



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DO AGRESTE
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

JANE KELLY BARBOSA DE ALMEIDA

**VISÃO COMPUTACIONAL APLICADA A GESTÃO DA MANUTENÇÃO DE
SISTEMAS DE ENGRENAGENS**

Caruaru

2021

JANE KELLY BARBOSA DE ALMEIDA

**VISÃO COMPUTACIONAL APLICADA A GESTÃO DA MANUTENÇÃO DE
SISTEMAS DE ENGRENAGENS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, como requisito para obtenção do título de mestre em Engenharia de Produção.

Área de concentração: Otimização e Gestão da Produção

Orientador: Prof. Dr. Rodrigo Sampaio Lopes

Caruaru

2021

Catálogo na fonte:
Bibliotecária – Paula Silva - CRB/4 - 1223

A447v Almeida, Jane Kelly Barbosa de.
Visão computacional aplicada a gestão da manutenção de sistemas de engrenagens.
/Jane Kelly Barbosa de Almeida. – 2021.
95 f.; il.: 30 cm.

Orientador: Rodrigo Sampaio Lopes.
Dissertação (Mestrado) – Universidade Federal de Pernambuco, CAA, Pós-
Graduação em Engenharia de Produção, 2021.
Inclui Referências.

1. Engrenagens. 2. Imagens. 3. Processamento de imagens. 4. Desgaste
mecânico. 5. Aprendizado de computador. 6. Algoritmos. I. Lopes, Rodrigo
Sampaio (Orientador). II. Título.

CDD 658.5 (23. ed.)

UFPE (CAA 2021-124)

JANE KELLY BARBOSA DE ALMEIDA

**VISÃO COMPUTACIONAL APLICADA A GESTÃO DA MANUTENÇÃO DE
SISTEMAS DE ENGRENAGENS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, como requisito para obtenção do título de mestre em Engenharia de Produção.

Área de concentração: Otimização e Gestão da Produção

Aprovada em: 05/07/2021.

BANCA EXAMINADORA

Prof. Dr. Rodrigo Sampaio Lopes (Orientador)

Universidade Federal de Pernambuco

Profa. Dra. Marcele Elisa Fontana (Examinadora interna)

Universidade Federal de Pernambuco

Prof. Dr. Roberto Zanetti Freire (Examinador externo)

Pontifícia Universidade Católica do Paraná

Este trabalho é dedicado a todas as mulheres da minha família que infelizmente não tiveram a mesma oportunidade de estudar e construir uma formação acadêmica. Mulheres que por meio dos seus esforços construíram um futuro melhor para seus familiares e, apesar do pouco estudo, são mulheres que tem muita sabedoria, conhecimento, força, determinação, disciplina e coragem. São mulheres que inspiram outras pessoas a lutarem sempre pelos seus objetivos e nunca desistir.

Também dedico este trabalho a todas as vítimas do COVID19 que infelizmente deixaram seus sonhos incompletos ...

AGRADECIMENTOS

A Deus pela oportunidade de chegar até aqui com saúde, de vivenciar essa experiência acadêmica incrível, principalmente por tudo que Ele fez por mim ao longo desses anos de pesquisa.

Ao meu Orientador, Rodrigo Lopes, pela oportunidade de trabalharmos juntos e poder aprender a pesquisar e desenvolver novos conhecimentos necessários para uma carreira acadêmica e profissional, muito obrigada.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Capes e à Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco – FACEPE pelo apoio e incentivo na disponibilização da bolsa de pesquisa, IBPG-1420-3.08/18, a qual foi fundamental para a concretização dessa dissertação.

Ao Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco, campus Caruaru - IFPE, principalmente ao Prof. Dr. Diniz Júnior, pela disponibilidade do laboratório de fabricação e ao técnico Julyandryos pelo apoio técnico no laboratório de eletrônica, contribuições que foram importantes durante a construção da bancada experimental.

Aos meus amigos Nazareno Felipe, Lianne Torres, Ane Izabelle, Samara Míria, Bruna Maksuely, Lais de Moura, Arleson Kennedy, Layza Melo, Joyce Araújo e Bianca Sabrina pelo apoio e incentivo durante o desenvolvimento dessa dissertação.

Aos meus familiares, em especial, minha mãe, Eliana Barbosa, que sempre esteve junto comigo durante toda a minha trajetória acadêmica.

Aos meus colegas de mestrado pela oportunidade de aprender um pouco com cada um ao longo do curso.

Aos professores do PPGE CAA, em especial, a Profa. Dra. Marcele Elisa e a Profa. Dra. Thárcylla Clemente, por todos os ensinamentos compartilhados em sala de aula.

Aos Membros da Banca, Prof. Dr. Roberto Zanetti Freire, Profa. Dra. Marcele Elisa Fontana e Prof. Dr. Rodrigo Sampaio Lopes, pelas contribuições e sugestões de melhoria que foram fundamentais para enriquecer a pesquisa desenvolvida, muito obrigada.

“Pesquisar é navegar em mar aberto em busca de novos territórios desconhecidos”¹

A Autora (2021)

¹ Epígrafe de autoria própria construída a partir de pensamentos reflexivos.

RESUMO

O desgaste progressivo de peças rotativas como engrenagens é um problema recorrente, principalmente para sistemas de produção cada vez mais sensíveis as variações destes componentes. Por isso, este trabalho propõe um *framework* para detectar desgastes superficiais em engrenagens de dentes retos, por meio de imagens digitais superficiais de dentes de engrenagem. Com o objetivo de responder a quatro questões norteadoras sobre o tema visão computacional e gestão da manutenção, uma revisão sistemática foi elaborada por meio de pesquisas realizadas nas bases de dados *IEEE*, *Scopus*, *ScienceDirect* e *Web of Science* e o *software* Start foi utilizado no processo metodológico. Uma bancada experimental foi construída para permitir a captura de imagens de dentes de engrenagem por meio de câmeras endoscópicas. As imagens foram selecionadas, pré-processadas, armazenadas em um banco de dados e utilizadas no estudo experimental do *framework* proposto. Três métodos foram estudados no *framework* para a identificação de desgastes em engrenagens de dentes retos: detecção de bordas, extração de recursos *Gray Level Co-occurrence Matrix* (GLCM) aplicados em algoritmos de *machine learning* e *deep learning* com *Convolutional Neural Network* (CNN). Os resultados foram acurácia de 85% com o algoritmo de detecção de bordas, acima de 60% para o classificador *Support Vector Machine* (SVM) e superior a 70% para o classificador *K - Nearest Neighbors* (KNN), além disso o algoritmo PCA analisou o comportamento da combinação dos recursos *energy*, *homogeneity*, *contrast*, *dissimilarity*, *entropy* e *correlation* concluindo que o distanciamento gradativo dos componentes principais caracteriza a formação e avanço do desgaste e a *Convolutional Neural Network* (CNN) obteve acurácia de 99,999981% e taxa de *loss* de $1,8822 \times 10^{-5}$ no treinamento e CAR de 91,6666%, F1_Score de 90,9090% e Recall de 83,3334% durante a etapa de teste.

Palavras-chave: Engrenagem; Imagem; Visão computacional; Desgaste; Aprendizado de máquina.

ABSTRACT

The progressive wear of rotating parts such as gears is a recurrent problem, especially for production systems that are increasingly sensitive to variations in these components. Therefore, this work proposes a *framework* to detect surface wear in spur gears, through digital images of gear teeth surface. To answer four guiding questions about computer vision and maintenance management, a systematic review was developed through research carried out in the IEEE, Scopus, ScienceDirect and Web of Science databases and the Start software was used in the process methodological. An experimental bench was built to allow the capture of images of gear teeth using endoscopic cameras. The images were selected, pre-processed, stored in a database and used in the experimental study of the proposed *framework*. Three methods were studied in the *framework* for the identification of wear in spur gears: edge detection, Gray Level Co-occurrence Matrix (GLCM) resource extraction applied in *machine learning* algorithms and deep learning with *Convolutional Neural Network* (CNN). The results were 85% accuracy with the edge detection algorithm, above 60% for the *Support Vector Machine* (SVM) classifier and greater than 70% for the K - Nearest Neighbors (KNN) classifier, in addition the PCA algorithm analyzed the behavior of the combination of energy, homogeneity, contrast, dissimilarity, entropy and correlation resources, concluding that the gradual distancing of the main components characterizes the formation and advancement of wear and the *Convolutional Neural Network* (CNN) obtained an accuracy of 99.999981% and a rate of loss of 1.8822×10^{-5} in training and CAR of 91.6666%, F1_Score of 90.9090% and Recall of 83.3334% during the test stage.

Keywords: Gear; Image; Computer vision; Wear; Machine learning.

LISTA DE DIAGRAMAS

Diagrama 1 - sistema de controle do motor de partida.....	52
---	----

LISTA DE FIGURAS

Figura 1 - Exemplo simplificado da disponibilidade de dados brutos dos equipamentos.....	22
Figura 2 - Abordagem simplificada do ciclo de <i>machine learning</i>	23
Figura 3 - Etapas principais do programa Start.	35
Figura 4 - Nuvem das palavras dos artigos aceitos na primeira etapa de seleção.	37
Figura 5 - Autores dos artigos utilizados na etapa de sumarização.....	39
Figura 6 - <i>Framework</i> da abordagem CNN.....	49
Figura 7 - Modelo conceitual simplificado da bancada experimental.....	50
Figura 8 - Bancada experimental para captura de imagens de dentes de engrenagem.....	52
Figura 9 - Imagens resultantes da etapa de pré-processamento.....	55
Figura 10 - Processo de detecção de bordas dos dentes da engrenagem.	59
Figura 11 - Exemplos de imagens com e sem desgaste.....	72
Figura 12 - Relatório da etapa de teste da CNN.	78
Figura 13 - Imagens teste para verificar o desempenho da CNN treinada.	78

LISTA DE FLUXOGRAMAS

Fluxograma 1 - Métodos da visão computacional.....	24
Fluxograma 2 - <i>Framework</i> proposto para as metodologias utilizadas.....	47
Fluxograma 3 - <i>Framework</i> para detecção de bordas.....	48
Fluxograma 4 - <i>Framework</i> para extração de recursos GLCM.....	49
Fluxograma 5 - Utilização do método detecção de bordas.....	60
Fluxograma 6 - Utilização do método extração de recurso GLCM.	75
Fluxograma 7 - Utilização do método <i>Convolutional Neural Network (CNN)</i>	79

LISTA DE FOTOGRAFIAS

Fotografia 1 - Estudo e seleção dos componentes para compor a bancada experimental.	51
Fotografia 2 - Corte parcial realizado na carcaça do motor a esquerda da imagem.....	51
Fotografia 3 - Funcionamento da bancada experimental.....	53
Fotografia 4 - Engrenagem da bancada experimental.	54

LISTA DE GRÁFICOS

Gráfico 1 - Distribuição dos artigos.	36
Gráfico 2 - Processo de seleção dos artigos da RS.....	36
Gráfico 3 - Distribuição dos artigos ao longo dos anos 2013 a 2020.....	38
Gráfico 4 - Identificação dos países dos artigos selecionados para a RS.....	38
Gráfico 5 - Áreas de pesquisa dos artigos selecionados para a revisão sistemática.....	40
Gráfico 6 - Variação de distância em (a) de 1, (b) 10 e (c) 20 pixels para o KNN.	65
Gráfico 7 - Variação de distância em (a) de 1, (b) 10 e (c) 20 pixels para o SVM.	68
Gráfico 8 - Distância de 1 pixel e ângulo de rotação 0° (a), 45° (b), 90° (c) e 135° (d).....	71
Gráfico 9 - Resultado do PCA para distância de 1 pixel e direção angular de 0°	73

LISTA DE QUADROS

Quadro 1 - Palavras-chave utilizadas para a formação das <i>strings</i> de busca.	34
Quadro 2 - Campo de critérios de inclusão e exclusão cadastrados no protocolo.....	35
Quadro 3 - Área do estudo e técnicas de visão computacional aplicadas em cada artigo.....	40
Quadro 4 - Vantagens e desvantagens na abordagem de visão computacional.....	44
Quadro 5 - Pseudocódigo do pré-processamento das imagens capturadas;	55
Quadro 6 - Pseudocódigo para detecção de bordas.	58
Quadro 7 - Exemplos de desgastes superficiais em dentes de engrenagem.	60
Quadro 8 - Pseudocódigo para extração de recursos GLCM.	61
Quadro 9 - Recursos extraídos das imagens dos dentes da engrenagem.....	62
Quadro 10 - Pseudocódigo do <i>K - Nearest Neighbors</i> (KNN).	64
Quadro 11 - Pseudocódigo do <i>Support Vector Machine</i> (SVM).	67
Quadro 12 - Pseudocódigo do <i>Principal Component Analysis</i> (PCA).	70
Quadro 13 - Ações de recomendação resultantes do método PCA	74
Quadro 14 - Pseudocódigo do <i>Convolutional Neural Network</i> (CNN).	76
Quadro 15 - Análise de viabilidade dos métodos para a indústria.	81

LISTA DE TABELAS

Tabela 1 - Equações dos recursos GLCM.	27
Tabela 2 - Resultados da busca das <i>strings</i> nas bases de dados.	34
Tabela 3 - Critério utilizado para elencar os artigos importantes.	35
Tabela 4 - Classificação do nível de desgaste do dente da engrenagem	57
Tabela 5 - Classificação do desgaste dos dentes da engrenagem	59
Tabela 6 - Resultados do treinamento da CNN	77

SUMÁRIO

1	INTRODUÇÃO.....	18
1.1	JUSTIFICATIVA.....	19
1.2	OBJETIVOS.....	20
1.2.1	Objetivo geral	20
1.2.2	Objetivos específicos	20
1.3	ORGANIZAÇÃO DO TRABALHO	21
2	FUNDAMENTAÇÃO TEÓRICA	22
2.1	CONTEXTUALIZAÇÃO DA ÁREA DE ESTUDO	22
2.2	REVISÃO DA LITERATURA.....	23
2.3	ABORDAGEM CLÁSSICA.....	24
2.4	INTELIGÊNCIA COMPUTACIONAL	25
2.5	ALGORITMO DE DETECÇÃO DE BORDAS.....	26
2.6	EXTRAÇÃO DE RECURSOS GLCM.....	26
2.7	<i>SUPPORT VECTOR MACHINE (SVM)</i>	29
2.8	<i>PRINCIPAL COMPONENT ANALYSIS (PCA)</i>	30
2.9	<i>K - NEAREST NEIGHBORS (KNN)</i>	30
2.10	<i>CONVOLUTIONAL NEURAL NETWORK (CNN)</i>	31
2.11	SÍNTESE CONCLUSIVA	32
3	REVISÃO SISTEMÁTICA	33
3.1	QUESTÕES NORTEADORAS.....	33
3.2	LEVANTAMENTO BIBLIOGRÁFICO	33
3.3	ETAPAS DA REVISÃO SISTEMÁTICA	34
3.4	SÍNTESE CONCLUSIVA	45
4	<i>FRAMEWORK</i> PROPOSTO PARA DETECÇÃO DE DESGASTE SUPERFICIAL EM ENGRENAGEM DE DENTES RETOS.....	46
4.1	CONTEXTUALIZAÇÃO DA METODOLOGIA.....	46
4.2	DETECÇÃO DE BORDAS	47
4.3	EXTRAÇÃO DE RECURSOS GLCM.....	48
4.4	<i>CONVOLUTIONAL NEURAL NETWORK (CNN)</i>	49
4.5	SÍNTESE CONCLUSIVA	49
5	ESTUDO EXPERIMENTAL DO <i>FRAMEWORK</i> PROPOSTO	50
5.1	ESTUDO E EXPERIMENTO	50

5.2	MÉTODO PROPOSTO PARA DETECÇÃO DESGASTE EM SUPERFÍCIE DE DENTE DE ENGRENAGENS	53
5.2.1	Coleta de dados de imagens.....	54
5.2.2	Filtragem e pré-processamento.....	54
5.2.3	Método e aplicação do algoritmo para detecção de bordas.....	56
5.2.4	Método e aplicação do algoritmo para extração de recursos GLCM.....	60
5.2.4.1	<i>Algoritmo K – Nearest Neighbors (KNN).....</i>	63
5.2.4.2	<i>Algoritmo Support Vector Machine (SVM).....</i>	66
5.2.4.3	<i>Algoritmo Principal Component Analysis (PCA).....</i>	69
5.2.4.4	<i>Discursões gerenciais para a utilização do método extração de recurso GLCM.....</i>	74
5.2.5	Método e algoritmo Convolutional Neural Network (CNN).....	75
5.2.5.1	<i>Classificação por meio da Convolutional Neural Network (CNN).....</i>	77
5.3	RELEVÂNCIA GERENCIAL DA VISÃO COMPUTACIONAL PARA A GESTÃO DA MANUTENÇÃO	79
5.4	SÍNTESE CONCLUSIVA	81
6	CONCLUSÕES.....	82
6.1	CONTRIBUIÇÃO DA PESQUISA.....	83
6.2	TRABALHOS FUTUROS.....	84
	REFERÊNCIAS.....	85

1 INTRODUÇÃO

A detecção precoce do desgaste de elementos mecânicos em sistemas produtivos é um desafio para a gestão da manutenção, tendo em vista a dificuldade em realizar inspeções frequentes nas linhas de produção, além do alto custo de investimento em equipamentos de monitoramento contínuo. Simultaneamente, as manufaturas modernizam os sistemas produtivos e requerem o apoio da gestão da manutenção para garantir a disponibilidade dos novos recursos produtivos.

Deste modo, os sistemas de produção da indústria 4.0, flexíveis, complexos e inteligentes baseiam-se no uso de ferramentas de inteligência artificial para desenvolver a integração de sistemas, máquinas e pessoas (GARCÍA; GARCÍA, 2019). Desta forma, torna-se necessário desenvolver soluções para manter a precisão e eficiências das indústrias (HOANG; TRAN, 2019). Diversos setores como ferroviário (ZHANG; KONG, 2019), rodoviário (AZHAR *et al.*, 2016), predial (HOANG *et al.*, 2019), sistema elétrico (SOLIGON; NEO; DUAN, 2017) e indústrias (LI; JI, 2019) estão aplicando tecnologias de visão de máquina (visão computacional) para diagnosticar a necessidade de intervir com ações de manutenção. Com essa nova abordagem os pesquisadores buscam reduzir acidentes de trabalho, melhorar o cronograma de atividades dos mantenedores e reduzir custos com materiais e equipes de trabalho (CHEN *et al.*, 2020).

Os algoritmos de visão computacional baseiam-se no uso de recursos extraídos de imagens que apresentam características de cada problema estudado (SHABIR *et al.*, 2019). Na literatura são encontrados artigos que utilizam a visão computacional em gestão da manutenção, como por exemplo, corrosão de estruturas prediais (HOANG; TRAN, 2019), detecção das condições de trechos de pavimentos recuperados (HOANG, 2019) e detecção da presença de rachaduras em asfaltos (NHAT-DUC; NGUYEN; TRAN, 2018), fios elétricos rompidos (SONG; WANG; ZHANG, 2014), defeitos em superfícies de aço (HU *et al.*, 2014) e detecção de trincas em estruturas de concreto (TONG *et al.*, 2011).

As imagens extraídas de cada cenário analisado podem transmitir informações úteis para a tomada de decisão em gestão da manutenção, onde os defeitos podem ser classificados automaticamente e as ações de manutenção podem ser programadas de acordo com o grau de desgaste do sistema (LI; GUO; LI, 2020). Um desafio da aplicação da visão computacional são os ruídos que estão presentes nas imagens, neste sentido, existem técnicas de processamento de imagem digital que buscam filtrar, equalizar e revelar detalhes significativos, resultando, assim, em melhoria na qualidade da informação extraída (GOEL; JAIN, 2018).

Os métodos mais empregados para o tratamento das imagens são matriz de Co-ocorrência em Nível de Cinza (GLCM) (HTAY; MAUNG, 2018), filtros de Binarização (KARAN; DHOLAY, 2017), filtro Gaussiano (LOKMANWAR; BHALCHANDRA, 2019), algoritmo de segmentação Otsu (LIANG; JIANCHUN; XUN, 2018), Modelo de Cinza Discreto (DGM) (WANG; ZHANG, 2013).

Para o desenvolvimento deste estudo foi utilizada uma bancada experimental para aquisição das imagens de interesse e posteriores etapas de pré-processamento, processamento e classificação do nível de desgaste dos dentes da engrenagem. Os algoritmos aplicados, como o filtro de binarização, serviram de apoio para detecção de defeitos nos contornos do topo da face do dente de engrenagens de dentes retos.

A aplicação experimental-prática realizada é uma aplicação da visão computacional na gestão da manutenção sendo possível acompanhar o desgaste de componentes e, assim, fornecer informações que podem apoiar as decisões gerenciais da gestão da manutenção.

Para demonstrar as potencialidades do uso da visão computacional como uma ferramenta inovadora e de baixo custo, a ser inserida no ambiente industrial para o monitoramento e acompanhamento das condições dos ativos críticos dos processos produtivos, foram testadas três diferentes metodologias para detecção de desgastes em superfícies. Outro fator utilizado foi a exploração dessa nova área de visão computacional para diagnósticos e prognósticos de máquinas e equipamentos.

1.1 JUSTIFICATIVA

As revoluções industriais aumentaram o nível de complexidade existente nas instalações fabris e como resultado tem-se vários sistemas de produção, principalmente com demanda de produtos personalizados em períodos de tempos cada vez menores (ZAJAČKO *et al.*, 2018). Além disso, a competitividade do mercado reforça a necessidade de inserir abordagens inovadoras para atender as expectativas dos clientes (ZAJAČKO *et al.*, 2018).

Para garantir a disponibilidade dos sistemas produtivos a gestão da manutenção também necessitou integrar novos recursos tecnológicos como a inteligência artificial (IA) para ampliar a capacidade de resolução de problemas cada vez mais complexos. Abordagens como reconhecimento de padrões, visão computacional, diagnósticos de processamento de imagens, robótica e automação são alguns dos exemplos das aplicações difundidas que buscam auxiliar o gestor(decisor) na tomada de decisão (PATEL *et al.*, 2021).

Apesar da crescente utilização da inteligência artificial para análise e diagnóstico em diversas áreas, como saúde (HTAY; MAUNG, 2018), manutenção predial (DUGAN, 2013),

manutenção de pontes (PRASANNA *et al.*, 2016), reconhecimento de movimento (ZENGLER; KOPINSKI; HANDMANN, 2019), agricultura (ABBAS *et al.*, 2019), processos produtivos (LI *et al.*, 2018), entre outros, poucos são os estudos direcionados para análise e diagnóstico de defeitos nas superfícies de elementos rotativos, por isso foi selecionado o componente mecânico engrenagem de dentes retos como o objeto de estudo na construção da bancada experimental.

Portanto, este trabalho apresenta um *framework* que pode contribuir com a tomada de decisão em gestão da manutenção por meio da aplicação de três diferentes abordagens para detecção de desgastes em regiões superficiais de dentes de engrenagem. Além disso, esta pesquisa enriquece a literatura ao apresentar uma revisão sistemática sobre os principais estudos na área de visão computacional aplicadas ao contexto da gestão de manutenção. Os métodos aplicados nesse trabalho são soluções inovadoras e de baixo custo para que as manufaturas monitorem as engrenagens dos seus sistemas produtivos, sendo, portanto, uma nova alternativa diante das opções de equipamentos de monitoramento disponíveis no mercado. De acordo com Huang *et al* (2016), a inspeção e medição realizada com o auxílio da visão computacional pode proporcionar várias vantagens, como rapidez e precisão no diagnóstico, critérios considerados importantes para a tomada de decisão em gestão da manutenção.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Desenvolver um *framework* com base na visão computacional para apoiar a gestão da manutenção durante a análise e diagnóstico de desgaste em superfícies metálicas, oferecendo ao gerenciamento da manutenção uma ferramenta computacional capaz de fornecer informações úteis para apoiar a tomada de decisão em manutenção baseada na condição.

