.

Figura 17 - Imagem monocromática e convenção do par de eixos (x, y) .



Fonte: Autora (2025)

A função $f(x, y)$ representa o resultado da interação entre a iluminância $i(x, y)$ que expressa a quantidade de luz incidente sobre o objeto, e as propriedades de reflectância ou transmitância do objeto, descritas pela função $r(x, y)$. O valor de $r(x, y)$ varia de 0 a 1, indicando a fração de luz incidente que o objeto reflete ou transmite no ponto (x, y) . Assim, a função $f(x, y)$ é dada pelo produto entre $i(x, y)$ e $r(x, y)$ (MARQUES FILHO e VIEIRA NETO, 1999).

No contexto da produção de telhas cerâmicas, a aquisição de imagens é uma etapa fundamental. A captura e análise adequadas dessas imagens permitem uma compreensão detalhada das características intrínsecas das telhas, possibilitando a detecção precoce de defeitos, a avaliação da qualidade e o aprimoramento contínuo dos processos de fabricação.

2.5.2 Pré-Processamento de Imagem

O pré-processamento de imagem tem como principal objetivo aprimorar a qualidade da imagem para as etapas subsequentes de processamento. As operações realizadas nessa fase são consideradas de baixo nível, pois atuam diretamente sobre os valores de intensidade dos pixels da imagem. Como resultado, obtém-se uma versão digitalizada de qualidade superior à original (MARQUES FILHO e VIEIRA NETO, 1999; GONZALEZ e WOODS, 2018).


Essa etapa inclui uma ampla variedade de técnicas e procedimentos, tais como transformações de cores, operações lógicas e aritméticas, transformações

geométricas, ajustes de histograma, filtragem, realce e suavização de imagens, além da aplicação de morfologia matemática. Cada um desses métodos contribui para a qualidade visual e a precisão da imagem processada.

O processamento de imagem, por sua vez, consiste em um conjunto de técnicas utilizadas para capturar, representar e transformar imagens por meio de um computador, com o propósito de aprimorar sua qualidade visual. Entre os métodos aplicados, destacam-se a redução de ruídos, a correção de contraste e brilho, e a suavização de certas propriedades da imagem (PEDRINE; SCHWARTZ, 2008).

Esse processo é realizado em etapas estrategicamente delineadas, que compartilham informações interligadas, de forma que cada fase influencia diretamente as seguintes. De acordo com Gonzalez E Woods (1992), as etapas essenciais do processamento de imagem são: aquisição da imagem, pré-processamento, segmentação, descrição, reconhecimento e interpretação. A Figura 18 ilustra o fluxo dessas etapas.

Figura 18 - Etapas fundamentais no processamento de imagens digitais.



Fonte: Gonzalez & Woods, 1992.

As ferramentas de processamento de imagem possibilitam a execução de diversas tarefas, simulando parcialmente a percepção visual humana, um dos maiores desafios no campo da inteligência artificial.


2.5.2.1 Modelo RGB

As imagens binárias ou monocromáticas (em tons de cinza) são representadas

por matrizes unidimensionais. O modelo RGB é representado por três matrizes bidimensionais, que correspondem aos canais de cor: vermelho (R), verde (G) e azul (B). Cada matriz armazena valores inteiros que indicam a intensidade de cor de cada pixel na imagem, variando entre 0 e 255, em uma escala de 8 bits.

O modelo RGB pode ser visualizado geometricamente como um cubo, em que os vértices representam as cores primárias (vermelho, verde e azul) e secundárias (ciano, magenta e amarelo). Nesse espaço tridimensional, o preto está localizado na origem (coordenada $[0,0,0]$), enquanto o branco ocupa o vértice oposto mais distante (coordenada $[255,255,255]$). A diagonal que conecta esses dois vértices (preto e branco) representa a escala de cinza, que abrange todos os tons intermediários de luminância (GONZALEZ; WOODS, 2010). A Figura 19 ilustra a estrutura do modelo RGB.

Figura 19 - Estrutura do modelo RGB.




Fonte: GONZALEZ, WOODS (2010)

Em contrapartida, as imagens coloridas são formadas por matrizes de intensidade, em que cada elemento é um vetor tridimensional que, no modelo RGB (*Red, Green e Blue*), representa as componentes de cor R (vermelho), G (verde) e B (azul) de cada pixel.

Uma das transformações de cor mais utilizadas no processamento de imagens é a conversão de uma imagem colorida para tons de cinza. A Figura 20, mostra como acontece o processo de aplicação de filtros para obtenção imagem colorida.

Figura 20 - Aplicação de filtros para obtenção imagem colorida.



Fonte: GONZALEZ, WOODS (2010).

Esse processo pode ser realizado por diferentes métodos, conforme discutido por KUMAR e VERMA (2010) e PADMAVATHI e THANGADURAI (2016). Um método comum para realizar essa conversão envolve a aplicação de uma operação específica em cada pixel da imagem, conforme descrito na Equação (2).

$$f(x, y) = \frac{R(x, y) + G(x, y) + B(x, y)}{3} \quad (2)$$


As matrizes R, G e B correspondem, respectivamente, aos componentes vermelho, verde e azul de uma imagem colorida. Além da conversão para tons de cinza, outra transformação de cor amplamente utilizada é a conversão de uma imagem em tons de cinza para uma imagem binária (preto e branco) (SZELISKI, 2010). Essa conversão é feita através de uma operação de limiarização, descrita na Equação (3).

$$f(x, y) = \begin{cases} 1, & \text{se a intensidade em } (x, y) > \text{limiar} \\ 0, & \text{se a intensidade em } (x, y) < \text{limiar} \end{cases} \quad (3)$$

O valor de limiar comumente adotado é 127 ou 128, mas pode variar conforme o efeito desejado, seja para aproximar a imagem mais do preto ou do branco. A seleção do limiar ideal é específica para cada aplicação e pode ser determinada por métodos de limiarização, sendo uma etapa fundamental no processo de binarização da imagem.

Outra técnica importante é a transformação de intensidade linear, que tem como objetivo expandir a escala de tons de cinza para que a imagem ocupe todo o intervalo possível, de 0 a 255. Esse processo, conhecido como autoescala, busca maximizar o contraste e realçar os detalhes da imagem, proporcionando uma visualização mais clara e nítida das informações presentes (MARQUES FILHO e VIEIRA NETO, 1999). A Figura 21 ilustra o processo de limiarização, destacando como essa técnica pode ser empregada para segmentar elementos específicos na imagem, facilitando a análise e a extração de características relevantes.

Figura 21 - Processo de limiarização.



Fonte: (FILHO; NETO, 1999).

Para um sistema que opera com 256 níveis de cinza, a função de autoescala pode ser implementada calculando, para cada pixel com intensidade f , o nível de cinza resultante g , conforme descrito na Equação (4).

$$g(x, y) = \frac{255}{f_{max} - f_{min}} * [f(x, y) - f_{min}] \quad (4)$$

Na Equação 4, f_{max} e f_{min} representam, respectivamente, os níveis máximo e mínimo de cinza presentes na imagem original.

2.5.3 Segmentação

A segmentação de imagens é uma etapa fundamental no processo de análise de imagens, cuja finalidade é dividir uma imagem em regiões visualmente homogêneas ou que representem objetos ou partes de objetos (ZERDOUMI et al., 2018). Esse processo permite isolar os elementos de interesse na imagem, facilitando o trabalho com esses componentes individualmente e permitindo uma análise mais precisa e detalhada dos objetos de estudo.

Entre as técnicas de segmentação destacam-se a busca pela região de interesse e a detecção de anomalias, que empregam métodos como limiarização e redes neurais artificiais, incluindo arquiteturas específicas (MOGHADDAM et al., 2016). A segmentação classifica pixels em grupos com características similares, como níveis de cinza ou texturas homogêneas, atendendo a condições de homogeneidade relacionadas à similaridade de tons, textura, entropia, entre outros critérios que caracterizam as vizinhanças dos pixels (MARQUES FILHO e VIEIRA NETO, 1999; GONZALEZ e WOODS, 2000). Dessa forma, a segmentação torna possível o isolamento dos objetos de interesse, o que resulta em uma análise mais detalhada e permite a manipulação individual desses elementos.

As *CNNs* desempenham um papel importante na segmentação de imagens e no processamento avançado de dados visuais. Um exemplo significativo é o estudo realizado por Minnema et al. (2018), que utilizou *CNNs* para segmentar imagens de tomografia computadorizada (TC) com o objetivo de criar modelos de superfície 3D para manufatura aditiva. As *CNNs* demonstraram ser uma alternativa eficaz aos métodos tradicionais de segmentação baseados em limiar, oferecendo maior precisão e adaptabilidade em cenários complexos.

2.5.4 Extração de Características e Classificação em Imagens

Após a etapa de segmentação, os conjuntos de pixels resultantes devem ser convertidos em representações adequadas para o processamento computacional subsequente. Essa conversão é realizada por meio da extração de características,

que consiste na identificação e quantificação de atributos relevantes das regiões segmentadas. Em imagens binárias, destacam-se propriedades geométricas fundamentais, como área, posição (centro de massa), orientação e dimensões (comprimento e largura), que fornecem informações essenciais para análises posteriores (GONZALEZ; WOODS, 2018).

Recomenda-se, sempre que possível, aplicar técnicas de pré-processamento às imagens de entrada antes da extração de características. Essa etapa é especialmente importante em situações em que há variações acentuadas na iluminação, as quais podem prejudicar a detecção precisa de atributos relevantes. O objetivo do pré-processamento é minimizar tais distorções e normalizar a imagem, proporcionando uma base mais estável e confiável para a extração dos dados (GONZALEZ; WOODS, 2018).

Dentre as técnicas mais utilizadas nesse processo, destacam-se a equalização de histograma, a correção de contraste e a aplicação de filtros para remoção de ruídos. O resultado é uma imagem aprimorada, que favorece a identificação de atributos descritivos de forma mais precisa e robusta (GONZALEZ; WOODS, 2018).

A etapa de classificação consiste na organização das instâncias com base nas características extraídas, visando ao reconhecimento de padrões e objetos homogêneos. De acordo com FONSECA (2000), o principal objetivo da classificação é inferir a classe associada a um padrão de características, considerando o conjunto de atributos previamente identificado. No contexto de redes neurais, essa inferência é realizada através de funções de ativação que mapeiam características aprendidas para distribuições de probabilidade sobre as classes (GOODFELLOW *et al.*, 2016). Esse mecanismo permite que modelos baseados em *CNNs*, como o proposto neste estudo, classifiquem padrões complexos mesmo sob variabilidade morfológica (ex.: trincas em telhas).

No campo da visão computacional, a classificação de objetos constitui um desafio relevante, principalmente quando associada à tomada de decisões automatizadas (STEMMER *et al.*, 2005). A complexidade desse processo está fortemente vinculada à quantidade e à qualidade das informações disponíveis, o que influencia diretamente na acurácia dos resultados (MACHADO, 2008).

Um exemplo de aplicação prática está na detecção e classificação de defeitos

em produtos industriais. Nesse contexto, a classificação permite identificar não apenas a existência de uma falha, mas também seu tipo específico, fornecendo subsídios valiosos para diagnósticos precisos e ações corretivas. Em indústrias de telhas cerâmicas, a classificação via *CNNs* possibilita maior controle de qualidade, redução de desperdícios e melhorias contínuas no processo produtivo.

2.6 TREINAMENTO DO MODELO

O processo de treinamento de uma rede neural consiste em capacitá-la para lidar adequadamente com um determinado conjunto de dados e com a tarefa-alvo. Essa etapa pode ocorrer de forma mais manual ou automatizada, a depender da abordagem empregada. Em linhas gerais, existem três principais paradigmas de treinamento: supervisionado, não supervisionado e semi-supervisionado (RUSSELL; NORVIG, 2013).

No contexto desta pesquisa, o treinamento supervisionado foi adotado para classificação de defeitos em telhas cerâmicas, com imagens rotuladas como 'normal e defeituosa'. Essa abordagem permite à *CNN* aprender padrões morfológicos sutis (ex.: microtrincas) que seriam negligenciados em métodos não supervisionados.

No treinamento supervisionado, os dados estão previamente rotulados, e o modelo aprende a associá-los às categorias correspondentes com base nesses rótulos. Já no treinamento não supervisionado, não há rotulagem prévia, cabendo ao modelo identificar padrões e agrupar os dados com base em similaridades intrínsecas. Por fim, o treinamento semi-supervisionado combina ambas as abordagens, utilizando uma parte dos dados rotulada e outra não rotulada, o que permite ao modelo aprender a partir de uma quantidade limitada de exemplos supervisionados (RUSSELL; NORVIG, 2013).

O treinamento de uma Rede Neural Convolucional (*CNN*) é, em geral, conduzido por meio de algoritmos de aprendizado supervisionado, que ajustam os pesos dos filtros e das conexões com base na minimização de uma função de custo. Essa função quantifica o erro entre a saída produzida pela rede e a saída esperada (rótulo) para cada amostra de entrada. Um dos algoritmos mais empregados para essa tarefa é o Gradiente Descendente Estocástico (SGD), que atualiza os pesos da rede em pequenos passos na direção oposta ao gradiente da função de custo,

permitindo um aprendizado eficiente e contínuo (RUDER, 2016).

Durante esse processo, ocorrem sucessivas atualizações dos pesos nas camadas convolucionais e totalmente conectadas, por meio de iterações que envolvem a propagação direta dos dados (*forward pass*) e o ajuste dos erros por retropropagação (*backpropagation*). Esse mecanismo permite à rede refinar seus parâmetros internos a cada ciclo de treinamento, visando reduzir progressivamente a discrepância entre a previsão gerada e o valor esperado (GOODFELLOW; BENGIO; COURVILLE, 2016).

Para que o treinamento seja eficaz, é necessário dispor de um conjunto de dados robusto e representativo. Esse conjunto é normalmente dividido em três subconjuntos: treinamento, validação e teste. A divisão estratificada garantiu proporcionalidade entre classes (normal/defeituosa), e o conjunto de teste foi composto exclusivamente por telhas capturadas em diferentes turnos de produção para validar robustez. No caso de uma tarefa de classificação binária supervisionada, o grupo de treinamento é utilizado para que a rede aprenda a distinguir as classes com base nos rótulos. Durante esse processo, a cada época de treinamento, os pesos e *biases* da rede são ajustados, com o objetivo de minimizar o erro e melhorar a acurácia na predição das classes.

Para que o treinamento seja eficaz, é necessário dispor de um conjunto de dados robusto e representativo. Esse conjunto é normalmente dividido em três subconjuntos: treinamento, validação e teste. No caso de uma tarefa de classificação binária supervisionada, o grupo de treinamento é utilizado para que a rede aprenda a distinguir as classes com base nos rótulos. Durante esse processo, a cada época de treinamento, os pesos e *biases* da rede são ajustados, com o objetivo de minimizar o erro e melhorar a acurácia na predição das classes.

O conjunto de validação permite avaliar se a rede está, de fato, aprendendo de forma generalizável ou apenas memorizando os exemplos do treinamento — fenômeno conhecido como *overfitting*. Por fim, o conjunto de teste é composto por dados inéditos, não utilizados em nenhuma etapa anterior, e tem a função de avaliar o desempenho final da rede frente a novas instâncias (DSA, 2023).

É fundamental que o conjunto de dados seja balanceado, ou seja, contenha uma distribuição equilibrada entre as classes. Desequilíbrios podem introduzir vieses

no treinamento, afetando a qualidade dos ajustes e comprometendo as métricas de desempenho. Um conjunto desbalanceado pode induzir o modelo a privilegiar a classe majoritária, reduzindo a capacidade de acerto da classe minoritária e elevando o risco de *overfitting*. Para lidar com essa limitação, podem ser empregadas técnicas como *oversampling* (reduplicação de exemplos da classe minoritária) e *weighted loss* (ponderação da função de perda com pesos ajustados por classe) (GUO (A); WANG et al., 2020).

O *overfitting*, ou sobreajuste, é uma das principais preocupações no treinamento de redes neurais. Ele ocorre quando o modelo apresenta desempenho elevado nos dados de treinamento, mas falha em generalizar para novos dados. Uma das causas comuns é o super treinamento, quando a rede começa a ajustar seus parâmetros apenas para minimizar o erro do conjunto de treinamento, sem efetiva aprendizagem.

Para evitar esse problema, técnicas como o *early stopping* são amplamente utilizadas. Esse método interrompe o treinamento automaticamente quando o desempenho no conjunto de validação deixa de melhorar, impedindo o sobreajuste. Outra estratégia eficaz é a aplicação do *dropout*, técnica em que determinados neurônios são desativados aleatoriamente durante o treinamento. Isso impede a coadaptação excessiva entre os neurônios e promove uma aprendizagem mais robusta e generalizável (DSA, 2023).

Concluído o processo de treinamento, torna-se essencial avaliar a qualidade do modelo com base em métricas apropriadas. Essas métricas de desempenho permitem verificar se a rede está obtendo resultados satisfatórios, e serão detalhadas na próxima seção.

2.7 MÉTRICAS DE VALIDAÇÃO

As métricas de validação consistem em indicadores quantitativos e, em alguns casos, representações gráficas que permitem avaliar, de forma objetiva, o desempenho de um modelo de classificação. Essas métricas são fundamentais para interpretar os resultados obtidos por uma Rede Neural Convolucional (CNN) após o treinamento e verificar sua capacidade de generalização frente a novos dados.

Dentre os instrumentos analíticos mais relevantes nesse contexto, destaca-se

a matriz de confusão, a qual organiza os resultados da classificação em uma estrutura tabular que compara as previsões realizadas pelo modelo com os rótulos reais dos dados. Na matriz de confusão, os valores na diagonal principal representam as classificações corretas, enquanto os valores, fora dessa diagonal indicam erros cometidos pelo modelo, como falsos positivos (FP) e falsos negativos (FN), que correspondem aos erros de tipo 1 e tipo 2, respectivamente. Na tabela 1 é possível observar a configuração de matrizes de confusão.

Tabela 2 - Matriz de confusão.

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

Fonte: Autora (2025)

A matriz de confusão é uma ferramenta fundamental para avaliar a eficácia de um modelo de classificação binária (ALPAYDIN, 2020). Ela permite visualizar a distribuição dos acertos e erros do modelo, dividindo as previsões em quatro categorias: Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP) e Falsos Negativos (FN). Goodfellow *et al.* (2016) destacam que a análise da matriz de confusão é essencial para identificar desequilíbrios no desempenho do modelo, possibilitando ajustes na sensibilidade e especificidade.

No contexto específico de uma classificação binária, a análise de desempenho é baseada em métricas que consideram quatro tipos de resultados possíveis, conforme descrito na Tabela 03.

Tabela 03 - Resultados de classificações possíveis.

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

Fonte: Autora (2025)

A partir dos valores extraídos da matriz de confusão, é possível obter as métricas de assertividade de acurácia, precisão, sensibilidade, especificidade e F-

Score. Essas métricas são amplamente reconhecidas como métodos eficazes para mensurar o desempenho de modelos preditivos, sendo recomendadas por autores como GÉRON (2019), GOODFELLOW *et al.* (2016), MURPHY (2012) e BISHOP (2006).

A acurácia, cuja formula está apresentada na Equação (5) representa a proporção de previsões corretas em relação ao total de amostras avaliadas, sendo uma métrica simples e intuitiva para análise inicial de um modelo (MURPHY, 2012). É calculada pela razão entre a soma dos verdadeiros positivos e verdadeiros negativos e o número total de previsões.

$$Acurácia = \frac{VP+VN}{(VP+VN+FP+FN)} \quad (5)$$

A precisão, Equação (6) é a razão entre a quantidade de amostras classificadas corretamente como positivas pelo modelo e o total de amostras que foram de fato classificadas como positivas, dando maior ênfase aos erros de Falsos Positivos (RASCHKA & MIRJALILI, 2019).

$$Precision = \frac{VP}{(VP+FP)} \quad (6)$$

A Recall, Equação (7), mede a capacidade do modelo de identificar todos os exemplos positivos de uma classe (GERON, 2019). É calculada pela razão entre os verdadeiros positivos e a soma dos verdadeiros positivos e falsos negativos. GOODFELLOW *et al.* (2016) destacam que a recall é essencial em problemas onde é crucial minimizar a ocorrência de falsos negativos, como no controle de qualidade industrial, onde é importante detectar todos os defeitos.

$$Recall = \frac{VP}{(VP+FN)} \quad (7)$$

O *F1-Score* Equação (8), é a média harmônica entre a Precisão e o *Recall*, proporcionando um equilíbrio entre ambas e assegurando um desempenho consistente do modelo (GOODFELLOW, BENGIO & COURVILLE, 2016).

$$F1 - Score = \frac{2*(Precisão*Revocação)}{(Precisão+Revocação)} \quad (8)$$

O *F1-Score* é particularmente útil para evitar um viés exagerado em favor de uma das métricas (precisão ou recall), penalizando cenários em que uma das métricas é baixa. Diferente da média aritmética, o *F1-Score* exige que precisão e recall estejam em níveis equilibrados para alcançar um valor elevado. Seu valor varia de 0 a 1, onde 1 indica desempenho perfeito, com alta precisão e recall.

Essas métricas de avaliação permitem uma análise abrangente do desempenho do modelo, considerando não apenas sua capacidade de acerto, mas também a qualidade das previsões em diferentes aspectos. A combinação dessas métricas oferece uma visão detalhada da eficácia do modelo na tarefa de classificação, possibilitando ajustes precisos e melhorias no processo de detecção de defeitos em telhas cerâmicas. A análise rigorosa dessas métricas, conforme discutido por GOODFELLOW *et al.* (2016) e MURPHY (2012), é essencial para garantir que o modelo atenda aos requisitos de qualidade e precisão necessários para sua aplicação prática no controle de qualidade industrial.

3 MATERIAIS E MÉTODOS

Esta seção apresenta, de forma sistemática, os procedimentos empregados para o desenvolvimento e a avaliação do modelo de classificação de defeitos em telhas cerâmicas por meio de Redes Neurais Convolucionais. As etapas metodológicas adotadas são: Aquisição de Dados, Banco de Dados, Ambiente de Desenvolvimento, Preparação dos Dados, Divisão da Base de Dados, Pré-processamento de Dados, Arquitetura da CNN, Treinamento do Modelo e Métricas de Validação.

A metodologia proposta foi elaborada com o objetivo de assegurar a reprodutibilidade dos experimentos e a confiabilidade dos resultados, atendendo aos requisitos de robustez técnica e precisão exigidos em aplicações industriais de visão computacional.

A Figura 22 apresenta o fluxograma que sintetiza, de forma visual, as etapas que compõem o processo metodológico adotado neste estudo.

Figura 22 - Fluxograma da metodologia.



Fonte: Autora (2025).

3.1 AQUISIÇÃO DE DADOS

A coleta de dados foi realizada por meio de visitas técnicas à linha de produção de uma indústria de cerâmica vermelha localizada na cidade de Teresina (PI), Brasil. O objetivo dessas visitas foi compreender detalhadamente o processo de fabricação das telhas cerâmicas e capturar imagens representativas para compor o banco de

dados utilizado no presente estudo.

Esta pesquisa adotou uma abordagem experimental para o desenvolvimento de um sistema automatizado de detecção de defeitos em telhas cerâmicas. A metodologia evoluiu de técnicas termográficas iniciais — que se mostraram inviáveis — para uma solução baseada em visão computacional com redes neurais convolucionais (CNNs). As etapas seguiram a seguinte sequência:

- (i) aquisição de imagens termográficas e análise de viabilidade;
- (ii) coleta de imagens no espectro visível;
- (iii) pré-processamento e aumento de dados;
- (iv) modelagem e treinamento da CNN;
- (v) avaliação do modelo com métricas de desempenho.

3.1.1 Protocolo Termográfico

A etapa de termografia visou identificar defeitos superficiais em telhas cerâmicas mediante o contraste térmico entre áreas íntegras e regiões comprometidas. Fundamentou-se na hipótese de que o processo de secagem a vapor — utilizado pela fábrica para remoção de umidade — geraria gradientes térmicos detectáveis em regiões com falhas estruturais.

O experimento termográfico foi conduzido com duas câmeras de diferentes configurações técnicas, de modo a equilibrar resolução espacial e sensibilidade térmica. As especificações estão apresentadas na tabela 4.