1.2.2 Objetivos específicos

- Construir uma bancada experimental para aquisição de dados e construção de banco de dados com imagens digitais;
- Construir um banco de dados de imagens de dentes retos de engrenagem;
- Desenvolver uma metodologia estruturada para aquisição e processamento de dados de imagens para auxiliar na gestão da manutenção;
- Adaptar algoritmos para detectar e classificar os níveis de desgastes em superfícies de dentes de engrenagens;

- Adaptar algoritmos para extrair propriedades de recursos de imagens digitais e utilizar algoritmos de inteligência artificial para a classificação automática do nível de desgaste;

1.3 ORGANIZAÇÃO DO TRABALHO

Esta pesquisa está organizada em 6 capítulos, o primeiro é a Introdução, e aborda a contextualização do tema visão computacional e suas aplicações em diversas áreas relacionadas com a gestão da manutenção, em seguida, a justificativa destaca a relevância do estudo da visão computacional para desenvolver soluções que contribua com a análise e diagnóstico de desgaste em superfícies de dentes de engrenagem e, ao final do capítulo, os objetivos geral e específicos que nortearam a pesquisa são apresentados.

O capítulo 2 é a Fundamentação Teórica, e aborda a contextualização da área do estudo, visão computacional e gestão da manutenção. Também é relatado uma breve revisão da literatura sobre as principais técnicas e métodos utilizados para o processamento de imagens que contribuíram para a seleção dos métodos algoritmo de detecção de bordas, extração de recurso GLCM e *Convolutional Neural Network* (CNN) a serem aplicados nesta pesquisa.

O capítulo 3 é a Revisão Sistemática, elaborada a partir de várias pesquisas nas bases de dados IEEE, *ScienceDirect*, *Scopus* e *Web of Science*. O processo sistemático de filtragem dos principais trabalhos, relevantes para esta pesquisa, foi realizado por meio da aplicação do *software* Start.

O capítulo 4 é o *Framework* Proposto para detecção de desgaste em dentes de engrenagem. Ao longo do capítulo uma contextualização geral e apresentação dos *frameworks* propostos detecção de bordas, extração de recursos GLCM com aplicação em algoritmos de *machine learning* e *Convolutional Neural Network* (CNN) é realizado.

O capítulo 5 é o Estudo Experimental do *Framework* Proposto, e detalha as informações sobre a construção da bancada experimental, o processo de coleta de imagens de dentes da engrenagem analisada, os resultados alcançados com a aplicação dos três *frameworks* propostos, as recomendações gerenciais para a manutenção são comentadas e a relevância gerencial da visão computacional para a gestão da manutenção.

O capítulo 6 é a Conclusão, reunindo as principais contribuições resultantes desta pesquisa para a área de gestão da manutenção e destacando outras oportunidades de pesquisas futuras relacionadas com o tema visão computacional e a área de gestão da manutenção.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresentará os principais conceitos relacionados com a área de visão computacional e o apoio a tomada de decisão em manutenção baseada na condição utilizados ao longo do desenvolvimento desta pesquisa. Além disso, também é apresentado uma breve revisão da literatura realizada para compreender as principais técnicas de processamento de imagens utilizadas na área de visão computacional.

2.1 CONTEXTUALIZAÇÃO DA ÁREA DE ESTUDO

Os equipamentos dos sistemas produtivos a todo momento transmitem sinais/dados do seu estado atual de funcionamento. Imagens dos componentes internos ou externos, ruídos sonoros, temperatura das peças do maquinário, surgimento de trincas nas superfícies, dentre outras formas, são exemplos da geração de dados brutos disponíveis para apoiar a gestão da manutenção por meio do monitoramento dos ativos críticos (HEGDE; ROKSETH, 2020). No entanto, a extração de informações úteis desses dados brutos, na maioria das vezes não estão acessíveis, pois a tecnologia na unidade produtiva não dispõe de dispositivos capazes de captar e interpretar a informação. A Figura 1 ilustra os dados em um sistema produtivo.

Figura 1 - Exemplo simplificado da disponibilidade de dados brutos dos equipamentos.



Fonte: A Autora (2021)

A falta dos dispositivos de monitoramento permite que as equipes de mantenedores busquem soluções alternativas por meio do acesso aos novos conhecimentos que são desenvolvidos e compartilhados pela comunidade acadêmica, pesquisadores etc. Os avanços computacionais como a inteligência artificial é apenas um exemplo das aplicações disponíveis aos gestores de manutenção (BALAMURUGAN et al., 2019). O aprendizado de máquina, também conhecido como *machine learning*, é uma das abordagens promissoras a serem difundidas nas empresas em diversos setores, principalmente na área de gestão da manutenção, pois os algoritmos de *machine learning* estão constantemente aprendendo e refinando a precisão da resposta final sobre o problema a ser solucionado (TONG et al., 2011).

A Figura 2 demonstra os passos principais envolvidos na aplicação dos algoritmos de *machine learning*. A primeira decisão do ciclo é determinar qual o formato dos dados que serão coletados, ou seja, se serão dados relacionados com o histórico das manutenções ou referentes

as condições do equipamento em um determinado período do tempo. Na sequência, os dados devem ser filtrados e armazenados para posteriormente iniciar a etapa de padronização e classificação das variáveis (KANAWADAY; SANE, 2018). Desta forma, os algoritmos de *machine learning* aprendem o comportamento dos dados de entrada e realizam previsões com um determinado nível de significância dos estados futuros (TRIVEDI et al., 2019). O incremento de novos dados, ou seja, a reinicialização do ciclo permite melhorar o treinamento dos algoritmos e, conseqüentemente, aumentar a acurácia dos modelos de previsão (KOLOKAS et al., 2018).

Figura 2 - Abordagem simplificada do ciclo de *machine learning*.



Fonte: A Autora (2021)

Nota: Adaptado de Lu *et al.* (2019).

As técnicas de processamento de imagens permitem que as regiões de interesse, *Region Of Interest* (ROI), forneçam dados capazes de construir uma padronização do estado da área superficial em análise (SONG; WANG; ZHANG, 2014).

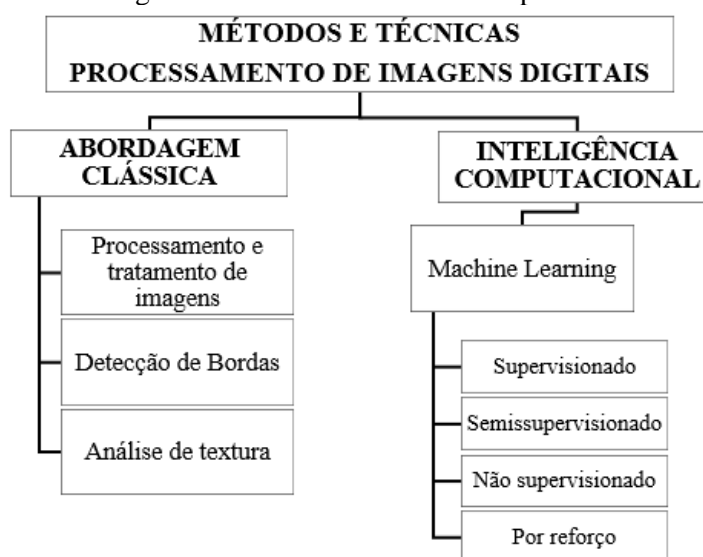
2.2 REVISÃO DA LITERATURA

De acordo com o objetivo da detecção a ser alcançado, técnicas específicas de processamento de imagens podem ser mais indicadas e eficientes em relação as outras. Portanto, com o objetivo de estudar e reunir informações sobre quais os métodos e técnicas utilizados em pesquisas da área de visão computacional, foi realizado uma pesquisa bibliográfica nas bases de dados *Scopus*, *ScienceDirect* e *IEEE*. Foram selecionados e analisados 124 artigos com a identificação de diversos métodos e técnicas de processamento de imagens digitais utilizados para identificação de desgastes em regiões superficiais em locais

como estradas, estruturas prediais de concreto e metálicas, superfícies de produtos acabados e em utilização.

Os métodos e técnicas foram divididos em dois grupos: abordagem clássica e inteligência computacional. A abordagem clássica refere-se aos processamentos, tratamentos, detecções de bordas e análises de texturas realizados nas imagens com o objetivo de remover os ruídos e facilitar a detecção da região de interesse e a abordagem inteligência computacional reúne as técnicas de aprendizado supervisionado, semissupervisionado, não supervisionado e profundo que foram aplicados nos artigos analisados. O Fluxograma 1 ilustra a divisão das abordagens apresentadas.

Fluxograma 1 - Métodos da visão computacional.



Fonte: A Autora (2021)

2.3 ABORDAGEM CLÁSSICA

Para o processamento e tratamento das imagens algumas das principais técnicas encontradas foram: *Thresholding and Smoothing Thresholding* (MOTAMEDI; FARAMARZI; DURAN, 2012), *Traditional Threshold Segmentation Algorithms e Otsu threshold segmentation algorithm* (LIANG; JIANCHUN; XUN, 2018), *Median Filtering, Histogram equalization, Sharpen filtering* (LI et al., 2018), *Savitzky-Golay Filter, Thresholding the Grayscale, Binary e Histogram* (CRINGASU; DRAGOMIRESCU; SAFTA, 2017), *Binary Image Processing* (ZHU et al., 2020), *Noise Removal, Grayscale, Contrast Enhancement* (XIA et al., 2020), *Gabor Filter* (SHABIR et al., 2019), *Gaussian Filter* (LOKMANWAR; BHALCHANDRA, 2019).

Com relação aos algoritmos de detecção de bordas, destaca-se as aplicações: *Sobel algorithm e Canny algorithm* (NHAT-DUC; NGUYEN; TRAN, 2018), *Canny Edge Detector*

(KARAN; DHOLAY, 2017), *Sobel Edge Detector*, *Canny Edge Detector*, *Fourier Transform e Fast Haar Transform* (ABDEL-QADER; ABUDAYYEH; KELLY, 2003), *Parallel Data-Driven Crack Location Method e Jaya K-Means-Based Crack Contour* (WANG; ZHANG; LUO, 2019). Para a extração de características textuais de imagens digitais foram identificadas as seguintes técnicas: *Statistical Properties of Color Channels*, *Gray-Level Co-Occurrence Matrix* (GLCM) e *Gray-Level Run Lengths (GLRL)*(HOANG; TRAN, 2019), *Local Binary Pattern* (QUINTANA; TORRES; MENÉNDEZ, 2016).

2.4 INTELIGÊNCIA COMPUTACIONAL

De acordo com SUN, HUANG & HUANG (2012), as técnicas de Inteligência Computacional (CI) buscam reproduzir o raciocínio humano e biológico, a tomada de decisão, o aprendizado e otimização por meio de técnicas de computação que imitam a capacidade evolutiva adaptativa dos seres vivos. Outros autores, Siddique & Adeli (2013, apud Guerra-Montenegro et al., 2021), definem a CI como um conjunto de metodologias e abordagens computacionais inspiradas na natureza para resolver problemas complexos do mundo real não suportados pelos métodos tradicionais de modelagem matemática.

O *Machine Learning* (ML), ou aprendizado de máquina, são algoritmos desenvolvidos em linguagem de programação para simular o processo de aprendizagem humana por meio do conhecimento adquirido ao analisar relacionamentos ocultos em dados(Entrada/Saída) de ambientes complexos e dinâmicos (WANG et al., 2021). Os métodos e técnicas de ML podem ser divididas em quatro principais abordagens: aprendizado supervisionado, não supervisionado, semissupervisionado e aprendizado por esforço (GUERRA-MONTENEGRO et al., 2021).

Theissler et al. (2021) define o aprendizado supervisionado como um modelo de ML que realiza treinamentos com dados rotulados para aprender sobre o relacionamento dos dados (Entrada/Saída), ajustando o modelo ao longo das iterações para alcançar os melhores níveis de precisão ao realizar a predição de dados futuros. Já a abordagem semissupervisionada os dados são parcialmente rotulados e utilizados para o treinamento de modelos de ML. Com a abordagem não supervisionada busca-se estruturar e descobrir os padrões desconhecidos dos dados, não rotulados, por meio da análise de semelhança entre os pontos do conjunto de dados. O aprendizado por reforço é uma abordagem que utiliza a técnica de tentativa e erro para treinar o modelo de ML a descobrir as ações que proporcionam as maiores recompensas, ou seja, a partir do desempenho do modelo ML pesos com penalidades ou recompensas são aplicados para refinar a precisão dos algoritmos ao realizar uma predição (THEISLER et al., 2021).

Por meio dessa pesquisa inicial foram selecionados três abordagens para desenvolver a identificação de desgastes em superfícies de dentes de engrenagem. Os métodos selecionados foram detecção de bordas com análise comparativa de medição manual, extração de recursos de imagens por meio de *Gray Level Co-occurrence Matrix* (GLCM) aplicados em algoritmos *machine learning* *K - Nearest Neighbors* (KNN), *Support Vector Machine* (SVM) e *Principal Component Analysis* (PCA) e, por fim, a utilização do algoritmo de aprendizado profundo, *Convolutional Neural Network* (CNN). Os métodos selecionados para este estudo serão apresentados a seguir.

2.5 ALGORITMO DE DETECÇÃO DE BORDAS

De acordo com Tang *et al.* (2020) as bordas de uma imagem são regiões onde ocorrem uma mudança significativa no brilho e existem regiões com diferentes tonalidades de cinza. Desta forma, ao reunir pontos adjacentes com a mesma cor e intensidade os contornos são formados e podem ser identificados. A detecção de bordas divide uma imagem por meio da identificação de mudanças abruptas de intensidade de tonalidade (PRATHUSHA; JYOTHI; MAMATHA, 2018).

O pré-processamento das imagens é importante para melhorar a precisão na detecção de bordas. Antes da detecção dos contornos é necessário que as imagens coloridas sejam convertidas em escalas de cinza e, posteriormente, em escala binária (ELIZABETH RANI; MURUGESWARI; RAJINI, 2020). Além disso, de acordo com Moradifar & Shahbahrami (2020), é necessário aplicar filtros para reduzir os ruídos presentes nas imagens e assim melhorar o processamento da detecção da região de interesse.

2.6 EXTRAÇÃO DE RECURSOS GLCM

De acordo com Krishna Jothi & Mohan (2020), a sigla GLCM significa *Grey Level Co-occurrence Matrix* e tem como objetivo extrair características textuais das imagens, também conhecidos como recursos estatísticos. Htay & Maung (2018) relatam que foi RM Haralick, K. Shanmugam e I. Dinstein que apresentaram as 14 características estatísticas que poderiam ser extraídas de uma imagem. As equações originais para a extração de recursos são apresentadas na Tabela 1, onde i e j representa os coeficientes das coordenadas da matriz em tons de cinza, N_g os níveis de cinza distintos da imagem, μ e σ representam a média e variância calculados dos pixels.

Tabela 1 - Equações dos recursos GLCM.

Recursos extraídos	Equações originais
Angular Second Moment (ASM)	$f_1 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} [P_d^\theta(i, j)]^2$
Contrast	$f_2 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} i-j ^2 P_d^\theta(i, j)$
Correlation	$f_3 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{ijP_d^\theta(i, j) - \mu_x\mu_y}{\sigma_x\sigma_y}$
Sum of Squares (SS)	$f_4 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i-\mu)^2 P_d^\theta(i, j)$
Inverse Difference Moment (IDM)	$f_5 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{1}{1+(i-j)^2} P_d^\theta(i, j)$
Sum Average (SA)	$f_6 = \sum_{i=2}^{2N_g} iP_{x+y}^\theta(i)$
Sum Variance (SV)	$f_7 = \sum_{i=2}^{2N_g} (i-f_8)^2 P_{x+y}^\theta(i)$
Sum Entropy (SE)	$f_8 = \sum_{i=0}^{N_g-1} P_{x+y}^\theta(i, j) \ln[P_{x+y}^\theta(i, j)]$
Entropy	$f_9 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_d^\theta(i, j) [\ln P(i, j)]$
Difference Variance (DV)	$f_{10} = \text{Variance of } P_{x-y}^\theta$
Difference Entropy (DE)	$f_{11} = \sum_{i=0}^{N_g-1} P_{x-y}^\theta(i) \log[P_{x-y}^\theta(i)]$
Information Measures Of Correlation (IOC)	$f_{12} = \frac{HXY - HXY1}{\max[HX, HY]}$
	$f_{13} = [1 - e^{-2.0(HXY2 - HXY)}]^{-\frac{1}{2}}$
	$HXY = \sum_i \sum_j P_d^\theta(i, j) \ln[P_d^\theta(i, j)]$
	$HXY1 = \sum_i \sum_j P_d^\theta(i, j) \ln[P_x^\theta(i)P_y^\theta(j)]$
	$HXY2 = \sum_i \sum_j P_x^\theta(i)P_y^\theta(j) \ln[P_x^\theta(i)P_y^\theta(j)]$
Maximum Correlation Coefficient (MCC)	$f_{14} = \sum_k \frac{P_d^\theta(i, k)P_d^\theta(j, k)}{P_x^\theta(i)P_y^\theta(k)}$

Fonte: A Autora (2021)

Nota: Adaptado de Wang & Ren (2014).

O método GLCM precisa de dois parâmetros, a distância (d) que geralmente inicia-se em 1, ou seja, 1 pixel de referência e seu vizinho, e o ângulo (θ), também conhecido como relação espacial, que pode assumir os valores de 0° , 45° , 90° e 135° para calcular as frequências relativas em nível de cinza dos pixels (ZHANG et al., 2016). Para esta pesquisa foi selecionado os 6 recursos estatísticos *energy*, *homogeneity*, *contrast*, *dissimilarity*, *entropy* e *correlation* devido a ampla aplicação na literatura. A seguir será detalhado as definições sobre os recursos utilizados.

A *energy* é o recurso no qual mede-se a uniformidade da textura, portanto, se a distribuição do nível de cinza estiver constante tem-se um valor alto de energia que varia entre 0 e 1. A Equação 1 é utilizada para calcular a energia, onde N_g representa o número de níveis de cinza na imagem, $P_d^\theta(i, j)$ representa a (i, j) éxima entrada em GLCM para calcular a probabilidade da presença de pares de pixels a certa distância (d) e ângulo (θ) (SINGH; SRIVASTAVA; AGARWAL, 2017).

$$Energy(d, \theta) = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} [P_d^\theta(i, j)]^2 \quad (1)$$

A *homogeneity* é o recurso que mede a distribuição de proximidade dos elementos GLCM com a diagonal GLCM (PRAMESTYA et al., 2018). A Equação 2 é utilizada para calcular a homogeneidade (SINGH; SRIVASTAVA; AGARWAL, 2017).

$$Homogeneity(d, \theta) = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{1}{1 + (i - j)^2} P_d^\theta(i, j) \quad (2)$$

O *contrast* é o recurso que mede a frequência espacial da imagem por meio da diferença entre os valores mais altos e baixos de um conjunto de pixels (PRAMESTYA et al., 2018). Calcula-se o contraste por meio da Equação 3 (SINGH; SRIVASTAVA; AGARWAL, 2017).

$$Contrast(d, \theta) = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} |i - j|^2 P_d^\theta(i, j) \quad (3)$$

A *dissimilarity* é um recurso que mede a distância entre pares de objetos (pixels) na região de interesse (ABORISADE et al., 2014). Calcula-se a dissimilaridade por meio da Equação 4.

$$Dissimilarity(d, \theta) = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_d^\theta(i, j) |i - j| \quad (4)$$

A *entropy* é um recurso que mede a aleatoriedade da textura de uma imagem. Quanto maior o valor da entropia, maior será a complexidade da imagem (PRAMESTYA et al., 2018). Calcula-se a entropia por meio da Equação 5.

$$Entropy(d, \theta) = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_d^\theta(i, j) [\ln P(i, j)] \quad (5)$$

A *correlation* é um recurso que mede o grau de correlação entre um pixel e os pixels vizinhos, além disso pode variar de -1 (perfeitamente correlacionado negativamente) até 1 (perfeitamente correlacional) (SINGH; SRIVASTAVA; AGARWAL, 2017). Calcula-se a correlação por meio da Equação 6.

$$Correlation(d, \theta) = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{ijP_d^\theta(i, j) - \mu_x\mu_y}{\sigma_x\sigma_y} \quad (6)$$

Onde μ_x e μ_y representam a média entre o pixel referência e o pixel vizinho, já σ_x e σ_y representam o desvio padrão das médias anteriores. As equações 7, 8, 8 e 10 são usadas para calculá-los (SINGH; SRIVASTAVA; AGARWAL, 2017).

$$\mu_x = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} iP_d^\theta(i, j) \quad (7)$$

$$\mu_y = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} jP_d^\theta(i, j) \quad (8)$$

$$\sigma_x = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \sqrt{(i - \mu_x)^2 P_d^\theta} \quad (9)$$

$$\sigma_y = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \sqrt{(j - \mu_y)^2 P_d^\theta} \quad (10)$$

2.7 SUPPORT VECTOR MACHINE (SVM)

O classificador *Support Vector Machine* (SVM) é um algoritmo de aprendizado de máquina, supervisionado, desenvolvido por (CORTES; VAPNIK, 1995) no qual o modelo conceitual é resolver problemas de classificação de dois grupos, por meio de vetores de entrada que realizam o mapeamento para definir uma superfície de decisão linear que diferencia dos dois grupos do conjunto de treinamento. De acordo com o resultado da classificação, os dados formam regiões que apresentam características comuns ao longo das fronteiras (SHEYKHMUSA et al., 2020).

Outra forma de definir o SVM é por meio de um hiperplano de separação onde os vetores de suporte são considerados os exemplos mais próximos do hiperplano de separação. Portanto,

o objetivo do SVM é orientar o hiperplano a manter a maior distância possível dos membros mais próximos de cada classe. Então, o hiperplano de separação torna-se o elemento de decisão que separa as duas classes (PULIDO; SOLAQUE; VELASCO, 2017).

2.8 *PRINCIPAL COMPONENT ANALYSIS (PCA)*

O *Principal Component Analysis* (PCA) foi desenvolvido por Pearson (1901) com o objetivo de analisar um conjunto de variáveis com altos índices de dimensionalidades espaciais em um plano bidimensional que represente as principais características dos dados analisados. Rehman et al., (2020) definem a *Principal Component Analysis* (PCA) como uma abordagem estatística baseada na transformação ortogonal onde ocorre a transformação de recursos possivelmente correlacionados em um conjunto linearmente não correlacionados denominados componentes principais. De acordo com Li *et al.* (2019b), o PCA é um método de redução de dimensionalidade no qual os recursos que tem grande influência nos resultados experimentais são selecionados entre os muitos recursos.

Os autores Wang & Meng (2019) consideram o PCA como um método estatístico multivariado utilizado para estudar como interpretar uma grande quantidade de informações de variáveis originais por meio de algumas combinações lineares, além disso, esses autores apresentam algumas relações existentes entre os componentes principais e suas variáveis originais como: cada componente principal é uma combinação linear de variáveis originais; o número de componentes principais é muito menor em relação as variáveis originais; o componente principal retém a maior parte das informações das variáveis originais; os componentes principais não estão correlacionados entre si.

2.9 *K - NEAREST NEIGHBORS (KNN)*

O classificador chamado de KNN, ou seja, método do k vizinho mais próximo, é um algoritmo de aprendizagem supervisionada desenvolvido por (FIX; HODGES; MEDICINE., 1951) onde seu princípio baseia-se na medição geométrica, ou seja, no cálculo da distância euclidiana (LIU; WEI; MENG, 2020). Desta forma as amostras são categorizadas pela maioria dos vizinhos mais próximos, assim, o “k” é um pequeno número inteiro e positivo que determina a qual classe a amostra pertence por meio da análise de “k” e os vizinhos mais próximos (ANDARABI et al., 2020).

O classificador KNN calcula a distância entre um ponto e os demais ao seu redor para determinar quais os vizinhos mais próximos, então o número de “k” indicará a quantidade de vizinhos mais próximos que serão procurados, além disso, caso sejam analisadas apenas duas classes o “k” é geralmente um número ímpar (BHARATE; SHIRDHONKAR, 2020).

Uma das funções que podem ser utilizadas para criar modelos do método KNN no *python* é a função `sklearn.neighbors.KNeighborsClassifier` que pertence a biblioteca `sklearn`, sendo necessário informar o parâmetro “k” (BAJPAI; HE, 2020).

2.10 CONVOLUTIONAL NEURAL NETWORK (CNN)

Outra técnica também considerada um subconjunto do *machine learning* é o *deep learning*, também conhecido como aprendizado profundo, o pesquisador Alexey G. Ivakhnenko foi um dos primeiros a realizar estudos nessa área, outros pesquisadores também se destacam como Bengio & Lecun (2007). O *deep learning* utiliza uma rede neural profunda que aprende sobre os recursos extraídos dos dados de entrada sem a interferência humana e a partir do processo de aprendizagem torna-se capaz de tomar decisões (GANATRA; PATEL, 2018). Este trabalho aplicou uma técnica particular do *deep learning* a *Convolutional Neural Network* (CNN).