Tabela 4 - Características técnicas das câmeras utilizadas.

Parâmetro	Câmera HT-02D	Câmera A-BF RX 300
Resolução	240 × 320 pixels	240 × 240 pixels
Sensibilidade	0.10°C	0.05°C (superior)
Emissividade (ε)	0.95 (fixa)	0.92 (fixa)
Critério de Seleção	Maior resolução espacial	Maior sensibilidade térmica

Fonte: Autora (2025)

3.1.2 Protocolo Experimental

a) Preparação das amostras

- Telhas posicionadas individualmente sobre superfície neutra;
- Coleta realizada após secagem natural e antes da queima industrial.


b) Captura termográfica

- **Fase 1 (Pré-secagem):** Imagens registradas antes da entrada no secador a vapor (Figuras 24a e 25a);
- **Fase 2 (Pós-secagem):** Imagens registradas imediatamente após a saída do secador (Figuras 24b e 25b), com intervalo máximo de 1 hora entre as fases.

c) Condições de controle

- Distância fixa entre câmera e amostra: 0,5 m;
- Emissividade calibrada para cerâmica úmida ($\epsilon \geq 0,92$);


Figura 23 - Fluxograma do Protocolo Experimental



Fonte: Autora (2025)


As Figuras 24 e 25 apresentam, respectivamente, as termografias obtidas pela câmera A-BF RX 300 e as imagens térmicas da câmera HT-02D, nas condições pré e pós-secagem.

Figura 24 - Termografias obtidas pela câmera A-BF RX 300: (a) antes da secagem; (b) após a secagem.



Fonte: Autora (2025)

Figura 25 - Imagens térmicas obtidas pela câmera HT-02D: (a) antes da secagem; (b) após a secagem.



Fonte: Autora (2025)

3.1.3 Análise Termográfica

A análise quantitativa e visual das Figuras 24 e 25 evidencia um aumento expressivo nas temperaturas médias e máximas após o processo de secagem, confirmando a ocorrência da transferência térmica prevista. Os valores correspondentes encontram-se detalhados na Tabela 5.

Tabela 5 - Comparação dos dados térmicos obtidos pelas câmeras A-BF RX 300 e HT-02D antes e após o processo de secagem.

Situação	Equipamento	Emissividade	Temperatura Central (°C)	Temperatura Mínima (°C)	Temperatura Máxima (°C)	Amplitude Térmica (ΔT)
Antes da secagem (a)	A-BF RX 300	0,92	35,1	32,5	36,5	4,0
	HT-02D	0,95	35,5	30,9	36,2	5,3
Após a secagem (b)	A-BF RX 300	0,92	68,7	33,5	73,3	39,8
	HT-02D	0,95	43,2	29,4	44,2	14,8

Fonte: Autora (2025)

A análise mostra que, embora ambas as câmeras tenham registrado aumento significativo nas temperaturas centrais e máximas após a secagem, a elevada amplitude térmica (14,8–39,8 °C) mascarou os contrastes sutis (<0,5 °C) esperados em regiões com defeitos. Esse efeito é consistente com as limitações relatadas por Cumbajin *et al.* (2024) e Kosmas *et al.* (2021), que apontam que a homogeneização térmica e o efeito da radiação global emitida pela superfície aquecida dificultam a detecção de microvariações térmicas em materiais cerâmicos.

Além disso, diferenças nos valores absolutos entre as câmeras refletem variações de sensibilidade dos sensores, configuração de emissividade e tempo de captura. Ainda que o comportamento relativo (antes vs. depois) tenha se mantido consistente, a técnica mostrou-se inviável para detectar defeitos superficiais sutis nas condições experimentais adotadas.

Diante dessa limitação e do custo elevado de equipamentos termográficos de alta precisão, optou-se pela migração para uma metodologia baseada no espectro visível, utilizando redes neurais convolucionais (CNNs). Essa abordagem, segundo Wan *et al.* (2022) e Wang *et al.* (2025), apresenta desempenho superior na detecção de padrões texturais e visuais em produtos cerâmicos, com potencial para aplicação em ambientes industriais em tempo real.

3.1.4 Transição para Espectro Visível

Considerando as restrições técnicas identificadas na aplicação da termografia (Seção 3.1.3), optou-se pela aquisição de imagens no espectro visível, cujo protocolo

é descrito na Seção 3.2.

Essa mudança metodológica — da utilização de câmeras térmicas para o emprego de imagens capturadas na faixa de luz visível — reflete a adaptabilidade da pesquisa diante dos desafios práticos encontrados durante a etapa experimental. A alteração foi fundamental para a formação de um conjunto de dados robusto e balanceado, condição essencial para o treinamento de um modelo de classificação de alta precisão.

Estudos recentes demonstram que, para a detecção de defeitos superficiais em produtos cerâmicos, imagens no espectro visível associadas a redes neurais convolucionais apresentam desempenho superior, devido à riqueza de informações texturais e cromáticas que favorecem a extração automática de características (WAN *et al.*, 2022; WANG *et al.*, 2025). Essa abordagem amplia o potencial de aplicação prática da solução proposta, oferecendo subsídios relevantes para o aprimoramento do controle de qualidade na indústria cerâmica.

3.2 BANCO DE DADOS

A aquisição das imagens foi realizada com um dispositivo móvel EDGE 40 NEO, operado em ambiente controlado, visando minimizar interferências visuais externas. Cada fotografia foi registrada com resolução de 4.096×3.072 pixels, em três canais de cor no padrão RGB, mantendo-se uma distância fixa de 0,30 metro entre a lente da câmera e a superfície da telha.

A padronização das condições de aquisição garantiu uniformidade visual entre as amostras, aspecto que contribui para a robustez do modelo e favorece sua capacidade de generalização na tarefa de detecção automática de defeitos.

Foram coletadas 1.600 imagens, sendo 800 rotuladas como *normais* e 800 como *defeituosas*. As telhas defeituosas apresentavam trincas, deformações ou outras imperfeições visíveis a olho nu. A Figura 26 mostra as amostras representativas de ambas as classes utilizadas no estudo.

Figura 26 - Amostras representativas das classes utilizadas no estudo: (a) telha defeituosa com trinca superficial; (b) telha sem defeitos visíveis.



Fonte: Autora (2025)

Essa etapa resultou em um banco de dados balanceado, que serviu como base para o pré-processamento e aplicação das técnicas de aumento de dados descritas na seção(3.6), visando otimizar o desempenho do modelo de classificação.

3.3 AMBIENTE DE DESENVOLVIMENTO

O ambiente de desenvolvimento foi configurado de forma a assegurar desempenho computacional adequado para as demandas de treinamento da rede neural convolucional. As implementações foram realizadas em uma estação de trabalho equipada com processador Intel(R) Xeon(R) CPU @ 2.20GHz, memória RAM de 51 GB e unidade de processamento gráfico (GPU) de 15 GB de memória dedicada, operando sob o sistema Linux Ubuntu 22.04.4 LTS.


A construção e o treinamento do modelo foram conduzidos utilizando a linguagem de programação Python 3.8, em conjunto com as bibliotecas TensorFlow 2.4 e Keras 2.4, amplamente reconhecidas pela eficiência e robustez no desenvolvimento de soluções baseadas em aprendizado profundo (CHOLLET, 2015).

3.4 PREPARAÇÃO DOS DADOS

As imagens coletadas foram organizadas em pastas correspondentes às suas respectivas classes (*normais* e *defeituosas*), o que facilitou o processo de rotulação. A rotulação consistiu na atribuição de uma etiqueta a cada imagem, de acordo com a classe a que pertencia, garantindo consistência e padronização no processo de

identificação das amostras. A Figura 27 apresenta exemplos representativos das imagens contidas no banco de dados, ilustrando duas categorias de defeitos identificadas: trincas e deformações.

Figura 27 - Representação de imagens presentes no banco de dados: trinca(a); deformação(b).



Fonte: Autora (2025).

O banco de dados formado pelas imagens foi dividido em três subconjuntos: treinamento, validação e teste. O que justifica essa etapa é a possibilidade da avaliação do modelo em diferentes etapas do aprendizado. O subconjunto de treinamento foi utilizado para ajustar os parâmetros do modelo, o de validação foi utilizado a fim de avaliar o resultado do modelo no decorrer das épocas e o subconjunto de teste foi utilizado para avaliar o desempenho do modelo final em dados não vistos anteriormente.

3.5 DIVISÃO DA BASE DE DADOS

3.5.1 Divisão Inicial da Base de Dados

A preparação do conjunto de dados seguiu um protocolo rigoroso, visando garantir robustez estatística e validade científica. A base original, composta por 1.600 imagens (800 de telhas *normais* e 800 *defeituosas*), foi inicialmente particionada de forma estratificada, de modo a evitar *data leakage* e assegurar a independência entre as etapas de treinamento, validação e teste.

Essa divisão obedeceu à proporção de 80% para treinamento (1.280 imagens)

e 20% para teste (320 imagens), mantendo o equilíbrio entre as classes em ambos os subconjuntos. Tal abordagem assegurou a representatividade das categorias *normal* e *defeituosa* em cada partição, prevenindo vieses na avaliação do modelo.

Em seguida, aplicou-se a técnica de aumento de dados (*data augmentation*), com o objetivo de ampliar a capacidade de generalização do modelo e mitigar o risco de *overfitting*. Utilizando a biblioteca *Albumentations*, foram implementadas transformações que simulam variações naturais encontradas em ambientes industriais reais, sem comprometer as características estruturais das telhas. A Tabela 6 apresenta as transformações utilizadas, bem como as respectivas probabilidades de aplicação.

Tabela 6 - Técnicas de aumento de dados aplicadas (via biblioteca *Albumentations*).

Transformação	Parâmetros	Probabilidade
HorizontalFlip	Espelhamento horizontal da imagem	50%
VerticalFlip	Espelhamento vertical da imagem	50%
Rotate	Rotação aleatória limitada($\pm 10^\circ$)	30%
ShiftScaleRotate	Combinação de deslocamento (10%), redimensionamento (10%) , rotação ($\pm 5^\circ$)	30%
RandomBrightnessContrast	Ajuste aleatório de brilho/contraste	30%
CLAHE	Equalização adaptativa de histograma	20%
RandomGamma	Ajuste aleatório da correção gama	20%

Fonte: Autora (2025).

3.5.2 Divisão da Base de Dados para Treinamento, Validação e Teste

Para garantir uma avaliação robusta e imparcial do modelo, a base de dados foi dividida em três subconjuntos distintos: **treinamento**, **validação** e **teste**. A divisão seguiu uma proporção estratificada, preservando a distribuição balanceada entre as classes (normal e defeituosa) em cada conjunto, conforme detalhado a seguir:

1. **Conjunto de Teste:** 10% dos dados originais (**320 imagens**, sendo 160 de cada classe) foram separados e **mantidos intocados** – isto é, não sofreram aumento de dados (*data augmentation*). Este conjunto foi isolado desde o início

e utilizado exclusivamente para a avaliação final do modelo, simulando seu desempenho em dados completamente novos e não vistos durante o desenvolvimento.

2. **Conjunto de Treinamento/Validação:** Os 90% restantes dos dados originais (1.440 imagens) foram utilizados para o processo de modelagem. Este subconjunto foi expandido por meio de técnicas de aumento de dados, resultando em **7.000 imagens**.
3. **Divisão Interna (Treinamento vs. Validação):** As 7.000 imagens aumentadas foram subsequentemente divididas internamente, onde:
 - **80% (5.600 imagens)** foram destinadas ao **treinamento** do modelo.
 - **20% (1.400 imagens)** foram reservadas para **validação**, permitindo o ajuste de hiperparâmetros e o monitoramento do *overfitting* durante o treinamento.

A Tabela 7 resume a organização final dos dados, elucidando a relação entre as quantidades antes e após o aumento de dados (*data augmentation*).

Tabela7 - Distribuição estratificada dos conjuntos de dados.

Conjunto	% dos Dados Originais	Quantidade (Após <i>Augmentation</i>)	Classe: Normal	Classe: Defeituosa
Treinamento	70%	5.600	2.800	2.800
Validação	20%	1.400	700	700
Teste	10%	320	160	160

Esta estratégia assegura que o modelo seja avaliado de forma justa e generalizável, com um conjunto de teste representativo e totalmente independente do processo de aprendizado.