De acordo com SILVA & CAPRETZ (2019), a sigla CNN significa *Convolutional Neural Network* e utiliza uma técnica de aprendizado profundo na qual o conhecimento é extraído de dados brutos. A arquitetura de uma CNN contém basicamente duas regiões principais, primeiramente, têm-se a região onde ocorre o processo de extração dos recursos e, em seguida, um classificador definirá a qual grupo pertence a imagem de entrada analisada.

A arquitetura de formação de uma CNN a imagem de entrada será redimensionada, compactada e formará os nós das camadas seguintes, desta forma, durante o processo de convolução os recursos são extraídos e propagados até alcançar a camada de classificação (ASLAM; SANTHI, 2019). Soomro et al (2019) destaca que existe três camadas principais em uma CNN, as camadas convolucionais, as camadas de *pooling* e as totalmente conectadas onde, de acordo com cada problema estudado, ocorrerá variações de uma arquitetura para outra.

Na camada Convulacional ocorre operações matemáticas para identificar e aprender sobre os diferentes recursos existentes na imagem de entrada, desta forma, por meio dos *kernels* das camadas de convolução, os mapas de recursos são gerados (SOOMRO et al., 2019). Já a camada pool tem o objetivo de reduzir o esforço computacional e a invariância ao deslocamento por meio da redução da resolução dos mapas de recursos, por isso essa camada transforma o mapa de recursos resultante da camada de convolução em um único valor para cada campo receptivo e a camadas totalmente conectada é responsável em conectar todos os neurônios das camadas anteriores e treiná-los para reconhecer as características que definem as classes definidas (SOOMRO et al., 2019).

2.11 SÍNTESE CONCLUSIVA

Este capítulo apresentou os estudos iniciais elaborados para a determinação dos métodos a serem explorados nesta pesquisa. Foram selecionadas três metodologias para verificar a aplicabilidade em diferentes contextos de detecção de desgastes em dentes de engrenagem. Os principais conceitos relacionados com os métodos detecção de bordas, extração de recurso GLCM com aplicação de algoritmos de *machine learning* (KNN, SVM e PCA) e *Convolutional Neural Network* (CNN) foram apresentados de forma a contribuir com o entendimento da aplicação dos métodos nos próximos capítulos.

3 REVISÃO SISTEMÁTICA

Neste capítulo será apresentado a revisão sistemática (RS) que foi desenvolvida com o objetivo de responder as questões norteadoras e reunir os principais trabalhos recentes relacionados com o tema da pesquisa desenvolvida.

3.1 QUESTÕES NORTEADORAS

As questões norteadoras estão listadas abaixo e espera-se que ao final deste capítulo sejam apresentadas suas respectivas respostas.

1. Quais os principais trabalhos relacionados com o tema visão computacional aplicada ao contexto da gestão da manutenção foram selecionados para a revisão sistemática e quais as técnicas aplicadas em cada pesquisa?
2. Onde concentram-se, geograficamente, os estudos utilizados na revisão sistemática e quais as principais áreas de aplicação considerando o campo da visão computacional no contexto da gestão da manutenção?
3. Quais as vantagens e desvantagens da utilização das técnicas de visão computacional para a tomada de decisão na gestão da manutenção?
4. Quais as lacunas encontradas na literatura que são oportunidades para o desenvolvimento de pesquisas futuras sobre gestão da manutenção e visão computacional?

Para responder aos questionamentos levantados, a seguir são reunidas todas as informações extraídas ao longo do processo de desenvolvimento da RS. Inicialmente, é apresentado como ocorreu o levantamento dos artigos nas bases de dados e, em seguida, os resultados obtidos são apresentados.

3.2 LEVANTAMENTO BIBLIOGRÁFICO

Os filtros utilizados nas bases de dados para essa revisão sistemática foram considerar apenas *journals* escritos na língua inglesa no período de 2009 a 2020, com acesso ao documento inteiro e apenas considerar os *journals* de áreas relacionadas com a gestão da manutenção. As *strings* de busca foram construídas por meio da combinação das *Keywords* por meio do operador lógico “AND”.

As *Keywords* foram selecionadas por meio de um *brainstorming* sobre quais as principais palavras relacionadas com o tema da pesquisa que poderiam auxiliar na identificação e seleção de artigos relevantes para a RS. O Quadro 1 apresenta as *Keywords* resultantes do *brainstorming* e as *strings* de buscas que foram formadas com a combinação de três palavras conectadas por meio do operador lógico “AND”.

Quadro 1 - Palavras-chave utilizadas para a formação das *strings* de busca.

Palavras-chave	String de busca
automation, classifier, computer, contour, convulation, corrosion, crack, detection, edge, extraction, feature, gear, glcm, image, inspection, knn, learning, machine, maintenance, network, neural, opencv, patch, processing, recognition, steel, support, surface, svm, texture, vector, vision	“image” and “detection” and “crack”
	“image” and “maintenance” and “machine” and “learning”
	“feature” and “gear” and “glcm”
	"image" and "inspection" and "neural"
	"opencv" and "image" and "maintenance"
	"wind turbines" and "image" and "maintenance"
"steel" and "image" and "maintenance"	

Fonte: A Autora (2021)

Apesar de não serem utilizadas todas as *Keywords* como *strings* de busca, outras análises foram realizadas por meio da identificação da presença dessas *Keywords* dentro dos artigos selecionados para a RS. O próximo passo foi definir quais as bases de dados a serem utilizadas e considerando a importância, relevância e uma maior possibilidade de encontrar os artigos de interesse. Para a RS foram selecionadas o *IEEE*, *Scopus*, *ScienceDirect* e *Web of Science*. A Tabela 2 apresenta os resultados da execução das *strings* de busca em cada base de dados onde esses artigos encontrados serão submetidos ao processo de seleção da RS.

Tabela 2 - Resultados da busca das *strings* nas bases de dados.


String de busca	Base de dados			
	IEEE	Scopus	ScienceDirect	Web of Science
“image” and “detection” and “crack”	54	281	975	202
“image” and “maintenance” and “machine” and “learning”	9	49	1257	33
“feature” and “gear” and “glcm”	-	10	7	1
"image" and "inspection" and "neural"	58	1073	179	26
opencv" and "image" and "maintenance"	7	66	33	3
"wind turbines" and "image" and "maintenance"	3	4	225	3
"steel" and "image" and "maintenance"	4	435	272	13

Fonte: A Autora (2021)

3.3 ETAPAS DA REVISÃO SISTEMÁTICA

O próximo passo foi utilizar a ferramenta computacional Start (*State of the Art through Systematic Review*), desenvolvida pelos pesquisadores da Universidade Federal de São Carlos (UFSCAR) do Laboratório de Pesquisa em Engenharia de Software (LAPES), para apoiar o processo organizacional metodológico da RS. O Start foi selecionado para ser aplicado nesta RS devido aos benefícios oferecidos pelo programa para identificar, selecionar e analisar os artigos relevantes para a pesquisa. A Figura 3 apresenta as três principais etapas que caracterizam a metodologia da RS.

Figura 3 - Etapas principais do programa Start.



Fonte: A Autora (2021)

No planejamento ocorre o preenchimento do protocolo responsável por nortear as etapas seguintes e são registradas informações sobre o objetivo principal da RS, principais questões a serem respondidas, quais as *Keywords* selecionadas, qual o idioma dos artigos, quais as bases de dados consideradas no estudo, os critérios de inclusão e exclusão dos artigos, além de informar as formas de seleção e extração dos dados dos artigos. O Quadro 2 apresenta os critérios adotados para análise de inclusão e exclusão dos artigos selecionados previamente durante a busca nas bases de dados.

Quadro 2 - Campo de critérios de inclusão e exclusão cadastrados no protocolo.

Critérios	
INCLUSÃO	EXCLUSÃO
<ul style="list-style-type: none"> ✓ Artigo do período 2009 - 2020; ✓ Artigos que contenham as <i>Keywords</i> no título; ✓ Artigos que contenham técnicas interessantes sobre o tema pesquisado; ✓ Artigos que disponibilizam o <i>full paper</i>; ✓ Artigos que utilizam dados de imagens como input nos algoritmos; 	<ul style="list-style-type: none"> ✓ Artigos que não sejam da área de manutenção; ✓ Artigos sem acesso ao material completo; ✓ Artigos não aprovados após a leitura do título e resumo; ✓ Artigos não aprovados após a leitura completa; ✓ Pontuação 0 obtida no score no programa Start.

Fonte: A Autora (2021)

Além disso, foi definido que o título e o resumo seriam também um instrumento de análise para selecionar os artigos. Foram estabelecidas as pontuações apresentadas na Tabela 3 para que o programa Start ranqueie os artigos de acordo com o score alcançado. Desta forma, os artigos com maiores scores foram priorizados durante a leitura do título e resumo devido a relevância destas pesquisas para a RS.


Tabela 3 - Critério utilizado para elencar os artigos importantes.

Critérios	Pontuação
Keywords no título	10
Keywords no resumo	5
Keywords nas <i>Keywords</i> do artigo	1

Fonte: A Autora (2021)

Após cadastrar todas as informações consideradas importantes para selecionar os artigos pode-se avançar para a etapa de execução, a qual é subdividida em três partes: (i) identificação

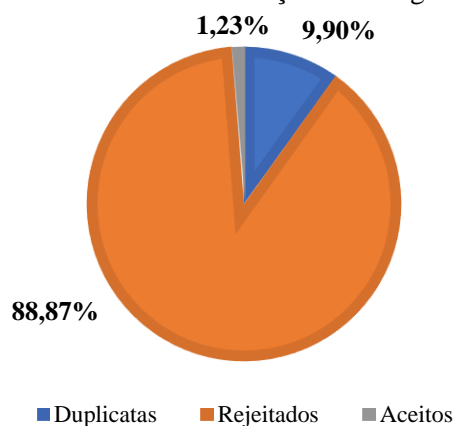
dos estudos; (ii) seleção e (iii) extração. Na etapa de identificação dos estudos foram criados os campos relacionados com as pesquisas executadas nas bases de dados e arquivos no formato Bibtex foram exportados das bases *Scopus*, *ScienceDirect* e *Web of Science* e na base *IEEE* exportou-se no formato RIS. Posteriormente estes arquivos foram inseridos na ferramenta Start nos respectivos campos de cada base de dados. O Gráfico 1 apresenta que 55,81% dos artigos foram encontrados na base de dados ScienceDirect, 36,31% na Scopus, 5,32% na Web of Science e 2,56% na IEEE.



Fonte: A Autora (2021)


Na etapa de seleção foram observados os 5282 artigos sendo encontrados 523 duplicatas, ou seja, artigos que estavam cadastrados em mais de uma base de dados. Por meio da leitura do título e resumo, 65 artigos foram aceitos para a próxima etapa, pois atendiam aos critérios de inclusão e 4694 foram rejeitados devido a alguns dos critérios de exclusão. O Gráfico 2 demonstra que aproximadamente de 1,23% dos artigos foram selecionados para a fase de extração e leitura integral do trabalho.

Gráfico 2 - Processo de seleção dos artigos da RS.



Fonte: A Autora (2021)

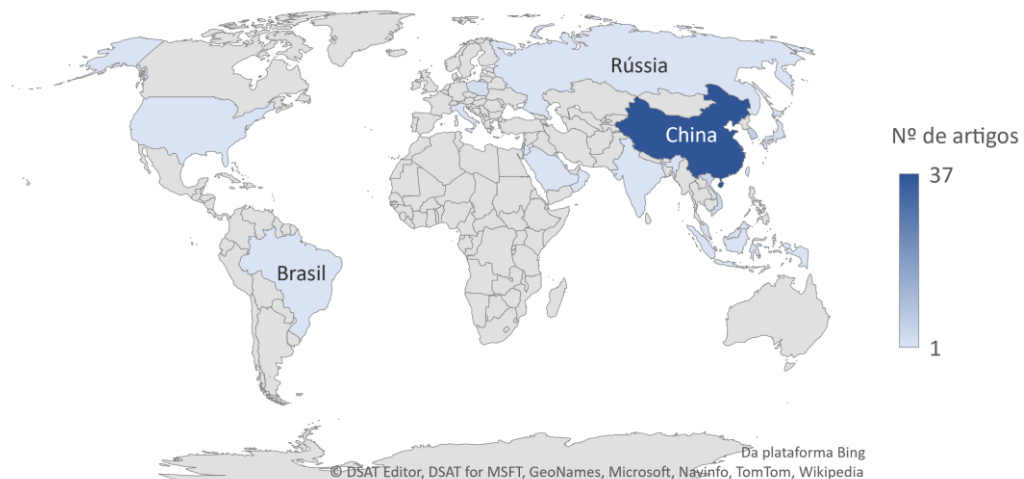
Gráfico 3 - Distribuição dos artigos ao longo dos anos 2013 a 2020.



Fonte: A Autora (2021)

Para responder à questão norteadora 2, analisou-se também onde estão concentrados geograficamente as pesquisas apresentadas nos artigos e a China foi o país com maior número de publicações, cerca de 58,73%, em seguida tem-se a Coreia do Sul com 9,52%, o Vietnã com 6,35%, a Polônia, Malásia e Japão com 3,17%, os demais países, Estados Unidos, Arábia Saudita, Brasil, Taiwan, Itália, Indonésia, Índia, Jordânia, Rússia e Omã com 1,59%, cada um respectivamente. O Gráfico 4 destaca os países citados anteriormente de acordo com o número de publicações, ou seja, quanto maior o número de artigos, mais escuro é a região no mapa mundial.

Gráfico 4 - Identificação dos países dos artigos selecionados para a RS.



Fonte: A Autora (2021)

Além disso, foi observado a identificação da frequência dos autores entre os artigos analisados e, por meio da nuvem de palavras da Figura 5, destaca-se, Nhat-Duc Hoang, Quoc-Lam Nguyen, Weidong Song, Xuefeng Zhao, Shengyuan Li, Li Li, Hong Zhu, Guohui Jia e Di

Jia como os que mais utilizam abordagens de visão computacional nas suas respectivas pesquisas para identificação e classificação de defeitos em superfícies de asfaltos e construções de concreto.

Figura 5 - Autores dos artigos utilizados na etapa de sumarização.




Fonte: A Autora (2021)

Nota: Retirado do *software Start* (2021).

Continuando a resposta da questão norteadora 2, a próxima análise foi observar quais as principais áreas onde os estudos estão concentrados, desta forma a área de Engenharia Civil destaca-se como o principal campo atuante em pesquisas que buscam identificar e classificar as *cracks*, como são chamadas as trincas e fissuras, encontradas em vias urbanas (LEI et al., 2020a), rodovias (CAO; LIU; HE, 2020), estruturas metálicas (WANG *et al.*, 2020) e de concreto (SHIM *et al.*, 2020) por meio do processamento de imagens.

No Gráfico 5 tem-se todos os campos de pesquisa identificados nos artigos selecionados onde a aplicação de imagens para realizar inspeção de controle de qualidade durante o processo de manufatura (FRUSTACI *et al.*, 2020) e ao longo da vida útil das peças (XU *et al.*, 2020) também está em crescimento devido a necessidade de reduzir as incertezas e falhas humanas no processo de inspeção manual. Outro fator positivo é a redução do tempo de resposta na identificação de uma peça defeituosa na linha de produção. Além disso, com os drones, veículos não tripulados, as possibilidades de obter imagens remotas de defeitos em superfícies, em locais de difícil acesso, são realidades encontradas nos trabalhos de Lei et al. (2020b), Shatnawi (2018) e Lin et al. (2019), nestes exemplos pode-se observar os benefícios da utilização da visão computacional.

Gráfico 5 - Áreas de pesquisa dos artigos selecionados para a revisão sistemática.



Fonte: A Autora (2021)

O artigo classificado como perspectivas futuras (KHAN; AL-HABSI, 2020) reúne as principais técnicas de processamento de imagens que estão presentes nas abordagens de aprendizado supervisionado, não supervisionado e semissupervisionado. Na maioria dos artigos os autores destacam uma crescente preocupação quanto a necessidade de inserir novas ferramentas tecnológicas para reduzir os esforços humanos durante as inspeções, assim como as subjetividades na tomada de decisão.

Outro fator importante é a segurança das pessoas e a possibilidade de redução de custos ao implementar metodologias baseadas em visão computacional, neste sentido, os autores destacam o quanto essas tecnologias trazem uma nova perspectiva para a tomada de decisão em gestão da manutenção devido a maior quantidade de informações disponíveis com confiabilidade cada vez maiores.

Por meio dos artigos resultantes da RS, a resposta da questão norteadora 1 foi apresentada no Quadro 3 com as principais informações das técnicas escolhidas e aplicadas, pelos autores, em suas respectivas pesquisas. Os pesquisadores buscam identificar as “cracks”, ou seja, trincas ou pequenas fissuras em diferentes superfícies como, por exemplo, regiões soldadas, estruturas de concreto e aço, construções civis e peças de maquinário.

Quadro 3 - Área do estudo e técnicas de visão computacional aplicadas em cada artigo.

Autores	Técnicas Aplicadas	Características dos trabalhos
(LEI et al., 2020a)	IoT; Extração de característica morfológicas;	Detecção de crack em superfícies soldadas
(YANG; LIU; PENG, 2019)	<i>Deep Convolutional Neural Network</i> (DCNN)	
(WANG; REN, 2014)	Técnica de Segmentação Imagem de micrografia com o uso do software DIGIMIZER	
(DONG et al., 2019)	Pré-processamento; Detecção de Bordas; Reconhecimento de textura CLTP; VSM	Detecção de <i>crack</i> em estruturas de concreto.

Fonte: A Autora (2021)

Quadro 3 - Área do estudo e técnicas de visão computacional aplicadas em cada artigo.

Autores	Técnicas Aplicadas	Características dos trabalhos
(LIANG; JIANCHUN; XUN, 2018)	Transformação não linear em escala de Cinza; Segmentação de limiar Otsu; VSM.	Detecção de <i>crack</i> em estruturas de concreto.
(TIAN et al., 2019)	Binarização; Método da Escala e Distância do objeto; Algoritmo estatístico de pixel de borda;	
(MANJURUL ISLAM; KIM, 2019)	<i>Deep Convolutional Neural Network</i> (DCNN)	
(SHEN et al., 2015)	Rede de sensores multimídia sem fio; Pré-processamento de imagem com filtragem mediana, Transformação High Cap e segmentação de limiar Otsu.	
(SHIM et al., 2020)	Rede Neural de Segmentação; Rede Neural discriminadora; Método de aprendizado multiescala e adversarial.	
(HOANG; NGUYEN, 2018a)	Filtro Mediana (MF); Algoritmos de detecção de bordas Roberts, Prewitt, Sobel e Canny; Algoritmo de Differential Flower Pollination (DFP);	
(CHUN; IZUMI; YAMANE, 2020)	Conversão em tons de Cinza; Filtro Gaussiano, Mediano, <i>Canny</i> ; Máquina de Aumento de gradiente de Luz (Light GBM);	
(QU et al., 2018)	Algoritmo de combinação; Método de percolação	
(ZHANG et al., 2019)	Rede Totalmente Convulacional (FCN); Aplicação de diferentes taxas de convolução dilatada.	
(LIN et al., 2019);	Algoritmo de detecção de bordas Canny; Recursos de padrões binários locais (LBP); classificador em cascata AdaBoost.	
(WANG et al., 2018)	Histograma de Gradientes Orientados (HOG); Recursos Padrões Binários Locais (LBP); Recursos Multi -visão;	
(ZHANG et al., 2014)	Pré-processamento da imagem; Rede Neural de Função de Base Radial (RBFNN); Aprendizado de Máquina Extremo (ELM); VSM; Classificador KNN	
(FENG et al., 2020); (ZHU; SONG, 2020); (LI; ZHAO, 2020); (RYU et al., 2020); (REN et al., 2020); (LAU et al., 2020)		
(XU et al., 2020); (SANTOS et al., 2020); (BUI et al., 2020); (ZABIŃSKI et al., 2019); (DENG; BAO; YE, 2020); (KIM; CHO, 2018);	<i>Convolutional Neural Network</i> (CNN).	Detecção de crack na superfície de comutadores de motores; correias de transportadoras; engrenagem, cabeçote de fresadora e placas de titânio.

Fonte: A Autora (2021)

Quadro 3 - Área do estudo e técnicas de visão computacional aplicadas em cada artigo.

Autores	Técnicas Aplicadas	Características dos trabalhos
(HU et al., 2018)	VSM; GLCM e PCA.	Detecção de crack em superfícies de rotores magnéticos.
(CAO; LIU; HE, 2020)	Segmentação por limiar; Método de detecção de bordas; Método de crescimento de região; Método de aprendizado não supervisionado, supervisionado.	Classificação de crack nas estruturas de pontes; barragens, ferrovias, prédios e estradas.
(OUYANG et al., 2019)	<i>Convolutional Neural Network (CNN)</i> .	Detecção de defeitos em tecidos
(ZHANG et al., 2018)	IoT; CNN; Técnicas de redução de ruído em imagens; Segmentação de imagens com o algoritmo Otsu.	Classificação de crack nas estruturas de pontes; barragens, ferrovias, prédios e estradas.
(MA et al., 2020); (LEI et al., 2020a)	CNN; Yolov3; Arvore de decisão;	
(GAO et al., 2020)	Matriz de Co – ocorrência em Nível de Cinza (GLCM); VSM.	
(SONG et al., 2020); (ZHANG et al., 2019);(LI; ZHAO, 2019)	FCN; DCNN.	
(HOANG, 2018a)	Método de detecção de crack Otsu; Discriminação de Nível de Cinza Min-Max (M2GLD).	
(IBRAHIM et al., 2019)	Segmentação da imagem; Extração de características; Classificador KNN e fuzzy KNN.	
(JANG et al., 2019)	CNN; Comparação de imagem baseada em contraste Weber;	
(SARI; PRAKOSO; BASKARA, 2020)	GLCM; Rede Neural Artificial (RNA)	
(SONG et al., 2019)	Módulo de Atenção Dilatada (MDA); Módulo Upsampling de Fusão de Recursos (FFU); Função <i>Generalized Dice Loss (GDL)</i> ;	
(SHATNAWI, 2018)	Pré-processamento: Função Normalização, conversão em tons de cinza; Detecção de bordas: Filtro Sobel; Extração de características: filtro bilateral, algoritmo Canny, clusterização K-means, filtro morfológico; Rede Neural Artificial (ANN)	
(LYASHEVA; TREGUBOV; SHLEYMOVICH, 2019)	Aumento do contraste; Operações morfológicas; Transformada Bottom-hat; Conversão de limiarização; Remoção de ruído; Detecção e classificação das bordas.	
(HOANG, 2018b)	Filtro Orientável (SF); Projeção Integral (PI); VSM; Máquina de Vetores de Suporte dos Mínimos quadrados (LSSVM);	

Fonte: A Autora (2021)

Quadro 3 - Área do estudo e técnicas de visão computacional aplicadas em cada artigo.