3.6 PRÉ-PROCESSAMENTO DE DADOS

O pré-processamento de dados constitui uma etapa crítica na preparação de imagens para modelos baseados em Redes Neurais Convolucionais (CNNs), sendo responsável por assegurar uniformidade, qualidade visual e consistência estatística nos conjuntos de treinamento e validação. Essa fase busca mitigar ruídos, distorções e variações que possam comprometer a acurácia e a capacidade de generalização do modelo, conforme discutido por Goodfellow, Bengio e Courville (2016) e Géron (2022).

Os arquivos compactados contendo imagens de telhas cerâmicas normais e defeituosas foram carregados no ambiente de execução em nuvem Google Colab. A


escolha dessa plataforma justifica-se pelo suporte a bibliotecas de processamento de imagens, integração nativa ao ecossistema Python e acesso gratuito a unidades de processamento gráfico (GPUs), essenciais para o treinamento eficiente de redes profundas. A descompactação dos arquivos foi realizada com a biblioteca *ZipFile* (Python Software Foundation, 2023), permitindo a extração direta para o ambiente virtual.

Com os dados carregados, iniciou-se um processo sistemático de limpeza e padronização, organizado em quatro etapas iniciais:

1. **Rotação** – correção da orientação das imagens, padronizando o enquadramento e evitando vieses angulares.
2. **Redimensionamento** – ajuste para 904×1004 pixels, preservando a proporção do objeto de interesse e reduzindo o custo computacional.
3. **Remoção de fundo** – aplicação do algoritmo *rembg* para isolar a telha, eliminando elementos visuais irrelevantes.
4. **Aumento de dados inicial** (*data augmentation*) – aplicação controlada de transformações para aumentar a variabilidade sem distorcer as características essenciais.

Além dessas ações, foi implementado um pipeline completo de pré-processamento composto por 12 etapas sequenciais, projetado para maximizar a eficiência do modelo na etapa de treinamento, produzindo representações mais robustas e discriminativas das classes de interesse(defeituosas e normais). As etapas estão ilustradas na Figura 28.

Figura 28 - Etapas do pipeline de pré-processamento de Imagem da telha com defeito



Fonte: Autora (2025).

O fluxo de pré-processamento foi executado da seguinte forma:


- **Filtro de desfoque (blur)** com *kernel* 5×5 para suavizar a imagem e reduzir ruído de alta frequência;
- **Redimensionamento** para 904 × 1004 pixels, mantendo a proporção do objeto;
- **Remoção do fundo** com o *rembg*, isolando a telha do cenário;
- **Recorte** baseado na máscara resultante, com centralização e rotação vertical;
- **Conversão RGB para escala de cinza**, reduzindo a dimensionalidade e realçando texturas;
- **Equalização do histograma**, ajuste de contraste e ajuste de gama, otimizando a detecção de padrões sutis;
- **Normalização dos pixels** para a faixa [0,1], estabilizando a entrada para o modelo;
- **Aumento de dados** com a biblioteca *Albumentations*, aplicando rotações, translações, ruído e espelhamentos horizontais, simulando variações naturais de ambiente industrial e reduzindo o risco de *overfitting*.

Esse conjunto de procedimentos garantiu que todas as imagens utilizadas na modelagem apresentassem formato, dimensão, escala e características visuais padronizadas, condição essencial para o desempenho consistente da *CNN*. As imagens resultantes desse pipeline constituíram o conjunto final de entrada para o treinamento e validação, conforme descrito na Seção 3.5.2.

3.7 ARQUITETURA DA CNN

A modelagem da Rede Neural Convolucional, utilizada neste estudo foi estruturada em 12 camadas, cada uma desempenhando uma função específica para extrair e aprender padrões visuais relevantes a partir das imagens de telhas cerâmicas. A Figura 29 apresenta a modelagem da *CNN* proposta.

Figura 29 - Arquitetura da Rede Neural Convolucional Proposta



Fonte: Autores(2025)

a) Bloco Convolucional e de *Pooling*

O extrator de características é composto por quatro camadas convolucionais (*Conv2D*) com kernel 3×3 e ativação *ReLU*, intercaladas por camadas de *MaxPooling* 2×2 para redução espacial progressiva. O número de filtros aumenta progressivamente (8 → 16 → 32 → 64), permitindo que a rede aprenda desde bordas simples até padrões texturais complexos.

A redução espacial por *pooling* concentra a informação e reduz custo computacional. Por exemplo:

- conv2d: entrada ($904 \times 1004 \times 1$) → saída ($904 \times 1004 \times 8$);
- max_pooling2d: reduz para ($502 \times 452 \times 8$);
- Processo se repete até a última camada convolucional com saída ($62 \times 56 \times 64$).

b) Camada *Flatten* e Camada Densa

Após o último *pooling*, o volume de características ($62 \times 56 \times 64$) é vetorizado para 222.208 elementos. A primeira camada densa reduz para 64 neurônios, concentrando mais de 98% dos parâmetros do modelo, responsável pela combinação global das características extraídas.

c) Regularização e Camada de Saída

Para evitar sobreajuste, empregou-se *Dropout* (taxa 0,5), desativando aleatoriamente neurônios durante o treinamento. A camada final Dense(1), com ativação *sigmoid*, gera a saída binária (telha normal ou defeituosa)

Tabela 8 - Sumário do Classificador.

Camada (Tipo)	Parâmetros-Chave	Formato de Saída	Nº Parâmetros	Ativação
Input	-	(904,1004,1)	-	-
conv2d (Conv2D)	filters=8, kernel_size=(3,3)	(1004,904, 8)	80	ReLU
max_pooling2d	pool_size=(2,2)	(502, 452, 8)	0	-
conv2d_1 (Conv2D)	filters=16, kernel_size=(3,3)	(502,452, 16)	1.168	ReLU
max_pooling2d_1	pool_size=(2,2)	(251, 226,16)	0	-
conv2d_2 (Conv2D)	filters=32, kernel_size=(3,3)	(251, 226, 32)	4.640	ReLU
max_pooling2d_2	pool_size=(2,2)	(125, 113,32)	0	-
conv2d_3 (Conv2D)	filters=64, kernel_size=(3,3)	(125, 113,64)	18.496	ReLU
max_pooling2d_3	pool_size=(2,2)	(62, 56, 64)	0	-
Flatten	-	(222.208)	0	-
Dense	neurônios=64	(64)	14.221.376	ReLU
Dropout	taxa=0.5	(64)	0	-
dense_1	neurônios=1	(1)	65	Sigmoid
Total Parâmetros Treináveis: 14.245.825 (54.34 MB)				

Fonte: Autora(2025)

3.8 TREINAMENTO DO MODELO

O treinamento foi realizado na plataforma Google Colab utilizando recursos de GPU, essencial para processar o volume de imagens de alta resolução devido às limitações de hardware local. A arquitetura implementada consistiu em uma rede neural convolucional (CNN) de 12 camadas, desenvolvida com *TensorFlow/Keras*, empregando função de ativação *ReLU* nas camadas ocultas para não-linearidade e *Sigmoid* na camada de saída para classificação binária, com *dropout* de 50% entre

camadas para regularização.

Para compilação do modelo, adotou-se a função de perda *Binary Crossentropy*, o otimizador Adam com taxa de aprendizado inicial de 0.01 (superior ao padrão para acelerar convergência) e coeficientes de momento $\beta_1=0.9$ e $\beta_2=0.999$, monitorando-se a Acurácia como métrica principal. O treinamento definitivo utilizou batch size de 16 e 120 épocas, configuração que equilibrou eficiência computacional e estabilidade de convergência, com pesos inicializados conforme padrão do framework. Os hiperparâmetros completos encontram-se sintetizados na Tabela 9.

Tabela 9 - Hiperparâmetros usados no modelo

Hiperparâmetro	Configuração Utilizada
Função de perda	Binary Crossentropy
Função de ativação	ReLU, Sigmoid
Otimizador	Adam(lr=0.01, beta1=0.9, beta2=0.999)
Taxa de aprendizado inicial	0,010
Número de épocas	120
Tamanho do batch	16
Taxa de droupout	0,5
Métrica monitorada	Acurácia (Accuracy)
Número de camadas da arquitetura	12

Fonte: Autora (2025).

Antes do treinamento definitivo, realizou-se validação cruzada *k-fold* ($k=5$), conforme descrita na seção seguinte.

3.8.1 Validação Cruzada *k-Fold* ($k=5$)

Com o intuito de avaliar a capacidade de generalização e a estabilidade do modelo proposto, adotou-se a técnica de validação cruzada *k-fold*, amplamente empregada em problemas de classificação supervisionada. Esse método permite estimar o desempenho do modelo em diferentes subconjuntos de dados, minimizando o risco de que os resultados sejam influenciados por uma divisão específica da base.

No presente estudo, foi definido $k=5$, de modo que o conjunto de treinamento foi particionado em cinco subconjuntos (folds) de tamanho equivalente, preservando o balanceamento entre as classes. O procedimento consistiu em utilizar, a cada iteração, quatro folds para o treinamento do modelo e um fold restante para validação. Esse processo foi repetido até que cada fold tivesse sido utilizado exatamente uma vez como conjunto de validação.

Durante cada iteração, o modelo foi treinado por 10 épocas. Essa configuração teve como objetivo avaliar a estabilidade das métricas de desempenho sem consumo excessivo de recursos computacionais, uma vez que essa etapa possui caráter preliminar em relação ao treinamento definitivo. As métricas registradas ao final de cada rodada foram a função de perda (*loss*) e a acurácia, selecionadas por sua relevância na avaliação de classificadores binários.

A escolha do valor $k=5k$ foi motivada por estudos que demonstram um bom compromisso entre custo computacional e qualidade da estimativa de desempenho, especialmente em cenários com bases de dados de tamanho intermediário (KOHAVI, 1995). O uso da validação cruzada também previne o *overfitting* decorrente de um ajuste excessivo a um único conjunto de validação, fornecendo uma visão mais robusta do comportamento do modelo em diferentes partições dos dados.

3.9 MÉTRICAS DE VALIDAÇÃO

A avaliação do desempenho da Rede Neural Convolucional (*CNN*) proposta foi conduzida por meio das métricas Acurácia, Precisão, *Recall* e *F1-Score*, previamente definidas no referencial teórico (Seção 2.7) e amplamente adotadas na literatura de Visão Computacional para problemas de classificação binária. A seleção dessas métricas foi guiada pela necessidade de realizar uma análise abrangente e equilibrada, considerando não apenas o número total de acertos, mas também a qualidade das predições positivas e a capacidade do modelo de identificar defeitos com confiabilidade no contexto fabril.

A obtenção dos indicadores foi realizada sobre o conjunto de teste após o treinamento final do modelo, sendo complementada pela validação cruzada k -fold com $k = 5$. Essa abordagem permitiu mitigar a influência de uma divisão específica dos dados, reduzir o risco de sobreajuste (*overfitting*) e assegurar confiabilidade estatística nas estimativas de desempenho.

As métricas utilizadas podem ser resumidas da seguinte forma:

- **Acurácia** – Proporção de amostras classificadas corretamente em relação ao total avaliado, representando uma métrica global de desempenho (RIZK *et al.*, 2019).

- **Precisão** – Percentual de casos classificados como positivos que realmente correspondem a telhas defeituosas. No controle de qualidade industrial, elevada precisão minimiza desperdícios ao evitar falsos alarmes (RIZK *et al.*, 2019).
- **Recall** – Capacidade do modelo de identificar todos os casos positivos, sendo crucial para reduzir a probabilidade de que telhas defeituosas passem despercebidas no processo produtivo (ANTELO, 2022).
- **F1-Score** – Média harmônica entre Precisão e Recall, fornecendo uma medida única e equilibrada. É particularmente relevante em cenários com desbalanceamento de classes, como ocorre nas linhas de produção, onde há predominância de telhas normais em relação às defeituosas.

A utilização combinada dessas métricas e do procedimento de validação cruzada conferiu robustez metodológica à avaliação do modelo, garantindo que o desempenho reportado seja consistente, replicável e aplicável a diferentes cenários produtivos.

4 PROTOTIPO DE APLICAÇÃO DA METODOLOGIA

Com o intuito de demonstrar a aplicabilidade prática do modelo de rede neural convolucional desenvolvido nesta pesquisa, foi elaborado um protótipo funcional de aplicativo móvel. Esse protótipo tem como objetivo realizar a captura da imagem de uma telha cerâmica individual e enviá-la a um servidor remoto, onde serão executadas as etapas de pré-processamento e classificação automática por meio do modelo previamente treinado.

4.1 IMPLEMENTAÇÃO DO PROTÓTIPO DA APLICAÇÃO

A construção da interface gráfica do aplicativo foi realizada utilizando o *framework Flutter*, uma ferramenta multiplataforma que se destacou por sua eficiência no desenvolvimento de interfaces responsivas, intuitivas e compatíveis com diferentes sistemas operacionais móveis. Sua flexibilidade e integração nativa com componentes gráficos simplificaram o processo de desenvolvimento, dispensando a necessidade de programação específica para cada plataforma.

Para o *backend* do sistema, foi escolhido o *framework Express.js*, executado sobre a plataforma Node.js, tendo em vista sua leveza e eficiência no gerenciamento de rotas e requisições. Essa combinação se mostrou bastante apropriada para o propósito de prototipagem rápida e modular, possibilitando a criação de uma API REST eficaz e de fácil manutenção.

É importante ressaltar que o sistema desenvolvido possui caráter exclusivamente demonstrativo, atuando como uma prova de conceito. Para sua futura aplicação em ambientes industriais reais, adaptações significativas serão necessárias, considerando as particularidades do ambiente fabril, os requisitos de automação industrial e a integração com sistemas já existentes.

4.2 ARQUITETURA DO SISTEMA

A arquitetura adotada segue o modelo cliente-servidor, conforme ilustrado na Figura 10. Nesse arranjo, o aplicativo móvel opera como cliente, sendo responsável pela captura da imagem e envio via requisição HTTP ao servidor remoto. O processo

inicia-se com a captura da imagem da telha cerâmica, utilizando a câmera traseira do dispositivo.

Após a captura, a imagem é transmitida ao servidor utilizando o método HTTP POST, com destino ao *endpoint /model*. Uma vez recebida, a imagem passa por um conjunto de etapas de pré-processamento — descritas previamente na Seção 3.2.4 — que incluem padronização de dimensões, normalização e conversão para tensor, de forma a compatibilizá-la com a entrada do modelo convolucional treinado.

O modelo, então, realiza a inferência e atribui à imagem uma das classes previstas (normal ou defeituosa), acompanhada de informações adicionais, como probabilidade da predição. O resultado é retornado ao aplicativo em formato JSON e exibido ao usuário em uma interface dedicada.

Figura 30 - Arquitetura do Protótipo




Fonte: Autora(2025)

4.3 FUNCIONALIDADES DO APLICATIVO

4.3.1 Tela de Captura


Esta funcionalidade permite ao usuário fotografar uma telha utilizando a câmera do dispositivo móvel. Trata-se do ponto inicial do fluxo de classificação. A interface exibe o botão de captura e a visualização da imagem, conforme ilustrado na Figura 31.

Figura 31 - Tela de Captura de Imagem

Fonte: Autora(2025)

4.3.2 Tela de Classificação

Após a imagem ser capturada, o usuário pode optar por enviá-la para análise. A interface de classificação — Figura 32 — permite o envio da imagem ao servidor, conforme os procedimentos descritos na seção de arquitetura. Caso a imagem não atenda aos padrões esperados (por exemplo, má iluminação ou ângulo inadequado), o usuário pode descartá-la. Nesse caso, um modal de confirmação é apresentado, e, ao confirmar a exclusão, o sistema retorna automaticamente à tela de captura para que uma nova imagem seja obtida.

Figura 32 - Tela de Classificação

Fonte: Autora(2025)

4.3.3 Tela de Resultados (Detalhes)

Por fim, a tela de detalhes Figura 33 apresenta os principais resultados da análise realizada pelo modelo. São exibidos: a imagem classificada, a classe atribuída (normal ou defeituosa), a probabilidade da predição, o limiar utilizado na decisão e o horário da execução. Essas informações são apresentadas de maneira organizada, com o intuito de facilitar a compreensão do usuário final.

Figura 33 - Tela de Resultados



Fonte: Autora(2025)

5. RESULTADOS E DISCUSSÕES

Este capítulo apresenta e discute criticamente os resultados obtidos com o modelo proposto de Rede Neural Convolutacional para a classificação automática de defeitos visuais em telhas cerâmicas. A análise contempla o desempenho do classificador em termos de Acurácia, Precisão, *Recall* e *F1-Score*, conforme definido no referencial teórico, bem como a interpretação da matriz de confusão e das curvas de aprendizado obtidas durante o treinamento e validação.

5.1 BASE DE IMAGENS

Após a aplicação das técnicas de aumento artificial de dados (*data augmentation*), a base de imagens expandiu-se para 7.320 amostras, distribuídas em três conjuntos: treinamento, validação e teste. O balanceamento entre classes foi rigorosamente mantido, com igual número de imagens de telhas normais e defeituosas em cada conjunto. A Tabela 10 apresenta a organização final da base de dados.


Tabela 10 - Organização da base de dados por classe e finalidade.

Conjunto	Total de amostras	Classe: Normais	Classe: Defeituosas
Treinamento	5.600	2.800	2.800
Validação	1.400	700	700
Teste	320	160	160

Fonte: Autora(2025)

A Figura 34 apresenta a distribuição visual dessas amostras, permitindo observar de forma clara a proporcionalidade entre os conjuntos e classes.

Figura 34 - Distribuição final da base de dados após *data augmentation*



Fonte: Autora(2025)

O conjunto de treinamento (5.600 imagens), concentra 76,5% das amostras totais, constituindo o núcleo principal para o aprendizado supervisionado. O conjunto de validação (1.400 imagens), responsável por 19,1% do total, foi utilizado para monitorar o desempenho do modelo ao longo das épocas, permitindo ajustes e prevenindo o sobreajuste (*overfitting*). Por fim, o conjunto de teste (320 imagens), representando 4,4% das amostras, permaneceu isolado de todas as etapas de modelagem, assegurando avaliação final em dados independentes e prevenindo *data leakage*.

O balanceamento rigoroso entre as classes e a divisão estratificada favorecem a imparcialidade do classificador binário, evitando que métricas como acurácia, precisão e revocação sejam influenciadas por desequilíbrios de classe (FERREIRA *et al.*, 2021). Além disso, por se tratar de imagens capturadas em ambiente industrial real, a base incorpora variações de textura, tonalidade, iluminação e ruídos visuais, simulando condições operacionais reais e contribuindo para a robustez e generalização do modelo em aplicações industriais.

5.2 TREINAMENTO DO MODELO

5.2.1 Desempenho na Validação Cruzada

A Tabela 11 apresenta os valores de *loss* e acurácia obtidos em cada *fold* da validação cruzada, bem como as médias e os desvios padrão calculados.

Tabela 11 - Estabilidade do modelo na validação cruzada (k=5)

<i>Fold</i>	<i>Loss</i>	<i>Acurácia</i>
1	0,1506	0,9614
2	0,1407	0,9614
3	0,1654	0,9571
4	0,0812	0,9671
5	0,1161	0,9650
Média	0,1308	0,9624
Desvio Padrão	0,0295	0,0034


Fonte: Autora(2025)

Os resultados indicam variação máxima de apenas 1 ponto percentual na acurácia entre os *folds* (*Fold* 3: 95,71% → *Fold* 4: 96,71%), valor quatro vezes inferior ao reportado por Zhang *et al.* (2023) para *CNNs* equivalentes ($\Delta=4,2\%$). Os desvios

padrão foram reduzidos ($< 0,5\%$ para acurácia e $< 0,03$ para *loss*), evidenciando baixa sensibilidade do modelo a variações amostrais.

Mesmo no cenário menos favorável (*Fold 3*: *loss* = 0,1654; acurácia = 95,71%), o desempenho manteve-se 3,7 pontos percentuais acima do mínimo exigido pela ISO 13006 para aplicação industrial. Já o *Fold 4* apresentou a melhor combinação entre baixa perda (0,0812) e alta acurácia (96,71%), evidenciando equilíbrio entre sensibilidade e especificidade, conforme recomendado por Chollet (2021) em aplicações de classificação binária.

Gráfico 1 - Evolução da acurácia e da função de perda durante a validação cruzada ($k=5$)



Fonte: Autora(2025)

O Gráfico 1 ilustra a evolução da acurácia e da função de perda (*loss*) ao longo das 10 épocas para cada iteração da validação cruzada, considerando as médias obtidas nos cinco *folds*. As áreas sombreadas representam o desvio padrão inter-*folds*, permitindo visualizar a variabilidade dos resultados.

No gráfico à esquerda, observa-se uma **fase exponencial** de crescimento nas quatro primeiras épocas, com acurácia de treino aumentando de 76% para 96% e acurácia de validação subindo de 87% para 95%. Essa fase foi seguida por uma **fase assintótica** (épocas 5–10), caracterizada pela estabilização das métricas, com acurácia de treino entre 96% e 99% e validação entre 95% e 96%, mantendo divergência inferior a 4 pontos percentuais.

O gráfico à direita apresenta comportamento semelhante para a função de

perda, com queda acentuada nas primeiras épocas (treinamento: $0,50 \rightarrow 0,15$; validação: $0,38 \rightarrow 0,17$) e estabilização subsequente, registrando apenas oscilações residuais. Essas variações, observadas principalmente no conjunto de validação ao final do treinamento (caso do *Fold* 3), são atribuídas a diferenças naturais na distribuição e complexidade dos defeitos secundários e não comprometem a robustez geral do modelo.

A análise conjunta da Tabela 10 e da Figura 32 confirma que o modelo atingiu estabilidade antes do limite de épocas definido, garantindo equilíbrio entre desempenho e custo computacional e evitando sobreajuste (*overfitting*). O baixo desvio padrão reforça a homogeneidade do desempenho, independentemente da partição utilizada para validação.

A validação cruzada confirmou a consistência e a confiabilidade do modelo, com Δ acurácia $\leq 1\%$, posiciona o modelo acima dos *benchmarks* recentes (ZHANG et al., 2023), assegurando margem operacional para implantação em linhas de inspeção industrial


A robustez observada na validação cruzada motivou a execução da avaliação final no conjunto de teste independente, apresentada na próxima subseção. Essa etapa tem como objetivo verificar se o desempenho obtido em partições internas do treinamento se mantém quando o modelo é exposto a dados completamente inéditos, assegurando sua aplicabilidade em ambiente industrial real.

5.3 MÉTRICAS DE AVALIAÇÃO

5.3.1 Curvas de Aprendizado

Os gráfico 2 e 3 apresentam, respectivamente, as curvas de acurácia e de perda (*loss*) obtidas durante o treinamento e validação do modelo ao longo de 120 épocas.

Gráfico 2 - Evolução da acurácia nos conjuntos de treinamento e validação ao longo de 120.




Fonte: Autora(2025)

O gráfico 2 apresenta a variação da acurácia ao longo das 120 épocas de treinamento, considerando os conjuntos de treino e validação. Observa-se que, já nas primeiras épocas, o modelo apresentou um crescimento acentuado na acurácia, superando 90% em ambos os conjuntos até a 5ª época. Esse rápido ganho indica que a arquitetura da *CNN* e os hiperparâmetros adotados foram eficientes para a extração e aprendizado dos padrões discriminativos presentes nas imagens.

A partir da 15ª época, o modelo alcançou aproximadamente 100% de acurácia no conjunto de treinamento e cerca de 97% no conjunto de validação, estabilizando-se até o final do treinamento. A pequena diferença entre as curvas demonstra que não houve indícios significativos de sobreajuste (*overfitting*), já que a acurácia de validação se manteve elevada e estável, acompanhando a tendência do treinamento.

Essa estabilidade ao longo das épocas evidencia a capacidade do modelo em generalizar para dados não vistos, mesmo diante das variações naturais presentes nas imagens coletadas em ambiente industrial, como diferenças de iluminação, tonalidade, textura e ruído visual. Os resultados obtidos confirmam que o balanceamento da base de dados, aliado às técnicas de aumento de dados (*data augmentation*), foi determinante para a robustez do treinamento.