Autores	Técnicas Aplicadas	Características dos trabalhos
(LI et al., 2014)	Pré-processamento; Segmentação da Imagem; Rede Neural de Retropropagação (BPNN);	Classificação de crack nas estruturas de pontes; barragens, ferrovias, prédios e estradas.
(HOANG et al., 2019)	Propriedades estatísticas dos canais de cores; GLCM; Comprimento de Execução em Nível de Cinza (GLRL); Regressão Logística de Gradiente Descendente Estocástico;	
(HOANG; NGUYEN, 2018b)	Filtro de Mediana (MF); Filtro Orientável (SF); Projeção Integral (PI); Classificador <i>Navie Bayes</i> (NBC); Classificador Árvore (CT); Rede Neural Artificial de Retropropagação (BPANN); Rede Neural de Função de Base Radial (RBFNN); VSM;LSSVM;	
(ZHENG; LEI; ZHANG, 2020)	FCN; Regiões com recursos de Rede Neural Convulacional (R-CNN); <i>Richer Fully Convolutional Networks</i> (RFCN)	
(KHAN; AL-HABSI, 2020)	VSM; CNN; Segmentação e extração de recursos.	Avaliações sobre a perspectiva futura das tecnologias de visão computacional.
(GUAN; LEI; LU, 2020); (LEE et al., 2019)	CNN; Arvore de decisão e algoritmo SSIM.	Identificação e classificação de defeitos em superfícies de aço; Inspeção e detecção de defeitos em superfícies de peças fundidas após o processo de usinagem; Detecção de corrosão em estruturas subaquáticas.
(YANG et al., 2019)	R-CNN	
(LI et al., 2019a)	Algoritmo de agrupamento espectral; Remoção de interferência com base em informações de contorno; Suporte a Descrição de Dados Vetoriais (SVDD).	
(FRUSTACI et al., 2020)	Segmentação de imagem; Filtro mediano; Algoritmo de detecção de borda Canny; Filtragem morfológica.	
(THANIKACHALAM ; KAVITHA; BHARATHI, 2019); (HUANGPENG et al., 2018)	GLCM;SOM; Mapa Anterior de Textura	
(WANG et al., 2020b)	<i>Faster Convolutional Neural Network</i> (R-CNN); Sistema de Inspeção de Superfície Inteligente (SSIS).	
(ŚWILŁO; PERZYK, 2013)	Filtro de bordas Laplaciano de Gaus; Rede Neural.	
(SHAH et al., 2019)	Detecção de bordas com algoritmo Canny	Detecção de defeitos em superfícies de revestimentos cerâmicos.
(ZHUANG et al., 2020)	Rede de segmentação; Rede de decisão e detecção de ponto facial	Detecção de fadigas em motoristas
(WANG; MENG, 2019)	Segmentação de imagem; extração de recursos GLCM; VSM; PCA	Detecção de equipamentos elétricos

Fonte: Autora (2021)

Ao analisar as principais técnicas encontradas nos artigos da RS, pode-se destacar três abordagens: as *Convolutional Neural Network* (CNN), os métodos de detecção de bordas e a extração de recursos GLCM de imagens. Além disso, para melhorar o desempenho dos algoritmos, os autores também se preocupam em eliminar os ruídos presentes nas imagens, desta forma, aplicam o pré-processamento para tratar as imagens e obter a detecção e classificação da ROI de maneira mais precisa.

O classificador SVM foi um dos algoritmos de *machine learning* mais empregado entre os trabalhos analisados, entretanto, o classificador KNN, o PCA e diversas outras variações de Redes Neurais Artificiais também foram empregadas. Os autores comparam as precisões alcançadas para definir quão eficiente resultou a abordagem adotada.

É interessante destacar que o uso da visão computacional apresenta vantagens e desvantagens, como apresentado no Quadro 4, respondendo à questão norteadora 3. Um dos benefícios está relacionado com a tomada de decisão em gestão da manutenção, ou seja, os recursos tecnológicos da visão computacional permitem a obtenção de mais informações resultantes do aprendizado de máquina e, portanto, os ativos em monitoramento podem ser reparados de acordo com a condição que se encontram, evitando desta forma manutenções desnecessárias ou consideradas tardias para o reparo.

Quadro 4 - Vantagens e desvantagens na abordagem de visão computacional.

VISÃO COMPUTACIONAL	
Vantagens	Desvantagens
<ul style="list-style-type: none"> ➤ Evita a subjetividade humana na tomada de decisão (FRUSTACI et al., 2020); ➤ Monitoramento remoto de área de difícil acesso (SHEN et al., 2015); ➤ Facilita o planejamento para definição de prioridades na execução de ações da manutenção (WANG et al., 2020b). 	<ul style="list-style-type: none"> ➤ Necessidade de especialistas para validar o desempenho da técnica aplicada (HOANG et al., 2019); ➤ Diversos ruídos capturados nas imagens que exigem um tratamento para posterior utilização (ZHANG et al., 2018); ➤ Necessidade de equipamentos para capturar e processar as imagens do objeto monitorado (SHAJAHAN et al., 2019).

Fonte: A Autora (2021)

Por outro lado, é necessário que a equipe de mantenedores que utiliza a ferramenta de visão computacional seja acompanhada periodicamente por um especialista na área para que ele possa validar, calibrar, corrigir e atualizar a ferramenta utilizada, além disso, as imagens precisam ser tratadas para eliminar os ruídos que dificultam a classificação do defeito

superficial. Ao comparar as vantagens e desvantagens na aplicação do processamento de imagens na identificação de defeitos pode-se concluir que os benefícios ao longo do tempo superam as desvantagens com os resultados que serão alcançados, como por exemplo, redução de falha inesperada do equipamento em monitoramento, de custos operacionais associados a manutenções corretivas e maior eficiência no planejamento da manutenção.

Para responder à questão norteadora 4, foi observado nos trabalhos uma ampla aplicação na área de construção civil, como rodovias, ferrovias, pontes, túneis de metrô e edificações de concreto, aproximadamente 28,57% exploraram o tema inspeção de peças fabricadas e manutenção industrial. Desta forma, identifica-se uma lacuna na literatura que pode ser preenchida por meio do desenvolvimento de mais pesquisas voltadas a integrar as ferramentas de processamento de imagens como apoio no processo de tomada de decisão em gestão da manutenção. Além disso, outra oportunidade é estimular mais pesquisas voltadas ao desenvolvimento de novas ferramentas de inspeções visuais baseadas em aprendizado de máquina para melhorar o processo de seleção de peça defeituosas nas linhas de produção devido a necessidade de retirar a subjetividade e incerteza do julgamento humano no momento de definição de aprovação ou rejeição das peças fabricadas.

3.4 SÍNTESE CONCLUSIVA

Portanto, a revisão sistemática teve como objetivo responder as questões norteadoras ao longo do capítulo, além de contribuir para identificação e seleção dos métodos a serem utilizados para a construção do *framework* proposto nessa pesquisa para a detecção de desgaste na superfície de dentes retos de engrenagem. Outra contribuição da RS é demonstrar as oportunidades de pesquisa no campo da visão computacional, principalmente para inspeção e manutenção de construções civis e, desta forma, incentivar que outros pesquisadores desenvolvam novos estudos voltados ao uso de dados de imagens como apoio para a obtenção de mais informações que contribuam com a resolução de problemas reais presentes nas industriais. Estradas, túneis de metrô, estruturas prediais metálicas e de concreto são alguns dos principais objetos de estudo dos pesquisadores atualmente. Esses estudos buscam reduzir a incerteza humana e recomendar ações de intervenção de manutenção antes do agravamento da situação, além de evitar a exposição dos mantenedores a ambientes com alto risco de acidentes. O avanço na utilização de imagens para diagnósticos e prognósticos de problemas de manutenção é um processo importante para o crescimento e fortalecimento da manutenção autônoma tanto em ambientes industriais quanto em setores externos como estradas, rede de geração e distribuição de energia etc.

4 **FRAMEWORK PROPOSTO PARA DETECÇÃO DE DESGASTE SUPERFICIAL EM ENGRENAGEM DE DENTES RETOS**

Este capítulo apresentará os *frameworks* propostos das três abordagens utilizadas para a detecção de desgastes em dentes de engrenagem: detecção de bordas, extração de recursos da *Grey Level Co-occurrence Matrix* (GLCM) e *Convolutional Neural Network* (CNN).

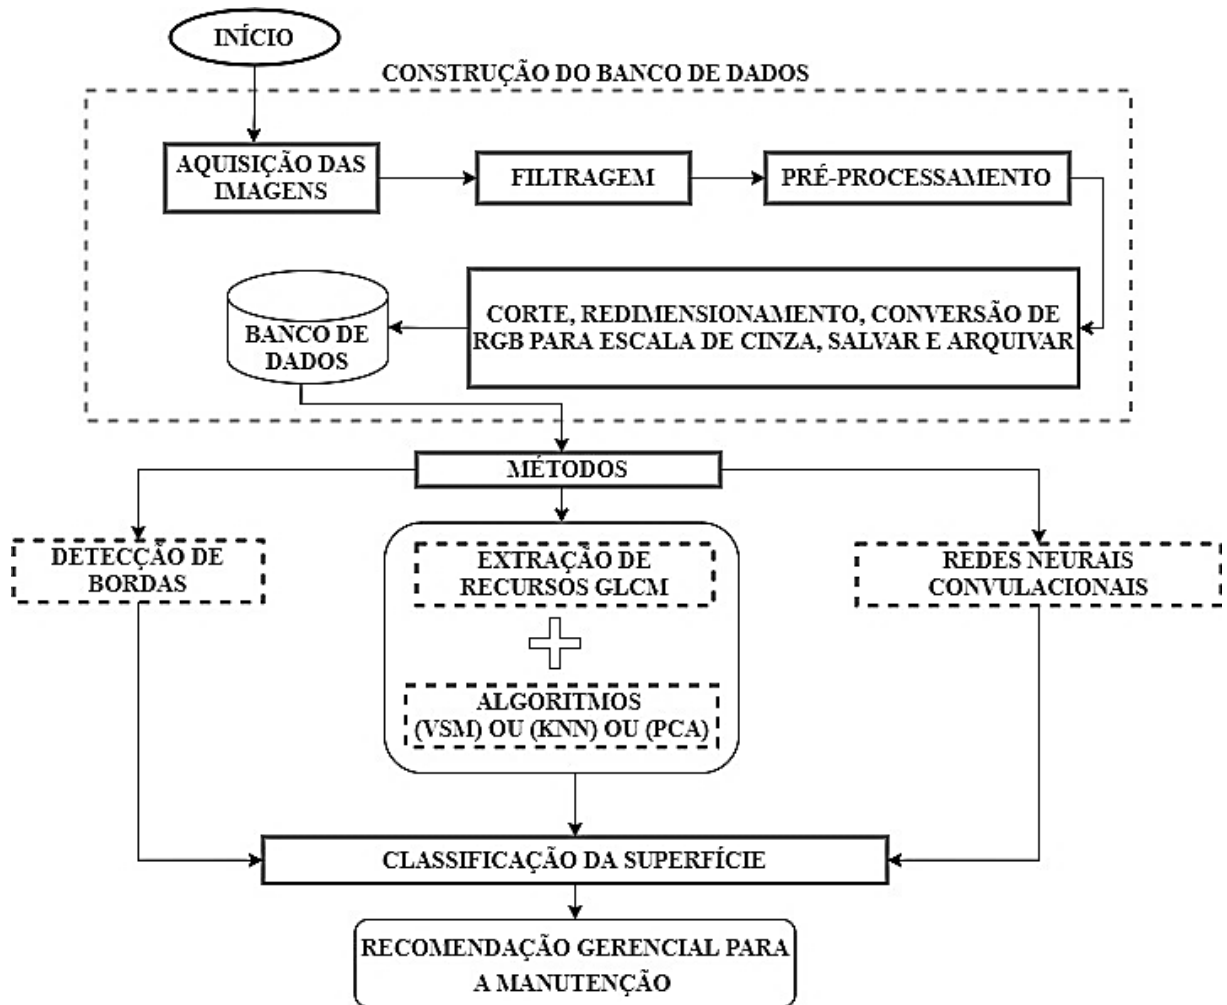
4.1 CONTEXTUALIZAÇÃO DA METODOLOGIA

A metodologia proposta para a detecção de desgaste na superfície de dentes de engrenagem é subdividida em três partes: abordagem detecção de bordas, extração de recursos (GLCM) com algoritmos *Support Machine Vector* (SMV), *K-Nearest Neighbors* (KNN) e *Principal Component Analysis* (PCA), e *Convolutional Neural Network* (CNN). Os métodos utilizam imagens digitais do topo da face de dentes de engrenagem para realizar a detecção de desgaste na região.

Para utilizar as metodologias propostas foi necessário construir uma bancada experimental composta por motor a combustão interna, com partida elétrica, bateria, fonte de corrente contínua, placa de controle, uma lâmpada e duas câmeras endoscópicas para capturar as imagens superficiais das faces dos dentes da engrenagem durante o intervalo de funcionamento da bancada experimental.

O método experimental foi o meio utilizado para registrar a condição da engrenagem, capturando imagens dos dentes da engrenagem nos intervalos do funcionamento do sistema. Durante o período de funcionamento da bancada foi construído um banco de dados com 1430 imagens. A metodologia proposta inspira-se nos estudos de Karan & Dholay (2017), para detecção de bordas, Hoang & Tran (2019), para extração de recurso GLCM, e ATHA & JAHANSHAH, (2018), para aplicação de *Convolutional Neural Network* (CNN).

O fluxograma 2 apresenta o *framework* proposto para a aplicação das metodologias propostas onde inicia-se com a aquisição das imagens por meio da bancada experimental, em seguida, uma filtragem é realizada para remover alguma imagem irregular, o próximo passo é o pré-processamento das imagens, onde ocorre o corte, redimensionamento, alteração da cor de *Red*, *Green* e *Blue* (RGB) para uma escala de cinza e o salvamento das imagens em um banco de dados. As imagens são utilizadas em cada método e, como resultado, tem-se a detecção e classificação da superfície da face dos dentes da engrenagem, além disso, cada método apresenta uma recomendação gerencial para auxiliar a tomada de decisão em manutenção baseada na condição do desgaste detectado.

Fluxograma 2 - *Framework* proposto para as metodologias utilizadas.

Fonte: A Autora (2021)

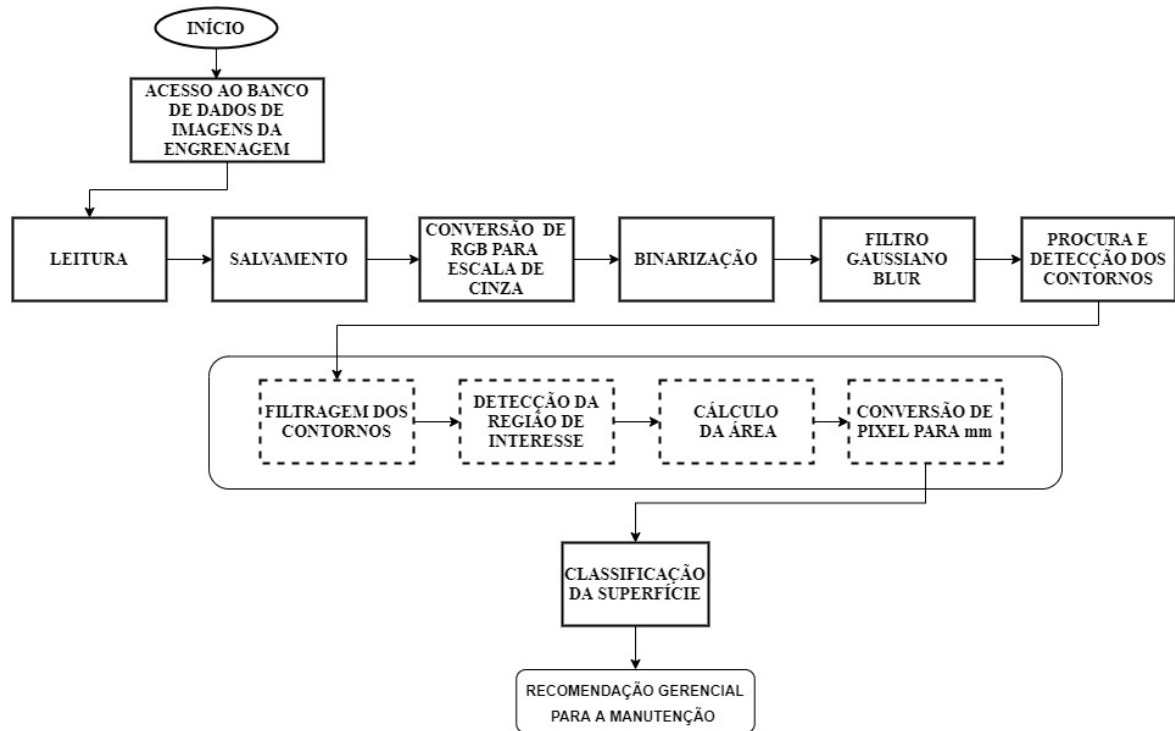
Algoritmos de visão computacional foram aplicados por meio da linguagem de programação em *python* para analisar o desempenho de cada abordagem no processo de detecção de desgastes dos dentes da engrenagem. Além disso, a metodologia aplicada neste trabalho busca destacar o potencial do uso de imagens para apoiar a tomada de decisão em manutenção baseada na condição. Com as informações resultantes dos algoritmos de visão computacional a equipe de mantenedores pode determinar qual a manutenção mais adequada para os equipamentos em monitoramento.

4.2 DETECÇÃO DE BORDAS

A metodologia aplicada, detecção de bordas, é composta por 12 etapas e contém princípios semelhantes ao trabalho desenvolvido por (KARAN; DHOLAY, 2017) no qual o objetivo é detectar anomalias nas superfícies das áreas por meio do processamento de imagens.

O Fluxograma 3 apresenta todas as etapas da metodologia aplicada onde o objetivo final é calcular a área superficial do dente e detectar se ocorreu uma redução de área devido ao desgaste na região de interesse. Desta forma, por meio dos resultados de desgastes algumas ações de recomendação são apresentadas para o gestor de manutenção.

Fluxograma 3 - *Framework* para detecção de bordas.

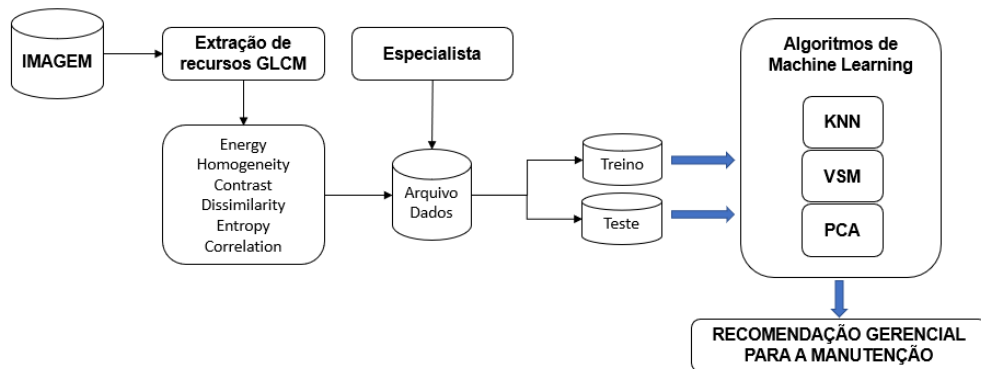


Fonte: A Autora (2021)

4.3 EXTRAÇÃO DE RECURSOS GLCM

A metodologia aplicada, extração de recursos GLCM, é apresentada no Fluxograma 4 e, de forma simplificada, representa as etapas do processo de obtenção das informações sobre as propriedades *energy*, *homogeneity*, *contrast*, *dissimilarity*, *entropy* e *correlation* das 1430 imagens dos dentes da engrenagem da bancada experimental. Em seguida, essas informações foram integradas com a opinião do especialista sobre a condição de cada imagem dos dentes da engrenagem e os dados resultantes foram separados entre arquivos de teste e treino para posterior aplicação dos algoritmos de *Support Machine Vector (SMV)*, *K-Nearest Neighbors (KNN)* e *Principal Component Analysis (PCA)*.


Para cada resultado dos algoritmos de *machine learning* são apresentadas ações de recomendação gerencial para a manutenção, desta forma, de acordo com nível do desgaste identificado, as ações podem indicar a continuidade do funcionamento do equipamento ou alertar a importância de interromper o funcionamento do equipamento e realizar o reparo preventivo necessário.

Fluxograma 4 - *Framework* para extração de recursos GLCM.

Fonte: A Autora (2021)

4.4 CONVOLUTIONAL NEURAL NETWORK (CNN)

A metodologia *Convolutional Neural Network* (CNN) foi utilizada para realizar a detecção de desgaste da região superficial de dentes de engrenagem por meio do treinamento de uma CNN. A Figura 6 apresenta o *framework* proposto para a utilização da CNN no processo de detecção de desgaste, composta por 2 camadas convolucionais arquitetadas com 32 filtros e *Kernel* (3,3), ativadas por meio da função ativação “Relu” e 2 camadas *Polling* Máximo com dimensão (2,2), a camada totalmente conectada tem 2 neurônios que serão conectados aos neurônios resultantes das camadas anteriores. De acordo com os resultados da CNN, as ações de recomendação para a gestão da manutenção são definidas.

Figura 6 - *Framework* da abordagem CNN.

Fonte: A Autora (2021)

Nota: Adaptado de Atha & Jahanshahi (2018)

4.5 SÍNTESE CONCLUSIVA

Este capítulo apresentou as metodologias utilizadas por meio de diagramas simplificados que ilustram as principais etapas da aplicação dos métodos detecção de bordas, extração de recursos GLCM com algoritmo de *machine learning* (KNN, SVM e PCA) e *Convolutional Neural Network* (CNN) para detectar o desgaste em dentes de engrenagem.

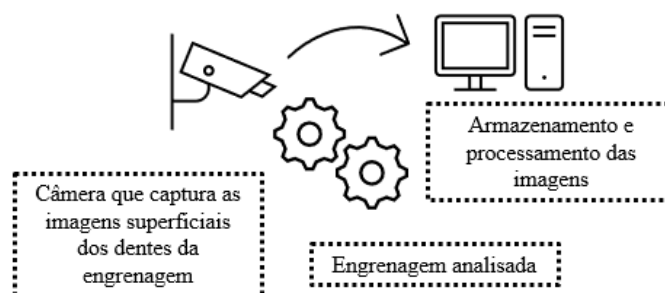
5 ESTUDO EXPERIMENTAL DO *FRAMEWORK* PROPOSTO

Neste capítulo será detalhado as principais informações sobre o processo de construção da bancada experimental, seu princípio de funcionamento e como ocorreu a coleta de dados de imagens dos dentes da engrenagem do sistema de partida elétrico do motor a combustão. Além disso, os resultados alcançados serão utilizados para validar os *frameworks* propostos no capítulo 4 para a detecção de desgaste em dentes de engrenagem.

5.1 ESTUDO E EXPERIMENTO

Para estudar a identificação de desgastes em dentes de engrenagens foi necessário construir um banco de dados de imagens. Com esse objetivo foi desenvolvida uma bancada experimental para permitir a captura das imagens de dentes da engrenagem. O modelo conceitual do experimento pode ser observado na Figura 7 no qual o objetivo é registrar a condição da face do dente após um período de funcionamento e arquivar as imagens para posteriormente realizar o processamento e aplicação dos algoritmos para a identificação do desgaste.


Figura 7 - Modelo conceitual simplificado da bancada experimental.



Fonte: A Autora (2021)

O próximo passo foi selecionar os componentes da bancada experimental e, após realizar diversas pesquisas sobre quais sistemas estudar, foi definido analisar a engrenagem intermediária do sistema de partida elétrica de um motor a combustão. Deste modo, a bancada experimental ficou composta por motor de combustão interna com partida elétrica, bateria contínua de 12 volts, relé de partida, 2 módulos relés de 5 volts, uma fonte de corrente contínua de 5 ampères, uma mini protoboard, uma placa de arduino uno, uma lâmpada, duas câmeras endoscópicas e um botão *on-off*, além disso um computador fornece a alimentação elétrica necessária para o funcionamento do arduino e também executa o programa que reconhece as imagens capturadas das câmeras endoscópicas. A Fotografia 1 reúne algumas imagens dos componentes para etapa de estudo do funcionamento da bancada experimental.


Fotografia 1 - Estudo e seleção dos componentes para compor a bancada experimental.



Fonte: A Autora (2021)

A engrenagem selecionada como objeto de estudo apresentava-se no interior da carcaça de alumínio do motor, portanto, para estudar o desgaste dos dentes desta engrenagem foi necessário realizar um corte parcial para que as câmeras endoscópicas conseguissem capturar as imagens durante o intervalo de funcionamento do sistema. Foram utilizadas duas câmeras endoscópicas para possibilitar a captura de mais imagens de diferentes dentes da engrenagem durante o mesmo intervalo de funcionamento. A Fotografia 2 demonstra o antes e depois da região onde ocorreu o corte parcial.


Fotografia 2 - Corte parcial realizado na carcaça do motor a esquerda da imagem.



Fonte: A Autora (2021)

A próxima etapa foi organizar o posicionamento dos componentes na bancada, buscando garantir a captura das imagens da face dos dentes da engrenagem, desta forma, devido a transmissibilidade da vibração resultante do funcionamento do motor de partida, as câmeras endoscópicas foram posicionadas em uma bancada auxiliar. A disposição de todos os componentes pode ser observada na Figura 8 onde cada item está identificado na imagem por meio de uma numeração.

Figura 8 - Bancada experimental para captura de imagens de dentes de engrenagem.

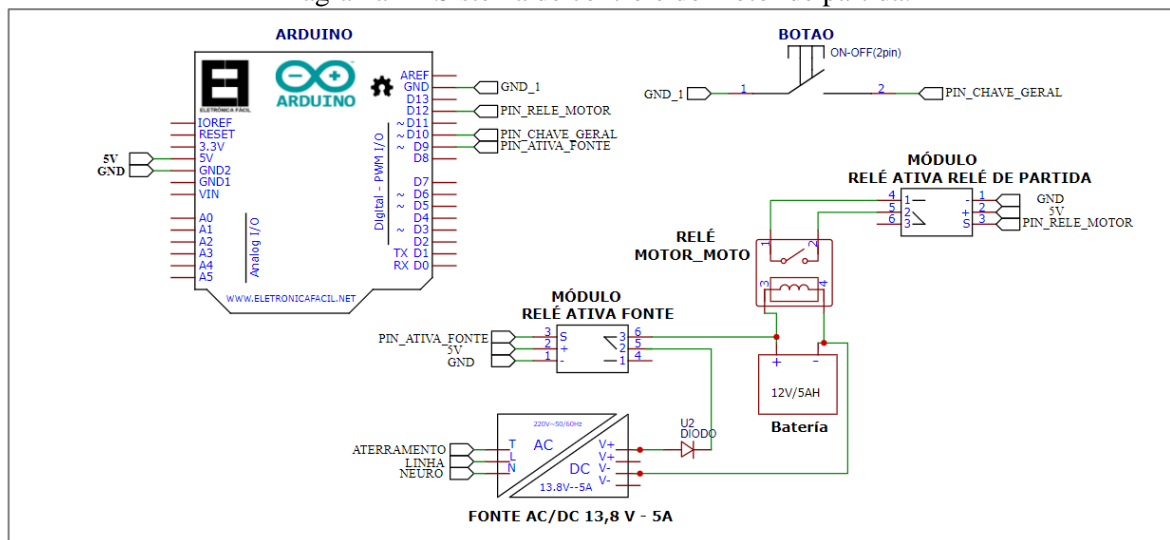


- | | |
|---|---------------------------|
| 1 – Motor a combustão; | 6 – Mini protoboard; |
| 2 – Bateria contínua 12 volts; | 7 – placa de Arduino Uno; |
| 3 – Relé de partida de moto; | 8 – Lâmpada de LED; |
| 4 – Módulo relé 5 volts; | 9 – Câmeras endoscópicas; |
| 5 – Fonte de corrente contínua 5 ampères; | 10 – Botão ON –OFF. |

Fonte: A Autora (2021)

Para controlar o acionamento do sistema de partida elétrica do motor a combustão foi necessário utilizar o diagrama eletrônico apresentado no Diagrama 1. O acionamento inicia-se com ativação do botão ON-OFF que libera um sinal lógico de entrada para o pino 10, em seguida, um sinal lógico de saída é liberado do pino 9 para desativar o módulo relé que controla a fonte de corrente que está recarregando a bateria de 12 v.

Diagrama 1 - Sistema de controle do motor de partida.



Fonte: A Autora (2021)

Ao atender as condições anteriores, o pino 12 envia o sinal lógico de saída para o módulo relé que controla o acionamento do relé do motor de partida, desta forma, o motor de partida

funciona durante o tempo programado e, logo após, permanece um tempo em repouso, neste intervalo, o módulo relé que controla o motor de partida é desativado e o módulo relé que controla a fonte de corrente é ativado, este ciclo se repete até 10 ciclos serem finalizados e um período de 10 minutos de repouso é ativado para proporcionar a recarga da bateria. As câmeras endoscópicas são programadas, por meio de um *software open source Yawcam*, para capturar as imagens da face dos dentes da engrenagem durante o intervalo de funcionamento do sistema. As imagens capturadas são armazenadas no computador em pastas e posteriormente são filtradas, pré-processadas e armazenadas em um novo banco de dados para que os métodos de detecção de desgaste tenham acesso.

A Fotografia 3 representa o funcionamento da bancada experimental no Laboratório de Estudos Avançados em Gestão da Produção e Operações. O período de coleta dos dados ocorreu de 21 de janeiro de 2020 a 10 de fevereiro de 2020, após realizar uma filtragem, foram obtidas 1430 imagens para serem utilizadas no desenvolvimento da pesquisa. Infelizmente, devido ao cenário pandêmico da Covid 19 que foi instaurado pouco tempo depois, não foi possível coletar mais imagens para acrescentar a pesquisa.

Fotografia 3 - Funcionamento da bancada experimental.



Fonte: A Autora (2021)

5.2 MÉTODO PROPOSTO PARA DETECÇÃO DESGASTE EM SUPERFÍCIE DE DENTE DE ENGRENAGENS

A seguir será apresentado os três métodos propostos para a detecção de desgaste em superfície de dentes de engrenagens, mas, inicialmente será detalhado como ocorreu a coleta e construção do banco de dados de imagens que foi posteriormente utilizado pelos métodos e

algoritmos de detecção de bordas, extração de recursos GLCM e CNN, além disso, uma análise comparativa de desempenho foi realizada entre os métodos.

5.2.1 Coleta de dados de imagens

De acordo com Turban (2008), um banco de dados é um conjunto de dados inter-relacionados e organizados para atender a uma necessidade específica, pode ser constituído por dados de multimídia, documentos e agentes inteligentes. A construção do banco de dados por meio das imagens coletadas pela bancada experimental é importante para o desenvolvimento dessa pesquisa. Desta forma, as imagens dos dentes da engrenagem do sistema de partida elétrica do motor a combustão foram coletadas durante o intervalo de funcionamento da bancada experimental por meio de câmeras endoscópicas de 7 megapixel. A captura das imagens foi programada no *software open source Yawcam* para acompanhar as pausas do experimento, pois, as imagens durante o funcionamento da bancada, apresentavam-se inadequadas para a aplicação dos algoritmos propostos. A Fotografia 4 exibe uma imagem coletada de dimensão 640 x 480 pixels.

Fotografia 4 - Engrenagem da bancada experimental.



Fonte: A Autora (2021)

5.2.2 Filtragem e pré-processamento

Durante o funcionamento do experimento as imagens são capturadas e, na sequência, as imagens com erros de captura, como por exemplo, borradas ou com erros são excluídas de forma manual. Em seguida, no banco de dados são armazenadas todas as imagens consideradas “aptas” para a detecção da superfície da face do topo dos dentes da engrenagem. Na próxima etapa, pré-processamento, as imagens são redimensionadas para obter a região de interesse (ROI) e altera-se a escala de cor de *Red, Green e Blue* (RGB) para um limiar de escala de cinza, assim as novas imagens são arquivadas em um novo banco de dados que será utilizado na etapa


de classificação do desgaste da engrenagem. O algoritmo utilizado na etapa de pré-processamento é apresentado no Quadro 5, de forma simplificada. Ao iniciar o algoritmo, as imagens são listadas, organizadas e salvas na variável “ **arquivos** ” e, por meio do laço “ **for** ” cada imagem é acessada, caso a condição do “ **if** ” seja aceita, ou seja, ao confirmar se a imagem realmente pertence a variável “ **arquivos** ”, uma nova imagem é gerada com as modificações de conversão de cores, de RGB para uma escala de cinza, além disso um recorte é realizado para obter apenas a região de interesse, ou seja, uma imagem que contenha a vista superior de apenas um dente da engrenagem, por fim, as imagens são salvas em um novo endereço. A Figura 9 ilustra a região de interesse e demonstra o resultado após a aplicação do algoritmo de pré-processamento.

Quadro 5 - Pseudocódigo do pré-processamento das imagens capturadas.

<p>Algoritmo 01 Pseudocódigo simplificado: Pré-processamento das imagens de dentes da engrenagem Início Passo 1: são importados alguns pacotes do python from PIL import Image Import os Passo 2: a variável diretorio ← recebe o acesso ao endereço do banco de dados das imagens Passo 3: os arquivos das imagens são listados arquivos = os.listdir(diretorio) Passo 4: os arquivos das imagens são ordenados arquivos.sort() Passo 5: um laço for é criado para acessar cada imagem for arquivo in arquivos: fullpath = os.path.join(diretorio, arquivo) Passo 6: uma Verificação do endereço do arquivo é realizada if os.path.isfile(fullpath): Passo 7: Conversão da imagem RGB em cinza = Image.open(fullpath).convert('RGB').convert('L') Passo 8: Recorta a imagem original no ROI (Região de interesse) por meio das coordenadas im = img.crop([esquerda,superior,direita,inferior]) Passo 9: Salva a nova imagem criada em um novo banco de dados FIM</p>

Fonte: A Autora (2021)

Figura 9 - Imagens resultantes da etapa de pré-processamento.



Fonte: A Autora (2021)

As imagens que foram pré-processadas e armazenadas em um novo banco de dados são acessadas e utilizadas como recurso de entrada para a aplicação das três abordagens: detecção de bordas, extração de recursos GLCM e CNN. A seguir será detalhado como ocorreu a aplicação de cada *framework* proposto para a detecção de desgaste em dentes de engrenagem.

5.2.3 Método e aplicação do algoritmo para detecção de bordas

A detecção de bordas foi o primeiro *framework* proposto selecionado para analisar os dentes da engrenagem intermediária do sistema de partida do motor a combustão. A engrenagem envolvida no estudo possui 61 dentes retos onde a região superficial da face do dente de interesse foi medida manualmente por meio do paquímetro, instrumento de medição, de precisão 0,02 mm, 5 vezes e foi calculado a média do resultado desta medição para calcular a área da região de interesse. Por meio das informações obtidas anteriormente, foi desenvolvido um algoritmo para realizar uma análise comparativa entre o resultado alcançado manualmente e a saída resultante do algoritmo de detecção de bordas.

Para calcular a área da superfície detectada é necessário converter os valores obtidos em pixel para uma unidade de medida de área conhecida, como por exemplo, mm². Para realizar essa conversão foi adotada a metodologia empregada por Riandini et al (2019), além disso utilizou-se como fator de conversão 300 PPI (Pixel por polegada). Com a identificação do dente da engrenagem com aspectos que se assemelhem ao estado de novo tem-se um elemento de referência para a classificação dos demais dentes, caso isso não seja possível, deve-se utilizar informações do fabricante sobre o dente da engrenagem. Desta forma, após arquivar a informação de área de todos os dentes das imagens de entrada, uma análise comparativa fornece o percentual de redução de área e, a partir desta informação é possível determinar em qual nível de desgaste o dente se enquadra. A Equação 11 apresenta como é calculado o percentual de redução de área dos dentes das engrenagens.

$$classificação_estado_desgaste = \frac{Area_{dente_novo} - Area_{dente_analizado}}{Area_{dente_novo}} \times 100\% \quad (11)$$

A Tabela 4 foi proposta para aplicação da detecção automática e apresenta uma recomendação das ações de manutenção que podem ser realizadas. Além disso, a Tabela 4 apresenta os níveis de classificação dos dentes da engrenagem por meio do resultado do nível de redução da área obtido na Equação 11. As ações recomendadas foram desenvolvidas para auxiliar os gestores de manutenção a identificar os estágios mais críticos do desgaste e, além disso, a automatização da classificação busca ajudar a construir estratégias para sinalizar a

necessidade de intervir no funcionamento do sistema, evitando paradas do sistema devido a falhas inesperadas.

Tabela 4 - Classificação do nível de desgaste do dente da engrenagem

Nível de desgaste em %	Classificação do dente	Ação
0 - 5	Condição Normal (CN)	Deixa operar
6 -10	Desgaste Leve (DL)	Deixar operar
11 -15	Desgaste Mediano (DM)	Deixar operar, porém menor eficiência
16 -20	Desgaste Severo (DS)	Sinalização visual sobre o agravamento do desgaste e recomendar uma parada programada.
21- 25	Desgaste Excessivo (DE)	Sinalização visual e sonoro para informar a necessidade de parada imediata para manutenção

Fonte: A Autora (2021)

Nota: Adaptado de Soleimani, Mahjoob & Shariatpanahi (2009)

O algoritmo inicia-se com a leitura e salvamento das imagens de entrada, em seguida, as medidas obtidas pelo paquímetro de comprimento e espessura do topo da face dos dentes são utilizadas para o cálculo de área manual e salvas na variável “**area_med_manual**”. Outras variáveis são criadas para calcular a área superficial por meio das informações extraídas das imagens. Por meio do laço “**for**” é realizada a leitura, salvamento, conversão da imagem para escala de cinza, binarização da imagem, aplicação do filtro gaussiano Blur e a procura e detecção de todos os contornos presentes na imagem analisada. Um novo laço “**for**” é criado para filtrar e identificar o contorno da região de interesse, posteriormente, o cálculo da área do contorno detectado é realizado por meio da função “**cv2.contourArea(c)**”, onde “**c**” representa o contorno detectado. Além disso, o comprimento e largura das imagens são obtidos por meio do atributo “**.shape**”, desta forma, como esses valores estão em pixel, uma conversão é realizada para obter o valor das áreas em mm². Algumas imagens são plotadas para que o usuário acompanhe as mudanças que ocorreram na imagem até o momento da detecção do contorno de interesse. Ao final, um novo laço “**for**” é criado para exibir os resultados obtidos após o cálculo da análise comparativa. O Quadro 6 descreve o passo a passo do algoritmo.

Quadro 6 - Pseudocódigo para detecção de bordas.


<p>Algoritmo 02 Pseudocódigo simplificado: Detecção de Bordas Início Passo 1: são importados alguns pacotes do python <code>import cv2</code> <code>from matplotlib import pyplot as plt</code> <code>import glob, os</code> Passo 2: a variável diretorio ← recebe o acesso ao endereço do banco de dados das imagens do ROI Passo 3: lista os arquivos do ROI <code>arquivos = os.listdir(diretorio)</code> Passo 4: ordena os arquivos do ROI <code>arquivos.sort()</code> Passo 5: inserção das medidas obtidas pelo paquímetro Passo 6: um laço for é criado para calcular a área da medição manual de cada dente <code>for i in range(n):</code> <code>area_manual = "Cálculo da área"</code> <code>area_med_manual.append(area_manual)</code> Passo 7: um laço for é criado para calcular a área do ROI <code>for img in glob.glob():</code> Passo 8: ocorre a leitura de cada imagem <code>image = cv2.imread(img)</code> Passo 9: altera-se a cor RGB para escala de cinza <code>cv2.cvtColor(image, cv2.COLOR_BGR2GRAY)</code> Passo 10: as imagens são binarizadas, ou seja, a cor é alterada para um limiar de (210, 255) <code>cv2.threshold()</code> Passo 11: o filtro <code>cv2.GaussianBlur()</code> é aplicador para destacar os contornos da imagem Passo 12: inicia-se a procura e detecção das bordas <code>cv2.findContours()</code> Passo 13: um laço for é criado para identificar os contornos fechados na imagem <code>for c in contornos:</code> <code>cv2.arcLength(c, True)</code> Passo 14: aplica-se o <code>if</code> para selecionar o contorno referente ao ROI do dente da engrenagem Passo 15: executa-se o cálculo da área por meio do contorno identificado Passo 16: ocorre a conversão da área em pixel para mm² Passo 17: as imagens do ROI com o contorno identificado são exibidas na tela Passo 18: um laço for é criado para calcular o erro percentual entre a medição manual e a obtida por meio do algoritmo <code>for i in range(n):</code> Passo 19: os resultados obtidos de área e erro percentual são impressos na tela FIM</p>

Fonte: A Autora (2021)

Em seguida, a classificação dos dentes da engrenagem foi definida a partir de uma análise comparativa entre os valores de área em pixel e, em milímetro, resultante da conversão, e da medição realizada com paquímetro analógico de resolução 0,02 mm. A Tabela 5 exibe os resultados dos cálculos de área que foram utilizados para determinar o grau de desgaste da superfície da imagem. O percentual de redução foi calculado considerando um dente em condição de novo para calcular a área do dente de referência dentre os demais analisados. Observa-se a identificação de diferentes níveis de desgastes como, condição normal para os

dentes 3,4,5 e 6, desgastes leves dentes 1 e 2, desgaste mediano dente 8 e desgaste severo dente 7. Com a avaliação da região superficial dos dentes, as ações recomendadas da Tabela 4 podem ser aplicadas para informar os mantenedores sobre a situação da engrenagem, contribuindo com a tomada de decisão da equipe responsável pela manutenção do equipamento. A Figura 10 exibe o resultado da execução do algoritmo de detecção de bordas do ROI do dente da engrenagem.

Figura 10 - Processo de detecção de bordas dos dentes da engrenagem.



Fonte: A Autora (2020)

Tabela 5 - Classificação do desgaste dos dentes da engrenagem

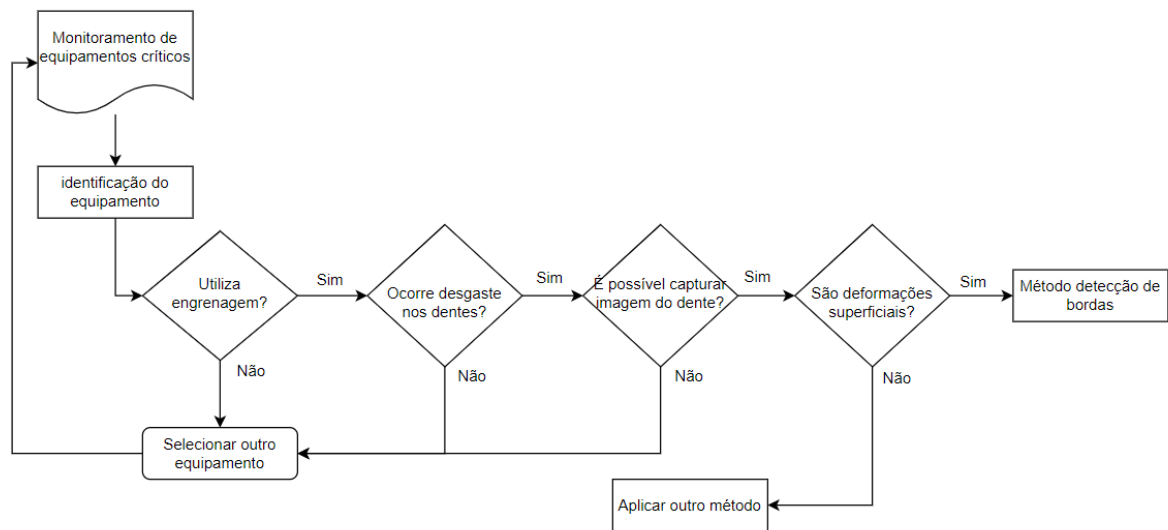
Nº de dente	Área em pixel	Área em Milímetro	Redução	Avaliação do estado dos dentes da engrenagem
1	1028,5	7,37274	7%	Desgaste Leve
2	1028,5	7,37274	7%	Desgaste Leve
3	1073,0	7,69174	3%	Condição Normal
4	1017,5	7,29389	8%	Condição Normal
5	1105,0	7,92113	-	Condição Normal
6	1055,5	7,56629	4%	Condição Normal
7	893,5	6,40500	19%	Desgaste Severo
8	981,5	7,03582	11%	Desgaste Mediano

Fonte: A Autora (2021)

Uma variação máxima de 15% entre os valores de área medidos manualmente e o resultado do algoritmo aplicado foi encontrada, esta diferença pode ser explicada devido a imprecisão ao realizar medições manuais em regiões irregulares por causa do desgaste. Apesar desta variação é possível identificar os diferentes estágios de desgaste da região superficial da face do topo dos dentes da engrenagem intermediária do sistema de partida elétrica de um motor a combustão de 150 cilindradas com a utilização de uma metodologia simples e de baixo custo.

Para aplicar a metodologia detecção de bordas, em outros sistemas, é necessária uma participação colaborativa da equipe de mantenedores com os responsáveis da implementação do protótipo, pois uma das etapas considerada principal para a correta detecção do desgaste é a obtenção de parâmetros que retratem o componente em boas condições de uso. Desta forma, componentes que contenham bordas de geometria fechada são considerados exemplos de aplicabilidade futura desta metodologia empregada na bancada experimental. O fluxograma 5 exemplifica como verificar se o método detecção de bordas é aplicável.

Fluxograma 5 - Utilização do método detecção de bordas.



Fonte: A Autora (2021)

Desta forma, o método detecção de bordas é uma ferramenta que pode auxiliar a gestão da manutenção a identificar o início do estágio dos desgastes, apresentados no Quadro 7, em dentes da engrenagem do equipamento em monitoramento. Acompanhar a evolução dos desgastes é uma informação importante para reduzir falhas inesperadas do sistema produtivo.

Quadro 7 - Exemplos de desgastes superficiais em dentes de engrenagem.

Autores	Desgastes superficiais Causas
(ONSY et al., 2012)	Fadiga por flexão e contato
(LI et al., 2019c)	<i>Pitting</i>
(FENG; XIE; CAO, 2009)	<i>Spalling</i>

Fonte: A Autora (2021)

Portanto, essa secção apresentou os resultados alcançados com a utilização do método de detecção de bordas para a detecção de desgastes em dentes de engrenagem. A análise comparativa entre as medições manuais e o resultado de saída do algoritmo demonstraram a detecção do desgaste da superfície dos dentes da engrenagem por meio da redução de área do topo da face do dente.

5.2.4 Método e aplicação do algoritmo para extração de recursos GLCM

O próximo *framework* proposto empregado foi a extração de recursos GLCM das imagens referente a região superficial dos dentes da engrenagem da bancada experimental. As propriedades selecionadas para o processo de extração foram seis: *energy*, *homogeneity*, *contrast*, *dissimilarity*, *entropy* e *correlation*. Esta abordagem é dividida em dois momentos, o primeiro está relacionado a extração de dados das imagens e formação de planilhas no formato “.csv”, ou seja, planilhas com valores separados por vírgula, já a segunda parte refere-se à

utilização de algoritmos de *machine learning* para verificar a acurácia da classificação do desgaste dos dentes da engrenagem.

O Quadro 8 é o algoritmo responsável pela construção das planilhas de dados. O algoritmo é inicializado com as importações dos pacotes das bibliotecas do *python* que serão necessárias, em seguida, as imagens são acessadas, salvas em uma variável e organizadas. O arquivo será formado por 7 colunas, 6 colunas com os dados das propriedades extraídas e 1 coluna chamada de “**classificação**” onde é inserido as informações do especialista por meio da atribuição de 0, se a imagem não contém desgaste, e 1, se contém. Um laço de repetição “**for**” é criado para acessar cada imagem e extrair as propriedades, durante o ciclo de repetição, dois parâmetros, distância em pixel “**d**” e ângulo de rotação “**θ**”, são utilizados como referência no processo de extração de recursos.

Quadro 8 - Pseudocódigo para extração de recursos GLCM.



<p>Algoritmo 03 Pseudocódigo simplificado: Extração de recursos GLCM Início Passo 1: são importados alguns pacotes do python from PIL import Image, ImageFilter import sys, glob, os import csv import numpy as np from skimage import io, color, img_as_ubyte from skimage.feature import greycomatrix, greycoprops from sklearn.metrics.cluster import entropy Passo 2: a variável diretorio ← recebe o acesso ao endereço do banco de dados das imagens do ROI Passo 3: os arquivos do ROI são listados arquivos = os.listdir(diretorio) Passo 4: é impresso o nome de cada propriedade que será extraída e a classificação atribuída a imagem, 0 para sem desgaste e 1 com desgaste Passo 5: um laço de repetição for é criado para acessar cada imagem for arquivo in arquivos: Passo 6: uma verificação do endereço é realizada com o if Passo 7: ocorre a abertura, leitura e conversão da imagem de RGB para escala de cinza, mesmo a imagem já estando em escala de cinza é necessário repetir este procedimento Passo 8: os parâmetros de distância e ângulo de rotação são inseridos Passo 9: a matriz glcm - extração dos recursos – é obtida pela função greycomatrix() Passo 10: os dados de cada propriedade são salvos nas respectivas variáveis energy, contrast, dissimilarity, correlation, entropia, classificacao Passo 11: os resultados de cada imagem são impressos e salvo em uma planilha no formato .csv FIM</p>
--

Fonte: A Autora (2021)

As variáveis utilizadas no processo de extração de recursos foram *energy, homogeneity, contrast, dissimilarity, entropy e correlation*. Cada recurso busca obter das imagens valores numéricos que representem uma característica identificada e, ao coletar as informações de todas as imagens, auxiliar o processo de treinamento e classificação dos algoritmos de *machine*

learning por meio do reconhecimento de padrões. Após imprimir todos os resultados das variáveis é realizado o salvamento em uma planilha no formato “*csv*” que será utilizada posteriormente nos algoritmos de *machine learning* SVM, KNN e PCA. O Quadro 9 exemplifica os resultados numéricos da extração de recurso de imagens sem e com desgaste.