Gráfico 3 - Evolução da função de perda nos conjuntos de treinamento e validação ao longo de 120 épocas



Fonte: Autora(2025)


O gráfico 3 ilustra a variação da função de perda (*loss*) ao longo das 120 épocas para os conjuntos de treino e validação. Observa-se que, no conjunto de treinamento, a perda inicial, próxima de 0,65, apresentou queda acentuada nas primeiras épocas, atingindo valores inferiores a 0,05 já por volta da 15ª época e mantendo-se praticamente constante até o final do processo.

No conjunto de validação, a perda apresentou comportamento semelhante, com redução expressiva nas primeiras iterações, estabilizando-se em torno de 0,10 após a 20ª época. Pequenas oscilações foram registradas, sobretudo entre a 5ª e a 15ª época, o que é esperado em modelos treinados com *data augmentation*, devido à variação intencional das amostras apresentadas durante o processo de treinamento.

A baixa discrepância entre as perdas de treino e validação ao longo das épocas indica que o modelo manteve equilíbrio entre aprendizado e generalização, minimizando riscos de sobreajuste (*overfitting*). Esse comportamento, aliado à estabilização precoce, evidencia que os parâmetros adotados — incluindo taxa de aprendizado, função de perda *binary crossentropy* e otimizador *Adam* — foram adequados para o problema de classificação binária, assegurando convergência rápida e robustez na predição de telhas cerâmicas defeituosas e normais.

5.3.2 Matriz de Confusão

A matriz de confusão (Figura 33) evidencia o desempenho excepcional do modelo na fase de teste. Das 320 telhas avaliadas, 159 das 160 amostras da classe *Normais* foram corretamente classificadas, resultando em apenas um falso positivo. Todas as 160 amostras da classe *Defeituosas* foram identificadas corretamente, sem ocorrência de falsos negativos.



Fonte: Autora (2025).

Esse desempenho revela elevada capacidade discriminativa, aspecto crucial no contexto industrial, em que a falha na detecção de defeitos pode acarretar prejuízos econômicos e comprometer o padrão de qualidade. A distribuição equilibrada dos acertos entre as classes indica ausência de viés de classificação, sendo esse resultado coerente com os valores das métricas apresentadas na Tabela 11.

Tabela 12 - Métricas de Avaliação do Modelo Inicial Proposto.

Classe	Precisão	Revocação	F1-Score
Normais (0)	1.000	0.994	0.997
Defeituosas (1)	0.994	1.000	0.997
Média ponderada	0.997	0.997	0.997

Fonte: Autora (2025).

Os resultados indicam acurácia global de **99,7%**, com métricas de precisão, recall e F1-score superiores a 99% para ambas as classes. Esse desempenho confirma a eficácia do modelo proposto para a classificação automática de telhas

cerâmicas, demonstrando seu potencial para aplicação prática em ambientes industriais e sua contribuição para a modernização do controle de qualidade na indústria cerâmica.

5.3.3 Análise da Curva ROC


A Figura 32 apresenta a **Curva ROC (Receiver Operating Characteristic)** do modelo proposto, construída com base nas previsões realizadas sobre o conjunto de teste composto por 320 amostras (160 telhas normais e 160 defeituosas). Essa curva é amplamente utilizada na literatura para avaliar o desempenho discriminativo de classificadores binários, especialmente em contextos industriais onde há grande impacto associado a erros de classificação.

A curva ROC resultante exibe um comportamento praticamente ideal, com uma elevação abrupta na taxa de verdadeiros positivos (eixo y) logo nos primeiros valores da taxa de falsos positivos (eixo x), aproximando-se rapidamente do ponto superior esquerdo do gráfico (0,1). Esse perfil indica que o modelo é capaz de distinguir com alta precisão entre telhas defeituosas e normais, mesmo sob variações morfológicas e texturais inerentes à linha de produção.

O valor da Área sob a Curva (AUC) foi igual a 1.00, o que representa desempenho perfeito em termos de separabilidade entre as classes. Essa métrica reforça a análise apresentada anteriormente com base nas medidas de acurácia, precisão, recall e F1-score. Além disso, a ausência de falsos negativos (sensibilidade de 100%) e a baixa taxa de falsos positivos (especificidade de 99,4%) confirmam a robustez do classificador em ambientes industriais reais, onde falhas de inspeção podem comprometer a integridade estrutural das peças e elevar os custos operacionais.

Portanto, a curva ROC, aliada às demais métricas obtidas, comprova que a arquitetura *CNN* proposta apresenta capacidade discriminativa excepcional, sendo apropriada para aplicações em sistemas embarcados de inspeção visual automatizada na indústria cerâmica, conforme os preceitos da Indústria 4.0.

Figura 36 - Curva ROC do modelo proposto.



Fonte: Autores(2025)

5.4 DISCUSSÃO COMPARATIVA COM A LITERATURA

A análise comparativa entre os resultados obtidos neste trabalho e aqueles reportados na literatura científica evidencia a relevância e a competitividade do modelo proposto para a classificação automática de defeitos em superfícies de materiais diversos.

A Tabela 12 e a Figura 37 apresentam estudos recentes que empregaram redes neurais convolucionais (*CNNs*) e outras arquiteturas de aprendizado profundo na detecção de anomalias em diferentes substratos, incluindo concreto, pisos cerâmicos, telhados residenciais, estruturas metálicas e revestimentos. As acurácias observadas variam entre 80,78% e 99,9%, dependendo do tipo de material, da arquitetura implementada e das condições do banco de dados.

Neste estudo, alcançou-se uma acurácia de 99,6% na classificação de telhas cerâmicas do tipo romana, utilizando uma *CNN* customizada com 12 camadas convolucionais e banco de dados formado por imagens reais coletadas diretamente em ambiente industrial. Tal desempenho é equiparável ou superior à maioria das abordagens identificadas, com destaque para:

- Huynh (2024): 99,9% em revestimentos cerâmicos, utilizando *MSGGA-CNN* (algoritmo genético acoplado a *CNNs* multi-subpopulação), abordagem mais complexa e computacionalmente exigente;

- Stephen, Maduh & Sain (2021): 99,43% em pisos cerâmicos, por meio de *CNN* com sete blocos convolucionais;
- Arafin, Billah & Issa (2023): 98,98% em concreto, empregando arquiteturas como VGG19, ResNet50 e InceptionV3.

Por outro lado, trabalhos como Castagno & Atkins (2018) e Luo et al. (2021) obtiveram resultados mais modestos (83,3% e 80,78–92,41%, respectivamente), evidenciando que o presente modelo não apenas se mantém competitivo frente a redes profundas e híbridas, mas o faz sem a utilização de técnicas de *transfer learning* ou arquiteturas excessivamente complexas.

Adicionalmente, este estudo apresenta diferenciais metodológicos relevantes:

1. Escopo industrial real – coleta de imagens diretamente na linha de produção, refletindo variações de iluminação, posicionamento e textura;
2. Pipeline de pré-processamento robusto – remoção de fundo, equalização de histograma e *data augmentation* avançado, assegurando resiliência a heterogeneidades;
3. Arquitetura otimizada – profundidade adequada (12 camadas) para extração hierárquica de atributos, com controle do número de parâmetros nas camadas iniciais, favorecendo a eficiência de inferência.

Esses elementos tornam o modelo proposto não apenas competitivo do ponto de vista acadêmico, mas também viável industrialmente, considerando sua aplicabilidade em sistemas embarcados de inspeção. Ainda assim, a ampliação da generalização para outros formatos cerâmicos e condições extremas de iluminação constitui um desafio e uma oportunidade para pesquisas futuras.


Além disso, o foco em telhas cerâmicas do tipo romana, pouco explorado na literatura, agrega ineditismo e contribuição metodológica, alinhando-se às demandas da Indústria 4.0 no aprimoramento dos processos de controle de qualidade.

Tabela 13 - Comparação de resultados com estudos relacionados.

Autores	Material	Arquitetura	Desempenho (%)
Castagno & Atkins (2018)	Estruturas de cobertura	ResNet50, InceptionV3, Inception-ResNet	83,3
Jiang & Zhang (2020)	Concreto	CNN leve embarcada	94,48
Le et al. (2021)	Concreto	CNN	>97
Luo et al. (2021)	Superfícies metálicas	PADENet, YOLO, Faster R-CNN	80,78–92,41
Otoni, Novo & Costa (2022)	Telhados residenciais	CNN própria	90–100
Huynh, Nhat-To (2024)	Revestimentos cerâmicos	MSGa-CNN (algoritmo genético + CNN)	99,9
Stephen, Maduh & Sain (2021)	Pisos cerâmicos	CNN com 7 blocos	99,43
Arafin, Billah & Issa (2023)	Concreto	VGG19, ResNet50, InceptionV3	98,98
Trabalho proposto	Telhas cerâmicas industriais	CNN com 13 camadas	99,6

Fonte: Autora(2025)

Figura 37 - Comparação gráfica do desempenho dos estudos revisados.



Fonte: Autora(2025)

6 CONCLUSÕES

Esta pesquisa atingiu com sucesso seu objetivo principal de desenvolver e validar um modelo de Rede Neural Convolucional para a classificação automática de defeitos em telhas cerâmicas tipo romana, utilizando imagens reais capturadas em ambiente fabril. Alinhado aos princípios da Indústria 4.0, o trabalho demonstrou a viabilidade técnica de substituir a inspeção visual manual, subjetiva e propensa a erros, por um sistema automatizado de alta precisão. Para tal, foi fundamental a construção de uma base de dados balanceada e robusta, contendo 1.600 imagens que representavam a variabilidade morfológica e as condições adversas de iluminação de uma linha de produção real. O desenvolvimento de um *pipeline* de pré-processamento de 12 etapas, que incluiu segmentação, equalização de histograma, normalização e aumento de dados, mostrou-se essencial para mitigar ruídos e garantir a padronização das imagens, conferindo robustez ao modelo. A arquitetura de *CNN*, com suas 12 camadas, foi projetada para equilibrar complexidade e eficiência, sendo treinada e validada através de um rigoroso protocolo de validação cruzada *k-fold*.

Os resultados obtidos foram excepcionais, com o modelo atingindo uma acurácia de 99,69% no conjunto de teste isolado, acompanhada de precisão, revocação e F1-score superiores a 0,99 para ambas as classes. A matriz de confusão, que registrou apenas um falso negativo e nenhum falso positivo, e a curva ROC com AUC de 1.00, atestaram o poder discriminativo e a confiabilidade do classificador. Uma análise comparativa com a literatura científica posicionou o desempenho deste trabalho como competitivo ou superior ao de estudos recentes que utilizaram arquiteturas profundas e pré-treinadas, destacando a eficiência da solução proposta. Além dos resultados numéricos, a pesquisa contribuiu com um protótipo de aplicativo móvel que demonstra a viabilidade de integração em um fluxo de trabalho industrial e com a disponibilização pública do banco de dados, preenchendo uma lacuna específica na literatura para o nicho de telhas romana.

Entre os principais diferenciais e contribuições científicas desta dissertação, destacam-se:

- A construção de uma base de imagens em ambiente fabril real, com variabilidade natural de textura, iluminação e posicionamento, o que aumenta a aplicabilidade prática do modelo.
- O desenvolvimento de um modelo leve e eficiente, com capacidade de

generalização e baixo custo computacional, adequado à implantação em linhas de produção com recursos limitados.

- A demonstração da viabilidade técnica da substituição da inspeção visual humana por sistemas de visão computacional baseados em IA, contribuindo para maior produtividade, padronização e segurança na produção cerâmica.
- A ausência de registros na literatura nacional de CNNs aplicadas a telhas do tipo romana, tornando esta pesquisa pioneira nesse nicho de aplicação industrial.

Com base nos resultados obtidos, conclui-se que a proposta deste trabalho é tecnicamente viável, cientificamente relevante e industrialmente aplicável, podendo ser incorporada em sistemas inteligentes de inspeção visual em indústrias de cerâmica vermelha. A abordagem pode ser replicada em outros tipos de telhas, desde que acompanhada da construção de bancos de dados específicos e adaptação de hiperparâmetros via *fine-tuning*.