Quadro 9 - Recursos extraídos das imagens dos dentes da engrenagem

Imagem	<i>energy</i>	<i>homogeneity</i>	<i>contrast</i>	<i>dissimilarity</i>	<i>entropy</i>	<i>correlation</i>
 Sem desgaste	0,023364	0,107564	1398,129431	21,580044	0,879262	5,434433
 Com desgaste	0,019492	0,10844	1290,355852	21,265105	0,886309	5,4159923

Fonte: A Autora (2021)

O conjunto de dados utilizado nesta pesquisa é limitado devido ao cenário pandêmico do COVID19, onde não foi possível acessar o experimento devido as restrições sanitárias, portanto foram inseridos dados repetitivos para verificar o quanto o desempenho do treinamento dos algoritmos de *machine learning* poderiam melhorar o resultado acurácia. A repetição dos dados é justificada ao considerar que imagens repetitivas serão capturadas e tecnicamente apresentaram os mesmos resultados após a extração dos recursos. Os dados foram organizados em 4 grupos onde o primeiro grupo é composto por 1430 imagens originais e os demais grupos resultam na duplicação do conjunto de dados anterior, deste modo, o segundo grupo contém 2860 imagens, o terceiro grupo contém 5720 imagens e o quarto grupo 11440 imagens. Essa estratégia foi adotada apenas para validar a hipótese na qual o aumento do conjunto de dados consequentemente aumentaria os resultados do desempenho do treinamento.

Além disso, buscou-se avaliar a influência da alteração dos parâmetros distância em pixel e ângulo de rotação. Para isto, foi realizado uma verificação dos dois parâmetros, distância entre pixels de 1 a 20 pixels e direção do ângulo em 0°, 45°, 90° e 135° influenciaria no processo de aprendizagem dos algoritmos de *machine learning*. Ao final deste processo foram obtidas 320 planilhas, sendo 80 de cada conjunto de dados. Posteriormente, durante o tratamento e elaboração dos gráficos foi observado que não houve alterações significativas do desempenho

da precisão, *recall* e *F1-score* devido a variação dos parâmetros distância de pixel e direção angular.

A seguir será detalhado os resultados alcançados ao inserir os dados das planilhas em algoritmos de aprendizado de máquina. Para esta pesquisa foram aplicados os algoritmos: *K-Nearest Neighbors* (KNN), *Support Vector Machine* (SVM) e *Principal Component Analysis* (PCA).

5.2.4.1 Algoritmo *K-Nearest Neighbors* (KNN)

O algoritmo é inicializado com a importação de algumas bibliotecas do *python*, em seguida, ocorre a leitura da planilha no formato “.csv” e salva-se esses dados em uma variável que representa o resultado da combinação da extração das características de cada imagem com a classificação individual do especialista. Os dados são pré-processados com o objetivo de realizar uma padronização em escala entre os valores resultantes de cada extração de recursos. A próxima etapa é criar o modelo de *machine learning* e dividir os dados nas variáveis de treinamento 60% e teste 40%. O classificador KNN é ativado e os resultados do treinamento são salvos para verificar o desempenho do algoritmo ao realizar uma predição. Ao final um relatório é impresso com os resultados de precisão e acurácia do modelo. O Quadro 10 apresenta os principais passos do algoritmo KNN.

Quadro 10 - Pseudocódigo do *K - Nearest Neighbors* (KNN).

<p>Algoritmo 04</p> <p>Pseudocódigo simplificado: KNN</p> <p>Início</p> <p>Passo 1: são importados alguns pacotes do python</p> <pre>import pandas as pd import seaborn as sns import matplotlib.pyplot as plt import numpy as np</pre> <p>Passo 2: é realizada a leitura do arquivo em formato “.csv” :</p> <pre>dados =pd.read_csv()</pre> <p>Passo 3: as informações contidas no arquivo .csv são salvas em uma nova variável</p> <p>Passo 4: um pré-processamento é realizado para padronizar os dados que serão treinados e classificados posteriormente, por isso serão considerados os dados de todas as colunas, exceto a última do arquivo .csv</p> <pre>from sklearn.preprocessing import StandardScaler StandardScaler() scaler.fit(dados.drop('classificação', axis = 1)) scaler.transform(dados.drop('classificação', axis = 1)) pd.DataFrame(dados_normalizados, columns= dados.columns[:-1])</pre> <p>Passo 5: é realizado a criação do modelo e seleção dos dados de treino e teste por meio da importação do modelo abaixo:</p> <pre>from sklearn.model_selection import train_test_split x_train, x_test, y_train, y_test = train_test_split()</pre> <p>Passo 6: é importado o classificador KNN, os resultados do treinamento são salvos e utilizados para a predição da classificação do vizinho mais próximo</p> <pre>from sklearn.neighbors import KNeighborsClassifier knn = KNeighborsClassifier(n_neighbors = n) knn.fit(x_train, y_train) pred = knn.predict(x_test)</pre> <p>Passo 7: um relatório é impresso para indicar o nível de precisão obtido com o treinamento do modelo criado</p> <pre>from sklearn.metrics import classification_report, confusion_matrix print(confusion_matrix(y_test,pred)) print(classification_report(y_test, pred))</pre> <p>Passo 8: ao final tem-se um refinamento para identificar o número de vizinhos que pode ser utilizado para aumentar a precisão e, conseqüentemente, reduzir o erro do classificador, desta forma é criado um laço de repetição para encontra o valor de “n” ideal</p> <pre>for n in range (1,5): knn = KNeighborsClassifier(n_neighbors= n) knn.fit(x_train, y_train) pred = knn.predict(x_test) error_rate.append(np.mean(pred!= y_test)) print(error_rate)</pre> <p>Passo 9: com o valor otimizado de “n” pode-se repetir os passos 6 e 7 para obter resultados melhores de precisão do classificador</p> <p>FIM</p>
--

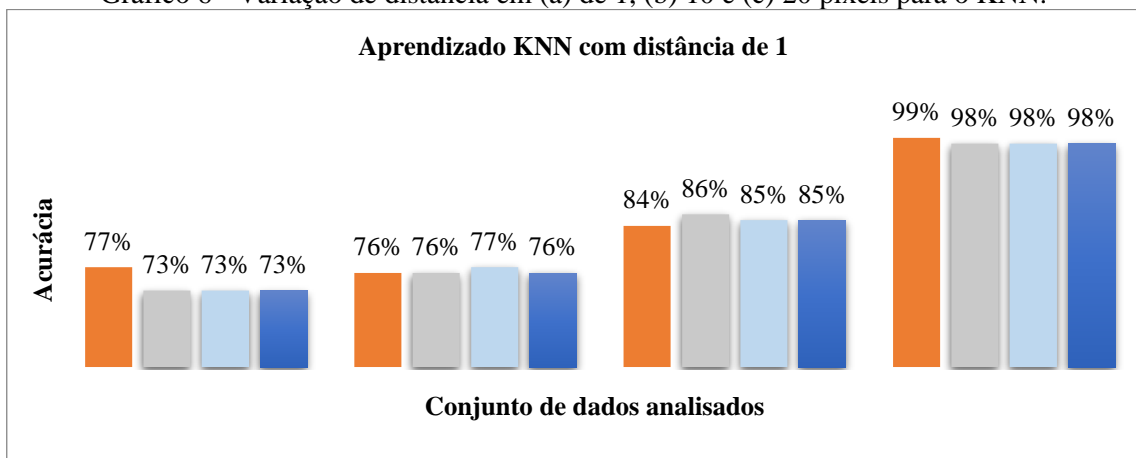
Fonte: A Autora (2021)

Os relatórios gerados foram arquivados no formato “.txt”, totalizando 320 documentos, e foram utilizados para realizar uma análise comparativa entre o conjunto de dados utilizados e os parâmetros, distância em pixel e ângulo de rotação. Devido a grande quantidade de resultados


para avaliar a variação dos parâmetros, foi selecionado os relatórios da distância de 1, 10 e 20 pixels para a análise gráfica.

O Gráfico 6 é subdividido em três partes onde em (a) tem-se os resultados da acurácia ao considerar a distância em pixel 1 e variar o ângulo de rotação em 0°, 45°, 90° e 135, em (b) têm-se os resultados da acurácia para a distância de 10 pixels e em (c) de 20 pixels. Além disso, cada bloco de quatro colunas representa o conjunto de 1430, 2860, 5720 e 11440 imagens utilizadas. Os resultados demonstram que a variação da distância em pixel e variação do ângulo de rotação pouco influenciaram na melhoria do aprendizado do classificador KNN, além disso, com as 1430 imagens, a acurácia manteve-se acima de 70%, portanto, as propriedades *energy*, *homogeneity*, *contrast*, *dissimilarity*, *entropy* e *correlation* apresentaram dificuldades em extrair características importantes para a detecção de desgastes nos dentes da engrenagem, por isso, com o aumento do conjunto de imagens, foi alcançado melhores resultados de acurácia, com média de 84,75% para o conjunto de 5860 imagens e 98,33% para o conjunto de 11440 imagens.


Gráfico 6 - Variação de distância em (a) de 1, (b) 10 e (c) 20 pixels para o KNN.



(a)



(b)



(c)

Fonte: A Autora (2021)

Portanto, nesta secção foi apresentado o desempenho do algoritmo KNN para a detecção de desgastes em dentes de engrenagem. A limitação do conjunto de dados de imagens dificultou o processo de aprendizagem do algoritmo KNN, no entanto, ao considerar conjunto de imagens maiores, os resultados de acurácia também aumentaram.

5.2.4.2 Algoritmo Support Vector Machine (SVM)

A execução do algoritmo SVM inicializa-se com a importação das bibliotecas necessárias do python, em seguida, ocorre a leitura e salvamento dos dados em uma variável. Cada imagem foi classificada anteriormente, por meio do especialista, desta forma, para o dente sem desgaste é atribuído “0” e, com desgaste, é atribuído “1”. Na planilha de dados a coluna “classificação” contém essas informações que serão utilizadas para o treinamento e teste do modelo.

No próximo passo ocorre a importação do modelo SVM e a divisão dos dados entre as variáveis de treinamento 60% e teste 40%. Com o classificador SVM definido, é inicializado o treinamento do modelo e, posteriormente, a predição com dados de teste é realizada. Ao final é impresso um relatório com as informações de acurácia obtidas pelo modelo criado. Um ajuste nos parâmetros do classificador SVM é realizado para melhorar o desempenho final dos resultados. O quadro 11 apresenta o pseudocódigo simplificado do algoritmo do classificador SVM.

Quadro 11 - Pseudocódigo do *Support Vector Machine* (SVM).

<p>Algoritmo 05 Pseudocódigo simplificado: SVM Início Passo 1: são importados alguns pacotes do python import pandas as pd import numpy as np import matplotlib.pyplot as plt import seaborn as sns Passo 2: é realizada a leitura do arquivo em formato “.csv” : dados = pd.read_csv() Passo 3: as informações contidas no arquivo “.csv” são salvas em uma nova variável Passo 4: a coluna chamada “classificação” é utilizada para identificar as classes, 0 para uma condição sem desgaste e 1 com desgaste, atribuída a cada imagem Passo 5: é realizado a criação do modelo e seleção dos dados de treino e teste por meio da importação do modelo abaixo: from sklearn.model_selection import train_test_split x_train, x_test, y_train, y_test = train_test_split() Passo 6: é importado o classificador máquina de vetores de suporte SVM, os resultados do treino são salvos e utilizados para a predição from sklearn.svm import SVC model = SVC() model.fit(x_train, y_train) pred = model.predict(x_test) Passo 7: ao final um relatório é impresso para indicar o nível de precisão obtido com o treinamento do modelo SVM criado from sklearn.metrics import classification_report, confusion_matrix print(classification_report(y_test, pred)) print(confusion_matrix(y_test,pred)) Passo 8: ao final tem-se um refinamento para ajustar os parâmetros e obter uma melhor precisão nos resultados da predição do classificador SVM Passo 9: com os novos parâmetros pode-se repetir os passos 6 e 7 para obter resultados melhores de precisão do classificador FIM</p>
--

Fonte: A Autora (2021)

Assim como no classificador KNN, os resultados do algoritmo SVM foram salvos em arquivos no formato “.txt” e utilizados para realizar uma análise comparativa entre o conjunto de dados utilizados e os parâmetros, distância em pixel e ângulo de rotação. Para a construção do Gráfico 7 foi considerado a distância de pixel de 1, 10 e 20, respectivamente, como é apresentado nas partes (a), (b) e (c).


Os resultados demonstraram uma taxa de acurácia inferior ao algoritmo KNN, com os dados disponíveis de 1430 imagens, portanto, devido ao baixo desempenho do modelo SVM, também foi utilizado o incremento de imagens até 5720. Por meio do Gráfico 7 pode-se observar que o desempenho do classificador SVM é melhorado ao aumentar o tamanho do conjunto de dados analisados, mas a variação de distância em pixel e ângulo de rotação não influenciaram no desempenho do algoritmo SVM.

A baixa acurácia inicial, identificada nos algoritmos KNN e SVM, pode estar relacionada também com a pequena variação numérica dos recursos *energy*, *homogeneity*, *contrast*, *dissimilarity*, *entropy* e *correlation* ao extrair informações de algumas imagens com indícios de desgastes iniciais e sem desgastes, por isso a importância do profissional especialista para classificar os desgastes das imagens do banco de dados durante a construção do modelo de *machine learning*.


Outro fator que pode ter influenciado é a pequena variação de posição do dente da engrenagem durante a captura das imagens, ou seja, a folga característica do engrenamento do sistema da bancada experimental pode causar uma pequena alteração na posição final do dente da engrenagem ao interromper o movimento do conjunto. Por isso, com uma quantidade maior de imagens, e um acompanhamento progressivo do desgaste dos dentes da engrenagem é possível reduzir os efeitos desses fatores durante a construção dos modelos de *machine learning*.

Ao observar o Gráfico 7 conclui-se que o processo de aprendizagem da identificação de desgastes em regiões superficiais de dentes de engrenagem é melhorado ao utilizar um maior número de imagens. Com o primeiro conjunto de imagens, a acurácia alcançada foi acima de 60%, o segundo e terceiro conjunto de dados obteve acurácia acima de 80% e 90%. Desta forma, a abordagem SVM é uma alternativa para identificar desgaste superficiais em dentes de engrenagem a partir de características textuais extraídos com o método GLCM.


Gráfico 7 - Variação de distância em (a) de 1, (b) 10 e (c) 20 pixels para o SVM.



(a)



(b)



(c)

Fonte: A Autora (2021)

Portanto, os resultados do classificador SVM foram, em média, superiores ao classificador KNN a partir do segundo conjunto de dados. Deste modo, a dificuldade de detecção de desgastes em dentes da engrenagem, por meio da abordagem KNN e SVM, com a quantidade de imagens disponíveis, indica que eram necessárias uma quantidade maior de imagens ao longo do tempo que retratassem o desgaste gradual dos dentes, infelizmente, não foi possível coletar um maior número de imagens do experimento devido as restrições sanitárias da pandemia do COVID19. Porém, apesar das limitações, as abordagens KNN e SVM podem contribuir para a detecção de desgaste em superfície de dentes de engrenagem.

5.2.4.3 Algoritmo Principal Component Analysis (PCA)

A próxima técnica de *machine learning* aplicada foi a *Principal Component Analysis* (PCA), neste caso, foram utilizados os 1430 dados originais para verificar o comportamento dos dados ao combinar os recursos *energy*, *homogeneity*, *contrast*, *dissimilarity*, *entropy* e *correlation*, transformando-os em apenas dois componentes principais. O algoritmo aplicado é

inicializado com a importação de bibliotecas do *python*, em seguida, a planilha com os dados de extração de recursos é acessada, os dados são lidos e salvos em uma variável e, posteriormente, são pré-processados, ou seja, transformados em uma escala padronizada. O modelo do algoritmo PCA é importado e os dados são divididos em dois componentes principais. Ao final os gráficos são plotados para permitir a visualização da distribuição dos dados entre as duas classes criadas. O Quadro 12 apresenta, de forma simplificada, o algoritmo *Principal Component Analysis* (PCA).

Quadro 12 - Pseudocódigo do *Principal Component Analysis* (PCA).


<p>Algoritmo 06 Pseudocódigo simplificado: PCA Início Passo 1: são importados alguns pacotes do python <code>import pandas as pd</code> <code>import numpy as np</code> <code>import matplotlib.pyplot as plt</code> <code>import seaborn as sns</code> Passo 2: é realizada a leitura do arquivo em formato “.csv”: <code>dados =pd.read_csv()</code> Passo 3: as informações contidas no arquivo “.csv” são salvas em uma nova variável Passo 4: um pré-processamento é realizado para padronizar os dados que serão reduzidos, posteriormente, em duas classes <code>from sklearn.preprocessing import StandardScaler</code> <code>StandardScaler()</code> <code>scaler.fit()</code> <code>scaler.transform()</code> Passo 5: é realizada a decomposição dos dados padronizados em dois componentes principais <code>from sklearn.decomposition import PCA</code> <code>PCA(n_components= 2)</code> <code>pca.fit()</code> <code>pca.transform()</code> Passo 6: o resultado da decomposição é apresentado em um gráfico onde duas cores são utilizadas para identificar os componentes de cada classe FIM</p>

Fonte: A Autora (2021)


O Gráfico 8-(a), 8-(b), 8-(c) e 8-(d) apresenta o comportamento das duas classes, ou componentes principais, ao realizar a variação do ângulo de rotação e mantendo a distância em pixel em 1. Os pontos em amarelo representam imagens de dentes da engrenagem consideradas com algum nível de desgaste e os pontos em azul sem desgastes. No Gráfico 8-(a), 8-(b) e 8-(d) é possível observar um comportamento semelhante dos dados com a variação do ângulo de rotação e no Gráfico 8-(c) ocorre uma concentração e dispersão diferente na região esquerda do gráfico. A proximidade e distanciamento dos dois componentes principais nos gráficos indica a dificuldade do modelo PCA ao buscar padronizar a separação dos dados em dois componentes principais, este fato pode ser explicado devido a pequena variação numérica dos

componentes principais dos dados da região, ou seja, a maioria dos dentes analisados apresenta um estado de conservação semelhante, considerados em bom estado de conservação ou com desgastes iniciais pontuais, porém outro pequeno grupo de imagens apresenta desgastes maiores, portanto, apresentam-se agrupados na região superior direita do Gráfico 8 em amarelo.


Gráfico 8 - Distância de 1 pixel e ângulo de rotação 0° (a), 45° (b), 90° (c) e 135° (d).




(a)



(b)



(c)




(d)

Fonte: A Autora (2021)

Devido a dificuldade de interpretação do Gráfico 8, uma análise simplificada composta por uma pequena amostra de 58 imagens do conjunto de dados original, sendo 29 imagens com desgaste e 29 imagens sem desgaste, como apresentado na Figura 11, foi realizada para verificar o comportamento do modelo PCA diante de uma análise pontual e simétrica de imagens com e sem desgaste.


Figura 11 - Exemplos de imagens com e sem desgaste.



Fonte: A Autora (2021)

Como resultado obteve-se, o Gráfico 9, os dois componentes principais agrupados em regiões diferentes, mas com um distanciamento maior entre as classes. A concentração ou afastamento dos dados dentro do mesmo grupo pode representar pequenas variações da condição superficial dos dentes, mas que não comprometem a classificação atribuída ao desgaste na região. Portanto, quanto maior o distanciamento entre os dois componentes principais, maior será a probabilidade de existir um dente com desgaste no equipamento monitorado. Desta forma, o método PCA pode ser utilizado como uma ferramenta de controle visual para o acompanhamento do avanço do desgaste em dentes de engrenagem ao longo do tempo.

Gráfico 9 - Resultado do PCA para distância de 1 pixel e direção angular de 0°.



Fonte: A Autora (2021)

Portanto, nesta secção foi apresentado a utilização do algoritmo *Principal Component Analysis* (PCA) para permitir a visualização da distribuição dos dados entre duas classes que representem o estado de conservação dos dentes da engrenagem em monitoramento. O aumento progressivo do distanciamento entre os componentes principais pode ser um indicativo do agravamento do nível de desgaste observado na engrenagem em monitoramento. O Quadro 13 recomenda deixar operar o equipamento ao identificar uma pequena variação entre os componentes principais e iniciar ações de correção de engenharia a partir do avanço do distanciamento.

Quadro 13 - Ações de recomendação resultantes do método PCA

Método	Distância entre os componentes principais uma comparação no tempo	Recomendações Gerenciais
PCA	Pequena	Deixar operar
	Alteração de Pequena para Média	Deixar operar e Sinalizar a formação do desgaste, iniciando ações de correção de engenharia.
	Crescente ao longo do tempo	Parar o equipamento e aplicar as soluções de engenharia.

Fonte: A Autora (2021)

Uma análise comparativa entre as distância dos componente principais no tempo apresenta informações úteis para o entendimento da formação e desenvolvimento de desgastes em dentes de engrenagem. Além disso, qualquer interferência externa no dente que altere a imagem padrão como resíduos de impurezas e corpos estranhos poderá ser detectado e sinalizado a necessidade de intervenção da equipe de manutenção.

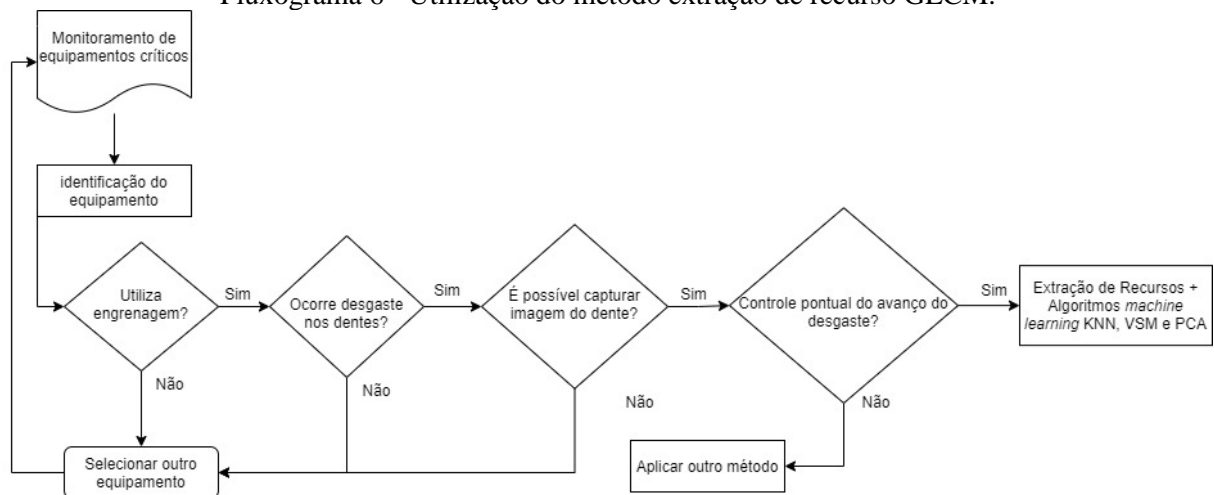
5.2.4.4 Discursões gerenciais para a utilização do método extração de recurso GLCM

A decisão de utilizar o método extração de recurso GLCM e algoritmos de *machine learning* deve ser baseada no objetivo, a longo prazo, da gestão da manutenção, pois o processo de construção e validação do modelo requer um período maior de tempo para registrar imagens suficientes que permitam o reconhecimento dos padrões que caracterizam a formação de desgaste na região superficial de dentes da engrenagem em monitoramento.

Além disso, a presença do profissional especialista em reconhecer desgastes característicos da engrenagem, em monitoramento, é um fator importante para selecionar a região pontual de captura de imagem dos dentes, realizar a classificação dos dados, validar as etapas de desenvolvimento do algoritmo e os resultados iniciais apresentados.

Portanto, recomenda-se a utilização da metodologia extração de recursos e algoritmos de *machine learning* para monitorar a formação de desgastes como corrosão, deformações localizadas e outros desgastes superficiais pontuais detectáveis por meio dos recursos *energy*, *homogeneity*, *contrast*, *dissimilarity*, *entropy* e *correlation* que cada imagem apresenta. O Fluxograma 6 define as etapas para revificar a aplicabilidade do método após selecionar o equipamento, caso o objetivo não seja o acompanhamento e controle do avanço pontual do desgaste, outros métodos devem ser utilizados.

Fluxograma 6 - Utilização do método extração de recurso GLCM.



Fonte: A Autora (2021)

5.2.5 Método e algoritmo *Convolutional Neural Network* (CNN)

A abordagem não supervisionada foi o último algoritmo empregado para verificar a identificação de desgastes em superfícies de dentes de engrenagem. Dentre o conjunto de imagens disponíveis foram selecionadas 60 imagens positivas, ou seja, que contém desgaste e outras 60 negativas, que não contém desgastes. A *Convolutional Neural Network* (CNN) foi construída por meio do pseudocódigo do Quadro 14. Desta forma, o algoritmo é inicializado com a importação de bibliotecas do *python* que serão necessárias para a construção da rede neural, em seguida, o modelo CNN é ativado e inicia-se a criação das camadas, ao final, as camadas são totalmente conectadas e as imagens são pré-processadas de acordo com os parâmetros previamente definidos para as etapas de treinamento e teste da CNN criada. Os parâmetros do treino da CNN podem variar de acordo com os resultados obtidos na saída da predição, desta forma, o tempo de treinamento, a quantidade de imagens no banco de dados e os parâmetros no pré-processamento podem ser melhorados ao longo do tempo.

Quadro 14 - Pseudocódigo do *Convolutional Neural Network* (CNN).

<p>Algoritmo 07 Pseudocódigo simplificado: CNN Início Passo 1: são importados alguns pacotes do python import tensorflow as tf import keras as k from keras.models import Sequential from keras.layers import Conv2D from keras.layers import MaxPooling2D from keras.layers import Flatten from keras.layers import Dense import cv2 from matplotlib import pyplot as plt Passo 2: é realizado a ativação do modelo sequencial de camadas: Sequential() Passo 3: é criado a primeira camada Convulacional classifier.add() classifier.add(MaxPooling2D()) Passo 4: é adicionado uma segunda camada Convulacional classifier.add() classifier.add(MaxPooling2D()) Passo 5: é aplicado o Flattening classifier.add(Flatten()) Passo 6: as camadas são totalmente conectadas classifier.add(Dense()) Passo 7: é realizado a compilação da Convolutional Neural Network classifier.compile() Passo 8: é criado os objetos de treino e teste de acordo com os parâmetros do pré-processamento do keras from keras.preprocessing.image import ImageDataGenerator Passo 9: é executado o treinamento da Convolutional Neural Network: classifier.fit_generator() Passo 10: é realizado a predição por meio da utilização de algumas imagens como teste Passo 11: os resultados da predição são salvos e utilizados posteriormente para verificar a acurácia da CNN ao identificar os verdadeiros positivos, falsos negativos, verdadeiros negativos e os falsos positivos Passo 12: um relatório é exibido com os resultados do treinamento e do teste FIM</p>
--

Fonte: A Autora (2021)

Após a criação da CNN é necessário realizar o treinamento, ou seja, “ensinar” ao algoritmo de *machine learning* o que representa um dente bom ou ruim. Foi necessário organizar três pastas onde, na pasta “*dataset_teste*” e “*dataset_validation*”, foram inseridas imagens aleatórias de dentes bons ou ruins de engrenagem, já na pasta “*dataset_treino*” foram anexadas duas novas pastas contendo apenas imagens de dentes bons e outra contendo apenas imagens de dentes ruins. O treinamento é uma etapa implícita pertencente ao Figura 6, localizada antes da predição de saída. No estudo experimental desta pesquisa tem-se a programação do treinamento com execução de 5 ciclos de repetição, com 800 passos para o algoritmo aprender com suas tentativas de “acertos” e “erros”, ocorrendo validações parciais a cada 200 passos concluídos.

Para validar o desempenho do treinamento é realizado uma nova predição com 12 imagens aleatórias, onde TP, TN, FP, FN são verdadeiro positivo, verdadeiro negativo, falso positivo e falso negativo, respectivamente e representam quatro novas variáveis utilizadas para verificar o desempenho da CNN nessa amostragem pequena. As equações de 12 a 16 são utilizadas para validar o desempenho do teste da CNN (HOANG; TRAN, 2019).

$$CAR = \frac{(TP + TN)}{(TP + TN + FP + FN)} \times 100\% \quad (12)$$

$$PPV = \frac{TP}{(TP + FP)} \quad (13)$$

$$NPV = \frac{TN}{(TN + FN)} \quad (14)$$

$$Recall = \frac{TP}{(TP + FN)} \quad (15)$$

$$F1_Score = \frac{2TP}{(2TP + FP + FN)} \quad (16)$$

5.2.5.1 Classificação por meio da Convolutional Neural Network (CNN)

Durante o treinamento da CNN, cada finalização do ciclo de 800 passos apresentava resultados parciais da taxa de acurácia, ou seja, o desempenho da rede treinada para a detecção das imagens com desgaste e a probabilidade de errar a correta classificação das classes definidas, a taxa de *loss*, calculada internamente no algoritmo da CNN. O tempo de processamento foi insignificante, por isso a Tabela 6 exibe apenas os resultados do treinamento e observa-se que inicialmente a taxa de *loss* supera a taxa de acurácia, mas, à medida que a CNN “aprende” a reconhecer os padrões de imagens com e sem desgaste, a acurácia aumenta e, conseqüentemente, a taxa de *loss* reduz para valores muito próximos de zero, resultando em uma acurácia final de aproximadamente 99,999981% e taxa de *loss* de $1,8822 \times 10^{-5}$.

Tabela 6 - Resultados do treinamento da CNN

Ciclo	Acurácia		Loss	
	Início	Término	Início	Término
1	56,25%	96,64%	68,87%	8,27%
2	99,9991%	99,83%	$9,0159 \times 10^{-4}$	0,55%
3	99,99991%	99,94%	$9,1621 \times 10^{-5}$	0,17%
4	99,999993%	99,999966%	$7,013 \times 10^{-6}$	$3,3702 \times 10^{-5}$
5	99,999994%	99,999981%	$6,3904 \times 10^{-6}$	$1,8822 \times 10^{-5}$

Fonte: A Autora (2021)

Com a finalização do período de treinamento da CNN, um teste composto por 12 imagens aleatórias de dentes classificados como “bons” ou “ruins” foi realizado para validar a

CNN treinada. Cada imagem apresentada ao algoritmo comparava a resposta da CNN com a verdadeira classificação da imagem exibida, em seguida, uma das variáveis TP, TN, FP e FN recebe um incremento. Ao finalizar o teste com todas as 12 imagens, os cálculos de F1_Score, CAR e Recall podem ser realizados.


A Figura 12 exibe o relatório resultante da etapa de avaliação do desempenho do modelo CNN treinado. Os resultados foram: acurácia (CAR) de 91,6667% , representando um bom desempenho do modelo para a identificação de imagens verdadeiro positivo e verdadeiro negativo, F1_Score de 90,9090%, indicando que a qualidade geral do modelo também é satisfatória, apesar da pequena quantidade de dados analisados, Recall de 83,33%, indicando que o modelo acerta, na maioria dos casos, a classificação da classe da imagem. Além disso, as taxas de precisão de verdadeiros positivos (PPV) e precisão de verdadeiros negativos (NPV) foram 100% e 85,71%, respectivamente, indicando que o modelo CNN conseguiu reconhecer desgastes em imagens de dentes da engrenagem analisada. Exemplos de imagens com e sem desgastes, utilizadas no teste do modelo CNN, são apresentadas na Figura 13.

Figura 12 - Relatório da etapa de teste da CNN.

```
TP: 5
TN: 6
FP: 0
FN: 1
CAR: 91.66666666666666
Resultado do PPV: 1.0
Resultado do NPV: 0.8571428571428571
Recall: 0.8333333333333334
F1_SCORE: 0.9090909090909091
```

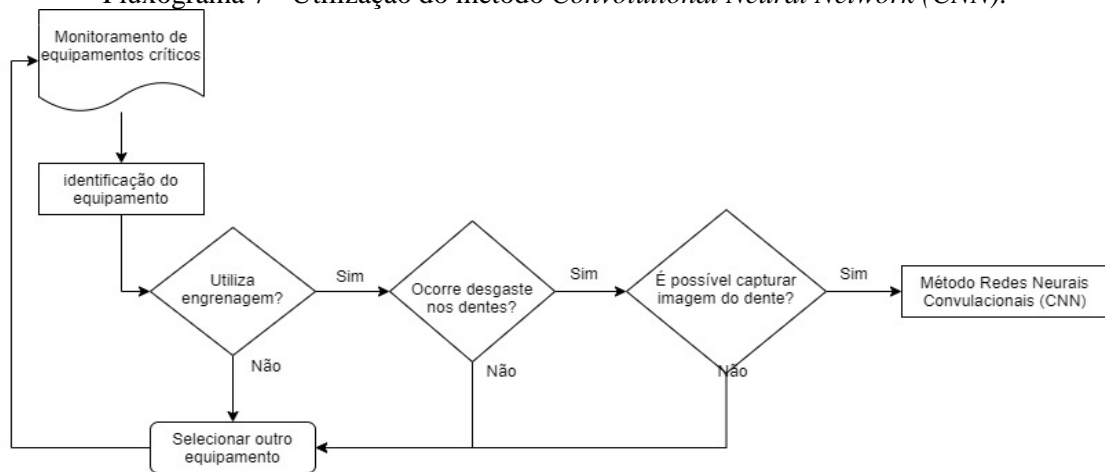
Fonte: A Autora (2021)

Figura 13 - Imagens teste para verificar o desempenho da CNN treinada.



Fonte: A Autora (2021)

A detecção de dentes com desgaste por meio da CNN é um processo de melhoria contínua, além disso, o tempo de desenvolvimento e treinamento é considerado de médio a longo prazo, devido ao processo de acompanhamento e registro do desgaste da engrenagem ao longo do tempo. De acordo com os resultados da CNN, a gestão da manutenção analisa as características do desgaste detectado e aplica as soluções de engenharia necessárias. Portanto, a partir da possibilidade de registrar imagens dos dentes da engrenagem, o método CNN pode ser aplicado, como é ilustrado no Fluxograma 7.

Fluxograma 7 - Utilização do método *Convolutional Neural Network* (CNN).

Fonte: A Autora (2021)

5.3 RELEVÂNCIA GERENCIAL DA VISÃO COMPUTACIONAL PARA A GESTÃO DA MANUTENÇÃO

O reconhecimento do desgaste das engrenagens por meio de imagens é uma oportunidade para intervir no sistema produtivo durante o estágio inicial do problema. O desgaste em dentes de engrenagens pode inserir folgas no sistema de transmissão e prejudicar tanto o sincronismo das máquinas quando transmissão de força para o sistema e linhas de produção. Desta forma, produtos defeituosos e acidentes de trabalho podem acontecer, por isso a importância em inserir novos recursos tecnológicos para acompanhar o desgaste das engrenagens e acionar a equipe de manutenção quando necessário.

Com o monitoramento do desgaste das engrenagens a gestão da manutenção contribui para reduzir os riscos de falhas inesperadas no conjunto de transmissão, reforça as ações de segurança do trabalho para evitar acidentes e impacta também na redução da fabricação de produtos defeituosos resultantes das folgas do sistema produtivo. Mas, é importante destacar que o desempenho final do monitoramento é resultante da integração dos dados coletados no equipamento e das informações inseridas no programa que representam o conhecimento do especialista ou dos profissionais mais experientes da unidade produtiva.

A decisão autônoma de parar um equipamento proporciona a gestão da manutenção mais uma ferramenta ativada para intervir no sistema de forma inteligente. O entendimento do estágio de desgaste da superfície do dente da engrenagem é apenas um exemplo das inúmeras aplicabilidades da visão computacional para a tomada de decisão autônoma. Para desenvolver um sistema autônomo é necessário utilizar recursos de *machine learning* para “ensinar” aos algoritmos inteligentes o que as imagens capturadas significam. Por isso, a importância de

definir bem o objeto de estudo e ao longo do desenvolvimento da ferramenta incluir a equipe de manutenção durante a construção, treinamento dos algoritmos e período de instalação da ferramenta.

Um exemplo dos benefícios de uma operação autônoma são as inspeções visuais das pás de aerogeradores por meio da abordagem da visão computacional, com processamento de imagens digitais, é realizado o acompanhamento programado do estado de conservação da região superficial das pás dos aerogeradores de forma remota, desta forma, busca-se evitar ou reduzir expor os mantenedores aos riscos de uma inspeção visual local perigosa (WANG; ZHANG; LUO, 2019). Outro benefício dessa abordagem é permitir a identificação prévia do problema que deve ser solucionado, ou seja, a equipe de manutenção tem a oportunidade de planejar como e qual reparo deverá ser realizado durante a intervenção no sistema. Então, a elaboração de um planejamento estruturado e direcionado pode contribuir com uma melhor utilização do tempo de parada e redução de acidentes (GU et al., 2020).

Com o sistema autônomo treinado e integrado aos comandos do equipamento em monitoramento, as ações podem ser encaminhadas para a equipe de manutenção. Situações consideradas normais podem utilizar sinalização visual para indicar o estado do componente e, com o agravamento da identificação do desgaste das engrenagens, alertas sonoros e sinalização intermitente podem ser utilizados. Em situações consideradas críticas para o sistema, o sistema autônomo interrompe o funcionamento do componente automaticamente e uma sinalização visual é utilizada para indicar o motivo da parada do equipamento. Apenas após a avaliação da equipe de manutenção o equipamento é autorizado a funcionar novamente.

O trabalho desenvolvido nessa pesquisa buscou por meio da utilização da bancada experimental, do motor a combustão e seu conjunto intermediário de engrenamento, exemplificar o potencial do uso de recursos de visão computacional para o estudo da identificação de desgaste em regiões superficiais por meio de imagens digitais. Desta forma, destaca-se que a área de gestão da manutenção aos poucos acrescentará a tomada de decisão autônoma nos seus processos de controle e monitoramento dos ativos da organização. Com essa nova abordagem os diagnósticos e prognósticos dos problemas dos sistemas produtivos podem ser aperfeiçoados, ou seja, o planejamento e a coordenação das atividades podem ser direcionados para mitigar os problemas mais críticos da organização com a alocação e utilização dos recursos necessários.

Portanto, as discussões abordadas ao longo desse trabalho evidenciam a tendência do surgimento de novos recursos tecnológicos para apoiar a gestão da manutenção em diversas áreas. A transferência da experiência e vivência dos especialistas continua sendo um desafio ao

construir um sistema de decisão autônoma, mas ao longo do tempo, os pesquisadores tendem a minimizar as dificuldades e desenvolver ferramentas cada vez mais precisas e eficazes para mitigar os problemas dos sistemas de produção.

5.4 SÍNTESE CONCLUSIVA

O resultado experimental desta pesquisa demonstra o potencial da aplicação da Visão Computacional como ferramenta para automatizar o setor industrial no processo de identificação do estado de conservação de componentes críticos como engrenagens. Diferentes metodologias foram aplicadas para exemplificar diferentes contextos e necessidades que são específicas para cada indústria. O tempo de desenvolvimento do método e o impacto do desgaste para o desempenho do equipamento são fatores que devem ser analisados ao definir a implementação dos métodos na indústria, como é apresentado no Quadro 15.

Quadro 15 - Análise de viabilidade dos métodos para a indústria.

Método	Período de desenvolvimento	Impacto do desgaste para o desempenho do equipamento
Detecção de Bordas	Curto - Médio	Pequeno - Médio - Grande
Extração de recursos GLCM + algoritmos <i>machine learning</i> (KNN, SVM e PCA)	Longo	Médio - Grande
<i>Convolutional Neural Network</i> (CNN)	Médio - Longo	Médio - Grande

Fonte: A Autora (2021)

A identificação da formação de desgastes na engrenagem direciona as ações da gestão da manutenção para evitar o agravamento do nível do desgaste, como por exemplo, verificar o alinhamento do conjunto engrenado e retirar as sobrecargas do equipamento. Desgastes maiores, em curto período, podem indicar a necessidade de reavaliação do projeto dimensional para selecionar outro material com maior resistência mecânica, além disso, a aplicação de tratamentos térmicos superficiais que aumentem a dureza da superfície dos dentes da engrenagem pode ser utilizada.

Portanto, os métodos detecção de bordas, extração de recursos GLCM com aplicação de algoritmos *machine learning* (KNN, SVM e PCA) e CNN, apresentados nesta pesquisa, podem contribuir com a identificação e acompanhamento dos desgastes em dentes de engrenagem, resultando em informações úteis sobre a condição da engrenagem, auxiliando assim a gestão de manutenção.

6 CONCLUSÕES

A inspeção visual é uma das abordagens utilizadas para a identificação de desgastes em superfícies de metal, mas a subjetividade e incerteza humana podem dificultar a decisão final do inspetor diante da avaliação do equipamento, além do risco, em alguns casos, de acidente ao realizar a inspeção. Partindo desse contexto, esta pesquisa propôs três diferentes *frameworks* para a detecção de desgaste em dentes de engrenagem. Por meio da construção de uma bancada experimental composta por motor a combustão, sistema de partida elétrica, sistema eletrônico de controle de acionamento e câmeras endoscópicas foram capturadas imagens de dentes de engrenagem. As imagens foram filtradas, pré-processadas e armazenadas em um banco de dados por meio do uso de ferramentas de visão computacional.

Este trabalho apresentou uma revisão da literatura que responde aos questionamentos elencados, reunindo informações sobre os principais trabalhos da área de visão computacional relacionados com a área de gestão da manutenção e onde destaca-se os autores Nhat-Duc Hoang, Quoc-Lam Nguyen, Weidong Song. Os países China, Coreia do Sul e Vietnã foram os principais colaboradores no desenvolvimento de pesquisas na área de visão computacional. Com esse embasamento teórico foram aplicados os três *frameworks* propostos para detecção de desgastes em dentes de engrenagem: detecção de bordas, extração de recursos estatísticos GLCM com utilização de algoritmos de *machine learning* (SVM, KNN, PCA) e *Convolutional Neural Network* (CNN). Foi utilizado a linguagem de programação em *Python* como ferramenta computacional para obter os resultados de validação de cada *framework* proposto.

Por meio do *framework* detecção de bordas o nível de desgaste dos dentes da engrenagem foi calculado ao analisar a região superficial de dentes de engrenagem e uma análise comparativa entre os dados resultantes do algoritmo e medições manuais realizadas com o instrumento paquímetro demonstraram uma acurácia, do método, de aproximadamente 85% para a determinação da área da região com desgaste.

Com o *framework* extração de recursos estatísticos GLCM os resultados obtidos do classificador KNN foram uma acurácia acima de 70%, para o primeiro e segundo conjunto de imagens, superior a 80% e 90% para o terceiro e quarto conjunto de imagens. Com o classificador SVM os resultados foram acurácia acima de 60%, 80% e 90%, para o primeiro, segundo e terceiro conjunto de dados, respectivamente. Os resultados demonstraram que não houve a influência da variação de ângulo de rotação e distância em pixel para a melhoria do desempenho dos classificadores KNN e SVM, apenas o incremento de imagens melhorou o desempenho dos algoritmos. Com o algoritmo PCA foram analisados o comportamento da

combinação dos recursos *energy, homogeneity, contrast, dissimilarity, entropy e correlation* para a formação de duas classes de componentes principais que representam conjunto de imagens com e sem desgaste nos dentes da engrenagem. Os resultados gráficos do PCA indicam que o distanciamento gradativo dos componentes principais caracteriza a formação e avanço do desgaste em superfícies de dentes de engrenagem, reforçando a necessidade de intervir no equipamento monitorado ao observar o agravamento da situação do componente engrenagem.

O *framework Convolutional Neural Network* (CNN) por meio da análise de 120 imagens com e sem desgaste em dentes de engrenagem foi validado com acurácia de 99,999981% e taxa de *loss* de $1,8822 \times 10^{-5}$ para o período de treinamento da CNN. Durante os testes de desempenho, com 12 imagens, os resultados foram um CAR de 91,6666%, F1_Score de 90,9090% e Recall de 83,3334%, também validando o *framework* proposto como alternativa para classificar imagens superficiais de dentes de engrenagem baseado nas classes pré-definidas e treinadas.

Outro fator que impactou esta pesquisa foi a pandemia do COVID19 que devido aos protocolos de segurança causou a interrupção da coleta de dados da bancada experimental, por isso os dados utilizados foram limitados. No entanto, apesar da limitação dos dados os resultados alcançados foram satisfatórios para validar os *frameworks* propostos e conseguiram demonstrar o potencial da visão computacional para a gestão da manutenção.

6.1 CONTRIBUIÇÃO DA PESQUISA

Esta pesquisa contribui para sociedade ao apresentar as principais pesquisas que estudam uma nova abordagem, visão computacional e gestão da manutenção, como uma ferramenta de apoio para realizar a detecção de desgastes em superfícies metálicas em diversas áreas de estudo por meio de imagens digitais.

O *framework* proposto demonstra três diferentes abordagens para detectar e acompanhar desgastes superficiais em dentes de engrenagem, resultando em uma contribuição inovadora para apoiar a gestão da manutenção, na tomada de decisão, ao monitorar os equipamentos críticos dos sistemas produtivos das organizações industriais.

Além disso, esta pesquisa contribui para que estudos futuros explorem o tema visão computacional e gestão da manutenção ao propor soluções para as demandas dos gestores de manutenção das indústrias do agreste pernambucano.

6.2 TRABALHOS FUTUROS

Aplicar os métodos desta pesquisa em ambientes industriais, buscando auxiliar a gestão da manutenção das empresas quanto a detecção de desgastes superficiais em dentes de engrenagem dos equipamentos críticos da produção.

Desenvolver uma interface gráfica, facilitando a utilização dos métodos, interpretação dos resultados e apresentação das ações de recomendação para a gestão da manutenção.

Incentivar a utilização da visão computacional para o monitoramento de outros componentes rotativos como rolamentos, mancais, polias, e outros elementos de transmissão considerados críticos para a gestão da manutenção.