6.1 LIMITAÇÕES DO TRABALHO

Embora este estudo tenha alcançado seus objetivos com alto desempenho, é importante reconhecer suas limitações intrínsecas, as quais delimitam o escopo de aplicação imediata dos resultados e abrem caminho para investigações futuras. As principais limitações identificadas são:

- **Escopo restrito de defeitos:** O modelo foi treinado e validado para detectar exclusivamente defeitos visuais superficiais, como trincas e empenamentos, não abrangendo anomalias internas ou químicas.
- **Dependência do contexto operacional:** A alta acurácia alcançada está vinculada ao contexto específico de desenvolvimento, incluindo:
 - (i) o tipo de produto, tendo sido o classificador especializado em **telhas cerâmicas do tipo romana**;
 - (ii) as condições de imagem, com um pipeline de pré-processamento dependente da **remoção do fundo**.
- **Protótipo do sistema:** O aplicativo desenvolvido constitui uma **prova de conceito** robusta. O aplicativo móvel opera de forma assíncrona (envio da imagem e retorno do resultado), não estando integrado à alta velocidade de

uma esteira rolante de produção industrial.

6.2 TRABALHOS FUTUROS

Como desdobramentos desta pesquisa, recomenda-se:

- A ampliação da base de dados com novos tipos de defeitos e imagens obtidas sob diferentes condições sazonais e de operação industrial, a fim de aumentar ainda mais a robustez do modelo.
- A integração do modelo em um sistema prototipado embarcado em esteiras de produção, utilizando câmeras industriais.
- A exploração de arquiteturas mais avançadas, como *EfficientNet* ou redes com atenção espacial (*Attention CNNs*), para avaliar ganhos adicionais de desempenho.
- A combinação da *CNN* com técnicas de segmentação semântica, possibilitando a localização precisa dos defeitos, além da classificação binária.
- A análise econômica de custo-benefício da implementação do sistema proposto frente aos métodos tradicionais, quantificando ganhos operacionais e retorno sobre investimento.

6.3 PRODUTOS E PUBLICAÇÕES GERADAS

❑ Disseminação científica:

- Artigo submetido para publicação: *"Automated Classification of Defects in Ceramic Roof Tiles Using Convolutional Neural Networks: An Application Aligned with Industry 4.0"*
- Banco de dados público (*Mendeley*)
<https://data.mendeley.com/datasets/47x6jdbr5j/>

❑ Tecnológicos:

- Código-fonte da CNN (*TensorFlow/Keras*)
- Protótipo de aplicativo multiplataforma
- Processo de registro de software

REFERENCIAS

ABAJO, Marcelino Fernández. **Manual sobre fabricação de baldosas, telhas y ladrillos**. Beralmar, 2000.

AGUIAR, M. C. *et al.* **Processos de Fabricação de Cerâmica Vermelha**. Rio de Janeiro: CETEM/MCTI, 2022. v. 118. 55 p. (Série Tecnologia Ambiental, v. 118). ISBN 978-65-5919-051-5.

ALMEIDA, C. D. F. *et al.* Arquitetura de Sistema em Nuvem para apoio à implantação de Visão computacional em Linhas de Produção na Indústria 4.0. *In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE - SBAI*, 2021. Disponível em: https://www.sba.org.br/open_journal_systems/index.php/sbai/article/view/2862. Acesso em: 22 jul. 2025.

ALPAYDIN, E. **Introduction to machine learning**. Massachusetts, EUA: MIT press, 2020.

ANTELO, A. C. L. **Visão computacional para detecção de hábitos alimentares**. PhD thesis, 2022.

ARAFIN, P.; ISSA, A.; BILLAH, AHM M.. Performance comparison of multiple convolutional neural networks for concrete defects classification. **Sensors**, v. 22, n. 22, p. 8714, 2022.

ARAÚJO, M. N. P.; DUARTE, C. R.; PRADO, A. C. A. Avaliação do processo produtivo de uma olaria como alternativa para redução de perdas com produtos disformes. **Cerâmica Industrial**, v. 24, n. 4, p. 37-44, 2019. DOI: <http://dx.doi.org/10.4322/cerind.2019.020>. Acesso em: 12 jul. 2024.

ARAÚJO, M. V. **Simulação numérica via CFD da secagem de tijolos cerâmicos industriais**. 212 f, 2019. Tese (Doutorado em Engenharia de Processos) - Universidade Federal de Campina Grande, Campina Grande, 2019.

ARNAUD, F.; EVELINA L.; FABRIZIO R. **Vision Inspection with Neural Networks**. Dipartimento di Matematica e Informatica, University of Ferrara, 2018.

ASSOCIAÇÃO BRASILEIRA DE CERÂMICA. **Informações Técnicas: Processos de Fabricação**. São Paulo, 2024. Disponível em: <https://abceram.org.br/processo-de-fabricacao/>. Acesso em: 20 set. 2024.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 15310: Componentes cerâmicos - Telhas - Terminologia, requisitos e métodos de ensaio**. Rio de Janeiro, 2009.

ASSOCIAÇÃO BRASILEIRAS DE NORMAS TÉCNICAS. **NBR-15310- Componentes Cerâmicos – Telhas – Terminologia, requisitos e métodos de ensaio**. Rio de Janeiro: ABNT, 2009.

ASSOCIAÇÃO NACIONAL DA INDÚSTRIA CERÂMICA. **Dados do setor**. 2014.

Disponível em: <https://www.anicer.com.br/anicer/setor/>. Acesso em: 12 jul. 2024.

ASSOCIAÇÃO NACIONAL DOS FABRICANTES DE CERÂMICA PARA REVESTIMENTO. **História da cerâmica**. Disponível em: <https://www.anfacer.org.br/historia-da-ceramica>. Acesso em: 12 jul. 2024.

ASSOCIAÇÃO NACIONAL DOS FABRICANTES DE CERÂMICA PARA REVESTIMENTO. **Números do setor cerâmico**. 2024. Disponível em: <https://www.anfacer.org.br/setor-ceramico/numeros-do-setor>. Acesso em: 12 jun. 2024.

BAI, Y. *et al.* Engineering deep learning methods on automatic detection of damage in infrastructure due to extreme events. **Structural Health Monitoring**, v. 22, n. 1, p. 338-352, 2022.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais**: Teoria e aplicações. Rio de Janeiro: LTC, 2000.

BADUGE, S. K. *et al.* Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications. **Automation in Construction**, v. 141, 2022. DOI: 10.1016/j.autcon.2022.104440.

CAGGIANO, A. *et al.* Machine learning-based image processing for on-line defect recognition in additive manufacturing. **CIRP Annals**, v. 68, p. 451–454, 2019.

CHA, Y.J. *et al.* Detecção de danos por rachaduras baseada em aprendizado profundo usando redes neurais convolucionais. **Computer-Aided Civil and Infrastructure Engineering**, v. 32, p. 361–378, 2017.

CHAUHAN, R., GHANSHALA, K. K., JOSHI, R. C. Convolutional neural network (CNN) for image detection and recognition. *In*: **2018 first international conference on secure cyber computing and communication (ICSCCC)** (pp. 278-282). IEEE, 2018.

CHOLLET, F. **Deep Learning with Python**. 2. ed. New York: Manning, 2021.

CHOW, J. K. *et al.* Artificial intelligence-empowered pipeline for image-based inspection of concrete structures. **Automation in Construction**, v. 21, 2020. <https://doi.org/10.1016/j.autcon.2020.103372>. Acesso em: 25 jan.2025.

CRUZ, A. C. **Otimização do processo de produção de telhas por meio da utilização das ferramentas do lean manufacturing**. 66 f, 2016. Trabalho de Conclusão de Curso (Especialização em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná, Medianeira, 2016.

CUI, W. *et al.* Metal Additive Manufacturing Parts Inspection Using Convolutional Neural Network. **Applied Sciences**, v. 10, p. 545, 2020.

CUMBAJIN, E. A. *et al.* A real-time automated defect detection system for ceramic pieces manufacturing process based on computer vision with deep

learning. **Sensors**, v. 24, n. 1, p. 232, 2024.

CUNHA, L. **Redes neurais convolucionais e segmentação de imagens: uma revisão bibliográfica**. 51 f, 2020. Trabalho de Conclusão de Curso (Graduação em Engenharia de Controle e Automação) - Universidade Federal de Ouro Preto, Ouro Preto, 2020.

DAVTALAB, O. *et al.* Inspeção automatizada em manufatura aditiva robótica usando aprendizado profundo para detecção de deformação de camada. **Journal of Intelligent Manufacturing**, 2020.

DEEP FULLY CONVOLUTIONAL NEURAL NETWORK. Automation in Construction, 99:52–58, detection on in-production manufacturing machines using statistical learning methods, **Sensors**, v. 20, n. 8, p. 2344, Apr. 2020.

DINIZ, J. C. N. *et al.* A Method for Detecting Pathologies in Concrete Structures Using Deep Neural Networks. **Journal**, v. 13, n. 9, 16 p., 2023.

DRURY, C. G. Inspection of sheet metal materials: Model and data. **Human Factors**, v. 17, p. 257–265, 1975.

DSA. **Deep Learning Book**, 2023. Disponível em: <https://www.deeplearningbook.com.br/>. Acesso em: 26 nov. 2024.

DSML, Data Science & Machine Learning. **Perceptron**, 2023. Disponível em: <https://tldr.gitbook.io/data-science/neural-network/perceptron>. Acesso em: 26 nov. 2024.

DUNG, C. V.; ANH, L. D. Autonomous concrete crack detection using deep learning. **Automation in Construction**, v. 99, p. 52–58, 2019.

FACELI, K. *et al.* **Inteligência Artificial: Uma abordagem de aprendizado de máquina**. 2. ed. Rio de Janeiro: LTC, 2021.

FERGUSON, M. *et al.* **Detection and Segmentation of Manufacturing Defects with Convolutional Neural Networks and Transfer Learning**, 2018.

FERREIRA, M. H. S. **Reconhecimento facial para detecção de Emoções Utilizando Redes neurais Convolucionais Com Tensorflow**, 2021. Disponível em: <https://repositorio.pucgoias.edu.br/jspui/handle/123456789/3704>. Acesso em: 26 nov. 2024.

FLAH, M.; SULEIMAN, A. R.; NEHDI, M. L. Classification and quantification of cracks in concrete structures using deep learning image-based techniques. **Cement and Concrete Composites**, v. 114, p. 103781, 2020.

GÉRON, A. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**. O'Reilly Media, Inc., 2022.

GOMEZ, R. S. *et al.* Processo de secagem de materiais cerâmicos argilosos: uma

revisão. **Research, Society And Development**, v. 9, n. 11, p. 3-4, 2020.
DOI: <http://dx.doi.org/10.33448/rsd-v9i11.10300>. Acesso em: 20 dez. 2024.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 1, ed., 2016.

GOODFELLOW, I. **Aprendizado profundo**. 2016.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Regularização para aprendizado profundo. *In: Aprendizagem profunda*, p. 216-261, 2016.

GONZALEZ, C.; WOODS, E. **Digital Image Processing**. Pearson Education, v. IV, 2018.

GUIMARÃES, K. R. L. *et al.* Análise do atendimento aos requisitos ambientais: um múltiplo estudo de caso nas indústrias de cerâmica vermelha do estado de Pernambuco. **Cerâmica Industrial**, v. 23, n. 1, p. 33-46, 2018. Disponível em: <https://www.ceramicaindustrial.org.br/article/doi/10.4322/cerind.2018.002>. Acesso em: 20 dez. 2024.

HAMMES, N. S. **Algoritmo de visão computacional para recomendação de um manipulador robótico baseado na pose de objetos**. Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Santa Catarina, 2020.

HANZAEI, S. H.; AFSHAR, A.; Barazandeh, F. Detecção e classificação automática de defeitos superficiais dos revestimentos cerâmicos. **Pattern Recognition**, v. 66, p. 174–189, 2017.

HAO, R. *et al.* Uma abordagem de inspeção de defeitos de superfície de aço para monitoramento industrial inteligente. **Journal of Intelligent Manufacturing**, 2020.

HE, K. *et al.* **Deep residual learning for image recognition**, 2015.

HUANG, Y. *et al.* **Saliência do defeito da superfície da telha magnética**. *In: Conferência internacional IEEE sobre automação e engenharia*, Munique, Alemanha, 2018.

HUANG, M. Q. *et al.* BIM, técnicas de aprendizado de máquina e visão computacional na construção subterrânea: status atual e perspectivas futuras. **Tunnelling and Underground Space Technology**, v. 108, p. 103677, 2021.

ITCHHAPORIA, Dipti. Artificial intelligence in cardiology. **Trends in cardiovascular medicine**, v. 32, n. 1, p. 34-41, 2022.

JAMSHED, K. **Everything you need to know about Visual Inspection with AI**, 2021. Disponível em: <https://nanonets.com/blog/ai-visual-inspection/>. Acesso em: 20 dez. 2024

JIANG, S.; ZHANG, J. Real-time crack assessment using deep neural networks with wall-climbing unmanned aerial system. **Computer-Aided Civil and Infrastructure**

Engineering, v. 35, n. 6, p. 549-564, 2020.

KOSMAS, C. *et al.* Thermal non-destructive testing of porous ceramics. **Ceramics International**, v. 47, n. 4, p. 5254–5262, 2021.

KRIZHEVSKY, A. *et al.* Imagenet classification with deep convolutional neural networks. *In: Advances in Neural Information Processing Systems* 25, 2012.

KUMAR, T.; VERMA, K. A Theory Based on Conversion of RGB image to Gray image. **International Journal of Computer Applications**, 2010.

KURIC, I. *et al.* Approach to automated visual inspection of objects based on Artificial Intelligence. **Applied Sciences**, v. 12, n. 2, p. 864, 2022.
DOI: <https://doi.org/10.3390/app12020864>. Acesso em: 16 nov. 2024

LEE, K. *et al.* MultiDefectNet: Multi-Class defects detection of building façade based on deep convolutional neural network. **Sustainability**, v. 12, p. 9785, 2020. <https://doi.org/10.3390/su12229785>. Acesso em: 16 nov. 2024

LI, Z. *et al.* **A survey of convolutional neural networks: analysis, applications, and prospects.** *IEEE Transactions on Neural Networks and Learning Systems*, 2021.

LI, Y.; ZHAN, J. SAI Bench: Benchmarking AI for Science. **BenchCouncil Transactions on Benchmarks, Standards and Evaluations**, v. 2, n. 2, p. 100063, 2022. DOI: 10.1016/j.tbench.2022.100063.

LIMA, E. S. *et al.* Secagem de tijolos cerâmicos industriais e estimativa de parâmetros do processo: uma abordagem concentrada avançada. **Research, Society and Development**, v. 9, n. 12, p. 1-24, 2020.

LIU, Y. *et al.* DeepCrack: Uma arquitetura de aprendizado de recursos hierárquicos profundos para segmentação de trincas. **Neurocomputing**, v. 338, p. 139–153, 2019.

LUO, C. *et al.* Autonomous detection of damage to multiple steel surfaces from 360 panoramas using deep neural networks. **Computer-Aided Civil and Infrastructure Engineering**, v. 36, n. 12, p. 1585-1599, 2021.

MAHARANA, K.; OLIVEIRA, S.; NEMADE, B. Uma revisão: Técnicas de pré-processamento e aumento de dados. **Global Transitions Proceedings**, v. 3, p. 91–99, 2022.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999.

MINISTÉRIO DE MINAS E ENERGIA. **Anuário estatístico do setor metalúrgico e do setor de transformação de não metálicos (ano base 2019)**. Brasília, DF, 2020.

MOROPOULOU, A. *et al.* Infrared thermography as a tool for the protection of built heritage. **Journal of Cultural Heritage**, v. 31, p. 1–10, 2018.

MURPHY, K. P. **Machine learning: a probabilistic perspective**. MIT press, 2012.

NEVES, L. A. Nexos entre visão computacional e computação afetiva para o desenvolvimento da robótica. **Brazilian Journals**, v. 8, n. 4, p. 24991-25005, 2022.

NIELSEN, M. A. **Neural networks and deep learning**. Determination press, 2015.

OLIVEIRA, A. P. N. *et al.* **Matérias primas empregadas na fabricação de tijolos e blocos de construção: características e influências sobre as propriedades do Produto final**. Universidade Federal de Santa Catarina UFSC, Departamento de Engenharia Mecânica, 2005.

OTTONI, A. L. C.; NOVO, M. S.; COSTA, D. B. Hyperparameter tuning of convolutional neural networks for building construction image classification. **The Visual Computer**, v. 39, n. 3, p. 847-861, 2022.

OPENCV TEAM. **Introduction to OpenCV**, 2023. Disponível em: <https://docs.opencv.org/4.10.0/d1/dfb/intro.html>. Acesso em: 18 jun. 2024.

PADMAVATHI, K.; THANGADURAI, K. Implementation of RGB and Grayscale Images in Plant Leaves Disease Detection – Comparative Study. **Indian Journal of Science and Technology**, 2016.

PAIVA, J. G. S. *et al.* An approach to supporting incremental visual data classification. **IEEE transactions on visualization and computer graphics**, v. 21, n. 1, p. 4-17, 2014.

PITTINO, F. *et al.* Automatic anomaly detection on in-production manufacturing machines using statistical learning methods. **Sensors**, v. 20, n. 8, p. 2344, 2020.

PONTI, M. A.; COSTA, G. B. P. **Como funciona o deep learning**. arXiv preprint arXiv:1806.07908, 2018.

PONTI, M. *et al.* **Everything You Wanted to Know about Deep Learning for Computer Vision but Were Afraid to Ask**. In: *2017 30th SIBGRAPI Conference on Graphics, Patterns and Images Tutorials (SIBGRAPI-T)*, p. 17-41, 2017.

PONTI, M. *et al.* **Training Deep Networks from Zero to Hero: avoiding pitfalls and going beyond**, 2021.

RAMOS, B. **Reconhecimento de Anomalias em Peças Injetadas Através do Uso de Redes Neurais Convolucionais**, 2019.

RECALCATI, F.; MINGORI, F. R. **Desenvolvimento de Sistema utilizando Visão Computacional para Interação Humana**. Seminário de Iniciação Científica e Seminário Integrado de Ensino, Pesquisa e Extensão, 2020.

RÊGO, V. R.; SOARES, R. A. L. Avaliação do processo produtivo e das propriedades tecnológicas de blocos cerâmicos produzidos na região da Grande Teresina. **Cerâmica Industrial**, v. 20, n. 3, p. 42-45, 2015. Disponível em: <https://ceramicaindustrial.org.br/journal/ci/article/5876575c7f8c9d6e028b4828>. Acesso em : 12 jun. 2024

RIZK, Y. *et al.* Deep belief networks and cortical algorithms: A comparative study for supervised classification. **Applied computing and informatics**, v. 15, n. 2, p. 81–93, 2019.

RIZWAN, M. **Convolutional Neural Networks – In a Nut Shell**. engMRK, 2018. Disponível em: <https://engmrk.com/convolutional-neural-network-3/>. Acesso em : 12 jun. 2024.

RUDER, S. **An overview of gradient descent optimization algorithms**. arXiv preprint arXiv:1609.04747, 2016.

SANGHADIYA, F.; MISTRY, D. Detecção de defeitos de superfície em um ladrilho utilizando processamento digital de imagens: Análise e avaliação. **International Journal of Computer Applications**, v. 116, n. 10, p. 33–35, 2015.

SANTOS, R. C. **Formulação de massas cerâmicas para a produção de telhas**. 89 f, 2021. Dissertação (Mestrado em Engenharia de Materiais) - Universidade Federal de Campina Grande, Campina Grande, 2021.

SANTOS, R. S. **Estudo do processo de secagem de blocos cerâmicos estruturais**: modelagem e simulação. 215 f, 2019. Tese (Doutorado em Engenharia de Processos) - Universidade Federal de Campina Grande, Campina Grande, 2019.

SANTOS, T. T. Visão computacional aplicada na agricultura. *In: Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas*, p. 146-164, 2020.

SCIME, L.; Beuth, J. Detecção e classificação de anomalias em um processo de manufatura aditiva em leito de pó a laser usando um algoritmo de visão computacional treinado. **Additive Manufacturing**, v. 19, p. 114–126, 2018.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. **Neural networks**, v. 61, p. 85-117, 2015.

SEE, J. *et al.* The Role of Visual Inspection in the 21st Century. **Proceedings of the Human Factors and Ergonomics Society Annual Meeting**, v. 61, n. 1, p. 262-266, 2017.

SELHORST, M. **Ensino de normas técnicas para a verificação de qualidade de produtos de cerâmica vermelha utilizando sistema especialista**, 2001. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, 2001.

SIMONYAN, K.; ZISSERMAN, A. **Very deep convolutional networks for large-scale image recognition**. *CoRR*, v. abs/1409.1556, 2014.

SOARES, J. M. D. *et al.* **Panorama Sócio-Econômico das Indústrias de Cerâmica Vermelha da Região Central do Estado do Rio Grande do Sul**. Cerâmica Industrial, 2004.

SOUZA, K. T. **Estudo dos perfis de temperatura de peças cerâmicas e do fluxo de gases no interior de um forno intermitente**, 2020. Dissertação (Mestrado em Sistemas Aplicados à Engenharia e Gestão) – Instituto Federal Fluminense, Campos dos Goytacazes, 2020.

SOUZA, M. P. **Explicabilidade de modelos de visão computacional aplicados à detecção de COVID-19 em radiografias**, 2020. Disponível em: <https://hdl.handle.net/10438/30352>. Acesso 06 ago. 2024

SPOSTO, R. M. *et al.* **Melhoria da qualidade de blocos cerâmicos e implantação de sistemas de gestão da qualidade em empresas que abastecem o mercado de Brasília**. Universidade de Brasília, FUB/CDT, SINDUSCON-DF, 2006.

STAVROULAKIS P. *et al.* External Shape Measurement for Industrial Applications Using Artificial Intelligence and Optimised Data Fusion. *In*: ARAI K., KAPOOR S., BHATIA R. (eds) **Intelligent Systems and Applications. IntelliSys 2018**. Advances in Intelligent Systems and Computing, v. 869. Springer, Cham, 2019.

STEPHEN, O.; MADUH, U. J.; SAIN, M. A machine learning method for detection of surface defects on ceramic tiles using convolutional neural networks. **Electronics**, v. 11, n. 1, p. 55, 2021

SUN, X. *et al.* Research Progress of Visual Inspection Technology of Steel Products—A Review. **Applied Sciences**, v. 8, p. 2195, 2018.

SZELISKI, R. **Computer Vision: Algorithms and Applications**. Springer, 2010.

VOULODIMOS, A. *et al.* Deep Learning for Computer Vision: A brief review. **Computational Intelligence and Neuroscience**, v. 2018, p. 7068349, 2018. DOI: 10.1155/2018/7068349.

WAN, Z.; FANG, J.; WANG, Y. Ceramic tile surface defect detection based on deep learning. **Ceramics International**, v. 48, n. 8, p. 11085–11093, 2022.

WANG, H. *et al.* Review of research on ceramic surface defect detection based on deep learning. **Electronics**, v. 14, n. 12, p. 2365, 2025.

WANG, W. *et al.* Automated crack severity level detection and classification for ballastless track slab using deep convolutional neural network. **Automation in Construction**, v. 124, p. 103484, 2021. <https://doi.org/10.1016/j.autcon.2020.103484>. Acesso em: 13 set. 2024.

WEIMER, D. *et al.* Design of deep convolutional neural network architectures for automated feature extraction in industrial inspection. **CIRP Annals**, v. 65, n. 1, p. 417-420, 2016.

WILLIAMS, G. *et al.* Design repository effectiveness for 3D convolutional neural networks: Application to additive manufacturing. **Journal of Mechanical Design**, v. 141, p. 111701, 2019.

YANG, L. *et al.* Reconstrução 3d métrica semântica para inspeção de concreto. *In: Conferência IEEE sobre Workshops de Visão Computacional e Reconhecimento de Padrões*, Salt Lake City, UT, EUA, p. 1543–1551, 2018.

ZHONGHE, R. *et al.* **State of the Art in Defect Detection Based on Machine Vision**. International Journal of Precision Engineering and Manufacturing-Green Technology, 2021.