REFERÊNCIAS

- ABBAS, H. M. T. et al. Automated sorting and grading of agricultural products based on image processing. **2019 8th International Conference on Information and Communication Technologies, ICICT 2019**, p. 78–81, 2019.
- ABDEL-QADER, I.; ABUDAYYEH, O.; KELLY, M. E. Analysis of edge-detection techniques for crack identification in bridges. **Journal of Computing in Civil Engineering**, v. 17, n. 4, p. 255–263, 2003.
- ANDARABI, S. et al. The study of various motionally-sounding classification using KNN, Bayesian, Neural network methods. p. 6–10, 2020.
- ASLAM, Y.; SANTHI, N. A Review of Deep Learning Approaches for Image Analysis. **Proceedings of the 2nd International Conference on Smart Systems and Inventive Technology, ICSSIT 2019**, n. Icssit, p. 709–714, 2019.
- ATHA, D. J.; JAHANSHAH, M. R. Evaluation of deep learning approaches based on convolutional neural networks for corrosion detection. **Structural Health Monitoring**, v. 17, n. 5, p. 1110–1128, 2018.
- AZHAR, K. et al. Computer vision based detection and localization of potholes in asphalt pavement images. **Canadian Conference on Electrical and Computer Engineering**, v. 2016-October, p. 1–5, 2016.
- BAJPAI, D.; HE, L. Evaluating KNN Performance on WESAD Dataset. **Proceedings - 2020 12th International Conference on Computational Intelligence and Communication Networks, CICN 2020**, p. 60–62, 2020.
- BALAMURUGAN, E. et al. Use Case of Artificial Intelligence in *Machine learning Manufacturing 4.0*. **Proceedings of 2019 International Conference on Computational Intelligence and Knowledge Economy, ICCIKE 2019**, p. 656–659, 2019.
- BENGIO, Y.; LECUN, Y. **Scaling learning algorithms towards AI**. 2007
- BHARATE, A. A.; SHIRDHONKAR, M. S. Classification of Grape Leaves using KNN and SVM Classifiers. **Proceedings of the 4th International Conference on Computing Methodologies and Communication, ICCMC 2020**, n. Iccmc, p. 745–749, 2020.
- BUI, K. H. et al. Vibration-based plastic-gear crack detection system using a *Convolutional Neural Network* - Robust evaluation and performance improvement by re-learning. **Journal of Advanced Mechanical Design, Systems and Manufacturing**, v. 14, n. 3, p. 1–12, 2020.
- CAO, W.; LIU, Q.; HE, Z. Review of Pavement Defect Detection Methods. **IEEE Access**, v. 8, p. 14531–14544, 2020.
- CHEN, K. et al. Transfer learning enhanced AR spatial registration for facility maintenance

- management. **Automation in Construction**, v. 113, n. February, p. 103135, 2020.
- CHUN, P. JO; IZUMI, S.; YAMANE, T. Automatic detection method of cracks from concrete surface imagery using two-step light gradient boosting machine. **Computer-Aided Civil and Infrastructure Engineering**, p. 1–12, 2020.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, v. 20, n. 3, p. 273–297, 1995.
- CRINGASU, E. C.; DRAGOMIRESCU, A.; SAFTA, C. A. Image Processing Approach for Estimating the Degree of Surface Degradation by Corrosion. **Proceedings of 8th International Conference on Energy and Environment: Energy Saved Today is Asset for Future, CIEM 2017**, p. 275–278, 2017.
- D.O, A. et al. Comparative Analysis of Textural Features Derived from GLCM for Ultrasound Liver Image Classification. **International Journal of Computer Trends and Technology**, v. 11, n. 6, p. 239–244, 2014.
- DENG, W.; BAO, J.; YE, B. Defect Image Recognition and Classification for Eddy Current Testing of Titanium Plate Based on Convolutional Neural Network. **Complexity**, v. 2020, 2020.
- DONG, S. et al. Automatic defect identification technology of digital image of pipeline weld. **Natural Gas Industry B**, v. 6, n. 4, p. 399–403, 2019.
- DUGAN, R. 22 nd International Conference on Electricity Distribution Paper 0664 22 nd International Conference on Electricity Distribution. **C I R E D 22nd International Conference on Electricity Distribution**, n. 0664, p. 10–13, 2013.
- ELIZABETH RANI, G.; MURUGESWARI, R.; RAJINI, N. Edge Detection in Scanning Electron Microscope (SEM) Images using Various Algorithms. **Proceedings of the International Conference on Intelligent Computing and Control Systems, ICICCS 2020**, n. Iciccs, p. 401–405, 2020.
- FENG, W.; XIE, X.; CAO, Y. Study on fault diagnosis of gear with spall using ferrography and vibration analysis. **2009 International Conference on Measuring Technology and Mechatronics Automation, ICMTMA 2009**, v. 1, p. 723–727, 2009.
- FIX, E.; HODGES, J. L.; MEDICINE., U. S. OF A. **Discriminatory analysis : nonparametric discrimination, consistency properties**. Randolph Field, Tex.: USAF School of Aviation Medicine, 1951.
- FRUSTACI, F. et al. An embedded machine vision system for an in-line quality check of assembly processes. **Procedia Manufacturing**, v. 42, n. 2019, p. 211–218, 2020.
- GANATRA, N.; PATEL, A. A Comprehensive Study of Deep Learning Architectures,

- Applications and Tools. **International Journal of Computer Sciences and Engineering**, v. 6, n. 12, p. 701–705, 2018.
- GAO, M. et al. Detection and Segmentation of Cement Concrete Pavement Pothole Based on Image Processing Technology. **Mathematical Problems in Engineering**, v. 2020, 2020.
- GARCÍA, S. G.; GARCÍA, M. G. Industry 4.0 implications in production and maintenance management: An overview. **Procedia Manufacturing**, v. 41, p. 415–422, 2019.
- GOEL, R.; JAIN, A. The implementation of image enhancement techniques on color n gray scale IMAGES. **PDGC 2018 - 2018 5th International Conference on Parallel, Distributed and Grid Computing**, p. 204–209, 2018.
- GU, W. et al. Autonomous Wind Turbine Inspection using a Quadrotor. **2020 International Conference on Unmanned Aircraft Systems, ICUAS 2020**, n. iii, p. 709–715, 2020.
- GUAN, S.; LEI, M.; LU, H. A Steel Surface Defect Recognition Algorithm Based on Improved Deep Learning Network Model Using Feature Visualization and Quality Evaluation. **IEEE Access**, v. 8, p. 49885–49895, 2020.
- GUERRA-MONTENEGRO, J. et al. Computational Intelligence in the hospitality industry: A systematic literature review and a prospect of challenges. **Applied Soft Computing**, v. 102, p. 107082, 2021.
- HEGDE, J.; ROKSETH, B. Applications of *machine learning* methods for engineering risk assessment – A review. **Safety Science**, v. 122, n. September 2019, p. 104492, 2020.
- HOANG, N. D. Detection of Surface Crack in Building Structures Using Image Processing Technique with an Improved Otsu Method for Image Thresholding. **Advances in Civil Engineering**, v. 2018, 2018a.
- HOANG, N. D. Image Processing-Based Recognition of Wall Defects Using *Machine learning* Approaches and Steerable Filters. **Computational Intelligence and Neuroscience**, v. 2018, 2018b.
- HOANG, N. D. et al. Automatic Detection of Concrete Spalling Using Piecewise Linear Stochastic Gradient Descent Logistic Regression and Image Texture Analysis. **Complexity**, v. 2019, 2019.
- HOANG, N. D. Image processing based automatic recognition of asphalt pavement patch using a metaheuristic optimized *machine learning* approach. **Advanced Engineering Informatics**, v. 40, n. April, p. 110–120, 2019.
- HOANG, N. D.; NGUYEN, Q. L. Metaheuristic optimized edge detection for recognition of concrete wall cracks: A comparative study on the performances of Roberts, Prewitt, Canny, and Sobel algorithms. **Advances in Civil Engineering**, v. 2018, 2018a.

- HOANG, N. D.; NGUYEN, Q. L. Automatic Recognition of Asphalt Pavement Cracks Based on Image Processing and *Machine learning* Approaches: A Comparative Study on Classifier Performance. **Mathematical Problems in Engineering**, v. 2018, 2018b.
- HOANG, N. D.; TRAN, V. D. Image Processing-Based Detection of Pipe Corrosion Using Texture Analysis and Metaheuristic-Optimized *Machine learning* Approach. **Computational Intelligence and Neuroscience**, v. 2019, 2019.
- HTAY, T. T.; MAUNG, S. S. Early Stage Breast Cancer Detection System using GLCM feature extraction and K-Nearest Neighbor (k-NN) on Mammography image. **ISCIT 2018 - 18th International Symposium on Communication and Information Technology**, n. Iscit, p. 345–348, 2018.
- HU, H. et al. Classification of defects in steel strip surface based on multiclass *Support Vector Machine*. **Multimedia Tools and Applications**, v. 69, n. 1, p. 199–216, 2014.
- HU, H. et al. Method for Detecting Micron Cracks on a Magnetic Rotor Surface Based on a *Support Vector Machine*. **IEEE Access**, v. 6, p. 53141–53152, 2018.
- HUANG, Y. et al. Vision based embedded tiny spur gear inspection and measurement system. **2016 IEEE International Conference on Mechatronics and Automation, IEEE ICMA 2016**, p. 1679–1684, 2016.
- HUANGPENG, Q. et al. Automatic visual defect detection using texture prior and low-rank representation. **IEEE Access**, v. 6, p. 37965–37976, 2018.
- IBRAHIM, A. et al. Characterization of cracking in pavement distress using image processing techniques and k-nearest neighbour. **Indonesian Journal of Electrical Engineering and Computer Science**, v. 14, n. 2, p. 810–818, 2019.
- JANG, J. et al. Intelligent image-based railway inspection system using deep learning-based object detection and weber contrast-based image comparison. **Sensors (Switzerland)**, v. 19, n. 21, 2019.
- KANAWADAY, A.; SANE, A. *Machine learning* for predictive maintenance of industrial machines using IoT sensor data. **Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS**, v. 2017-Novem, n. Figure 2, p. 87–90, 2018.
- KARAN, S.; DHOLAY, S. Machine vision based approach to analyze street surface anomalies. **Proceedings - International Conference on Global Trends in Signal Processing, Information Computing and Communication, ICGTSPICC 2016**, p. 241–246, 2017.
- KHAN, A. I.; AL-HABSI, S. *Machine learning* in Computer Vision. **Procedia Computer Science**, v. 167, n. 2019, p. 1444–1451, 2020.

- KIM, B.; CHO, S. Automated vision-based detection of cracks on concrete surfaces using a deep learning technique. **Sensors (Switzerland)**, v. 18, n. 10, 2018.
- KOLOKAS, N. et al. Forecasting faults of industrial equipment using *machine learning* classifiers. **2018 IEEE (SMC) International Conference on Innovations in Intelligent Systems and Applications, INISTA 2018**, 2018.
- KRISHNA JOTHI, A.; MOHAN, P. A comparison between KNN and SVM for breast cancer diagnosis using GLCM shape and LBP Features. **Proceedings of the 3rd International Conference on Smart Systems and Inventive Technology, ICSSIT 2020**, n. Icssit, p. 1058–1062, 2020.
- LAU, S. L. H. et al. Automated Pavement Crack Segmentation Using U-Net-Based Convolutional Neural Network. **IEEE Access**, v. 8, p. 114892–114899, 2020.
- LEE, S. Y. et al. Steel surface defect diagnostics using deep *Convolutional Neural Network* and class activation map. **Applied Sciences (Switzerland)**, v. 9, n. 24, 2019.
- LEI, X. et al. Automated Pavement Distress Detection and Deterioration Analysis Using Street View Map. **IEEE Access**, v. 8, p. 76163–76172, 2020a.
- LEI, Y. et al. Applications of *machine learning* to machine fault diagnosis: A review and roadmap. **Mechanical Systems and Signal Processing**, v. 138, 2020b.
- LI, C.; JI, D. Research on Surface Defects Detection of Stainless Steel Spoon Based on Machine Vision. **Proceedings 2018 Chinese Automation Congress, CAC 2018**, p. 1096–1101, 2019.
- LI, D. et al. Crack detection and recognition model of parts based on machine vision. **Journal of Engineering Science and Technology Review**, v. 12, n. 5, p. 148–156, 2019a.
- LI, L. et al. Automatic pavement crack recognition based on BP neural network. **Promet - Traffic - Traffico**, v. 26, n. 1, p. 11–22, 2014.
- LI, R. et al. Arrhythmia Multiple Categories Recognition based on PCA-KNN Clustering Model. **2019 8th International Symposium on Next Generation Electronics, ISNE 2019**, p. 2–4, 2019b.
- LI, S.; ZHAO, X. Image-Based Concrete Crack Detection Using *Convolutional Neural Network* and Exhaustive Search Technique. **Advances in Civil Engineering**, v. 2019, n. M1, 2019.
- LI, S.; ZHAO, X. Automatic Crack Detection and Measurement of Concrete Structure Using Convolutional Encoder-Decoder Network. **IEEE Access**, v. 8, p. 134602–134618, 2020.
- LI, X. et al. Early Gear Pitting Fault Diagnosis Based on Bi-directional LSTM. **2019 Prognostics and System Health Management Conference, PHM-Qingdao 2019**, 2019c.
- LI, X.; GUO, Y.; LI, Y. Particle Swarm Optimization-Based SVM for Classification of Cable Surface Defects of the Cable-Stayed Bridges. **IEEE Access**, v. 8, p. 44485–44492, 2020.

- LI, Z. et al. Metal surface defect detection based on MATLAB. **Proceedings of 2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference, IAEAC 2018**, n. Iaeac, p. 2365–2371, 2018.
- LIANG, S.; JIANCHUN, X.; XUN, Z. An extraction and classification algorithm for concrete cracks based on machine vision. **IEEE Access**, v. 6, p. 45051–45061, 2018.
- LIN, C. S. et al. Crack detection on a retaining wall with an innovative, ensemble learning method in a dynamic imaging system. **Sensors (Switzerland)**, v. 19, n. 21, 2019.
- LIU, W.; WEI, J.; MENG, Q. Comparisons on KNN, SVM, BP and the CNN for Handwritten Digit Recognition. **Proceedings of 2020 IEEE International Conference on Advances in Electrical Engineering and Computer Applications, AEECA 2020**, p. 587–590, 2020.
- LOKMANWAR, S. D.; BHALCHANDRA, A. S. Contour detection based on Gaussian filter. **Proceedings of the 3rd International Conference on Electronics and Communication and Aerospace Technology, ICECA 2019**, p. 722–725, 2019.
- LU, Y. et al. Standards for smart manufacturing: A review. **IEEE International Conference on Automation Science and Engineering**, v. 2019- August, p. 73–78, 2019.
- LYASHEVA, S.; TREGUBOV, V.; SHLEYMOVICH, M. Detection and recognition of pavement cracks based on computer vision technology. **2019 International Conference on Industrial Engineering, Applications and Manufacturing, ICIEAM 2019**, p. 1–5, 2019.
- MA, D. et al. Intelligent detection model based on a fully *Convolutional Neural Network* for pavement cracks. **CMES - Computer Modeling in Engineering and Sciences**, v. 123, n. 3, p. 1267–1291, 2020.
- MANJURUL ISLAM, M. M.; KIM, J. M. Vision-based autonomous crack detection of concrete structures using a fully convolutional encoder–decoder network. **Sensors (Switzerland)**, v. 19, n. 19, p. 1–12, 2019.
- MORADIFAR, M.; SHAHBAHRAMI, A. Performance Improvement of Gaussian Filter using SIMD Technology. **Iranian Conference on Machine Vision and Image Processing, MVIP**, v. 2020- Febru, 2020.
- MOTAMEDI, M.; FARAMARZI, F.; DURAN, O. New concept for corrosion inspection of urban pipeline networks by digital image processing. **IECON Proceedings (Industrial Electronics Conference)**, p. 1551–1556, 2012.
- NHAT-DUC, H.; NGUYEN, Q. L.; TRAN, V. D. Automatic recognition of asphalt pavement cracks using metaheuristic optimized edge detection algorithms and convolution neural network. **Automation in Construction**, v. 94, n. January, p. 203–213, 2018.
- ONSY, A. et al. Application of image registration methods in monitoring the progression of

surface fatigue failures in geared transmission systems. **IEEE Aerospace Conference Proceedings**, 2012.

OUYANG, W. et al. Fabric Defect Detection Using Activation Layer Embedded Convolutional Neural Network. **IEEE Access**, v. 7, n. 2, p. 70130–70140, 2019.

PATEL, A. R. et al. **Artificial Intelligence: Prospect in Mechanical Engineering Field—A Review**. [s.l.] Springer Singapore, 2021. v. 52

PEARSON, K. LIII. On lines and planes of closest fit to systems of points in space. **The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science**, v. 2, n. 11, p. 559–572, 1 nov. 1901.

PRAMESTYA, R. H. et al. Road defect classification using Gray Level Co-Occurrence Matrix (GLCM) and Radial Basis Function (RBF). **Proceedings of 2018 10th International Conference on Information Technology and Electrical Engineering: Smart Technology for Better Society, ICITEE 2018**, p. 285–289, 2018.

PRASANNA, P. et al. Automated Crack Detection on Concrete Bridges. **IEEE Transactions on Automation Science and Engineering**, v. 13, n. 2, p. 591–599, 2016.

PRATHUSHA, P.; JYOTHI, S.; MAMATHA, D. M. Enhanced Image Edge Detection Methods for Crab Species Identification. **ICSNS 2018 - Proceedings of IEEE International Conference on Soft-Computing and Network Security**, 2018.

PULIDO, C.; SOLAQUE, L.; VELASCO, N. Weed recognition by SVM texture feature classification in outdoor vegetable crop images. **Ingenieria e Investigacion**, v. 37, n. 1, p. 68–74, 2017.

QU, Z. et al. Concrete surface crack detection with the improved pre-extraction and the second percolation processing methods. **PLoS ONE**, v. 13, n. 7, p. 1–14, 2018.

QUINTANA, M.; TORRES, J.; MENÉNDEZ, J. M. A simplified computer vision system for road surface inspection and maintenance. **IEEE Transactions on Intelligent Transportation Systems**, v. 17, n. 3, p. 608–619, 2016.

REHMAN, A. et al. Performance Analysis of PCA, Sparse PCA, Kernel PCA and Incremental PCA Algorithms for Heart Failure Prediction. **2nd International Conference on Electrical, Communication and Computer Engineering, ICECCE 2020**, n. June, p. 1–5, 2020.

REN, Y. et al. Image-based concrete crack detection in tunnels using deep fully convolutional networks. **Construction and Building Materials**, v. 234, p. 117367, 2020.

RIANDINI, R.; DEWANTORO, S. K.; ISTONI, R. Measurement of stain area in metal surface with particle analysis. **Proceedings of ICAITI 2019 - 2nd International Conference on Applied Information Technology and Innovation: Exploring the Future Technology of**

- Applied Information Technology and Innovation**, p. 116–121, 2019.
- RYU, E. et al. Automated Detection of Surface Cracks and Numerical Correlation with Thermal-Structural Behaviors of Fire Damaged Concrete Beams. **International Journal of Concrete Structures and Materials**, v. 14, n. 1, 2020.
- SANTOS, A. A. et al. Automatic system for visual detection of dirt buildup on conveyor belts using convolutional neural networks. **Sensors (Switzerland)**, v. 20, n. 20, p. 1–16, 2020.
- SARI, Y.; PRAKOSO, P. B.; BASKARA, A. R. Application of neural network method for road crack detection. **Telkomnika (Telecommunication Computing Electronics and Control)**, v. 18, n. 4, p. 1962–1967, 2020.
- SHABIR, M. A. et al. Tyre defect detection based on glcm and gabor filter. **Proceedings - 22nd International Multitopic Conference, INMIC 2019**, 2019.
- SHAH, H. N. M. et al. Automated quality inspection on tile border detection using vision system. **International Journal of Recent Technology and Engineering**, v. 8, n. 3, p. 3737–3745, 2019.
- SHAJAHAN, N. M. et al. Automated Inspection of Monopole Tower Using Drones and Computer Vision. **Proceedings - 2019 2nd International Conference on Intelligent Autonomous Systems, ICoIAS 2019**, p. 187–192, 2019.
- SHATNAWI, N. Automatic pavement cracks detection using image processing techniques and neural network. **International Journal of Advanced Computer Science and Applications**, v. 9, n. 9, p. 399–402, 2018.
- SHEN, B. et al. Wireless multimedia sensor network based subway tunnel crack detection method. **International Journal of Distributed Sensor Networks**, v. 2015, 2015.
- SHEYKHMOUSA, M. et al. *Support Vector Machine* Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 6308–6325, 2020.
- SHIM, S. et al. Multiscale and Adversarial Learning-Based Semi-Supervised Semantic Segmentation Approach for Crack Detection in Concrete Structures. **IEEE Access**, v. 8, p. 170939–170950, 2020.
- SILVA, W.; CAPRETZ, M. Assets Predictive Maintenance Using Convolutional Neural Networks. **Proceedings - 20th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing, SNPD 2019**, p. 59–66, 2019.
- SINGH, S.; SRIVASTAVA, D.; AGARWAL, S. GLCM and its application in pattern

- recognition. **5th International Symposium on Computational and Business Intelligence, ISCBI 2017**, p. 20–25, 2017.
- SOLEIMANI, A.; MAHJOOB, M. J.; SHARIATPANAHI, M. Fault classification in gears using *Support Vector Machines* (SVMs) and signal processing. **ICSCCW 2009 - 5th International Conference on Soft Computing, Computing with Words and Perceptions in System Analysis, Decision and Control**, v. 1, n. C, p. 1–4, 2009.
- SOLIGON, A.; NEO, J.; DUAN, X. Structures Congress 2017. **Fire Safety and Tall Timber Building - What's Next**, n. 2013, p. 556–569, 2017.
- SONG, W. et al. Automatic Pavement Crack Detection and Classification Using Multiscale Feature Attention Network. **IEEE Access**, v. 7, p. 171001–171012, 2019.
- SONG, W. et al. Automated pavement crack damage detection using deep multiscale convolutional features. **Journal of Advanced Transportation**, v. 2020, n. ii, 2020.
- SONG, Y.; WANG, H.; ZHANG, J. A vision-based broken strand detection method for a power-line maintenance robot. **IEEE Transactions on Power Delivery**, v. 29, n. 5, p. 2154–2161, 2014.
- SOOMRO, T. A. et al. Deep Learning Models for Retinal Blood Vessels Segmentation: A Review. **IEEE Access**, v. 7, p. 71696–71717, 2019.
- SUN, H. C.; HUANG, Y. C.; HUANG, C. M. Fault diagnosis of power transformers using computational intelligence: A review. **Energy Procedia**, v. 14, p. 1226–1231, 2012.
- ŚWIŁŁO, S. J.; PERZYK, M. Surface Casting Defects Inspection Using Vision System and Neural Network Techniques. **Archives of Foundry Engineering**, v. 13, n. 4, p. 103–106, 2013.
- TANG, X. et al. An Improved Sobel Face Gray Image Edge Detection Algorithm. **Chinese Control Conference, CCC**, v. 2020- July, p. 6639–6643, 2020.
- THANIKACHALAM, V.; KAVITHA, M. G.; BHARATHI, V. Artificial neural network and gray level co-occurrence matrix based automated corrosion detection. **International Journal of Engineering and Advanced Technology**, v. 8, n. 6, p. 4499–4502, 2019.
- THEISSLER, A. et al. Predictive maintenance enabled by *machine learning*: Use cases and challenges in the automotive industry. **Reliability Engineering & System Safety**, v. 215, p. 107864, 2021.
- TIAN, F. et al. Concrete crack identification and image mosaic based on image processing. **Applied Sciences (Switzerland)**, v. 9, n. 22, p. 1–19, 2019.
- TONG, X. et al. A new image-based method for concrete bridge bottom crack detection. **Proceedings of 2011 International Conference on Image Analysis and Signal Processing, IASP 2011**, n. 1, p. 568–571, 2011.

- TRIVEDI, S. et al. Predictive Maintenance of Air Conditioning Systems Using Supervised *Machine learning*. **2019 20th International Conference on Intelligent System Application to Power Systems, ISAP 2019**, 2019.
- WANG, B. et al. Crack damage detection method via multiple visual features and efficient multi-task learning model. **Sensors (Switzerland)**, v. 18, n. 6, p. 1–18, 2018.
- WANG, D. et al. Machine vision-based monitoring methodology for the fatigue cracks in U-Rib-to-deck weld seams. **IEEE Access**, v. 8, p. 94204–94219, 2020a.
- WANG, H.; MENG, F. Research on power equipment recognition method based on image processing. **Eurasip Journal on Image and Video Processing**, v. 2019, n. 1, 2019.
- WANG, J. S.; REN, X. D. GLCM based extraction of flame image texture features and KPCA-GLVQ recognition method for rotary kiln combustion working conditions. **International Journal of Automation and Computing**, v. 11, n. 1, p. 72–77, 2014.
- WANG, L.; ZHANG, Z.; LUO, X. A Two-Stage Data-Driven Approach for Image-Based Wind Turbine Blade. v. 24, n. 3, p. 1271–1281, 2019.
- WANG, Q. P.; ZHANG, W. L. A novel algorithm of image denoising and edge preserving based on discrete grey model. **Proceedings of IEEE International Conference on Grey Systems and Intelligent Services, GSIS**, p. 147–150, 2013.
- WANG, Y. et al. A smart surface inspection system using faster R-CNN in cloud-edge computing environment. **Advanced Engineering Informatics**, v. 43, n. April 2019, p. 101037, 2020b.
- WANG, Z. et al. Advanced big-data/machine-learning techniques for optimization and performance enhancement of the heat pipe technology – A review and prospective study. **Applied Energy**, v. 294, n. December 2020, p. 116969, 2021.
- WYATT, J. C.; TAYLOR, P. Decision Support Systems and Clinical Innovation. **Getting Research Findings into Practice: Second Edition**, p. 123–137, 2008.
- XIA, D. H. et al. Review-material degradation assessed by digital image processing: Fundamentals, progresses, and challenges. **Journal of Materials Science and Technology**, v. 53, p. 146–162, 2020.
- XU, L. et al. A Weakly Supervised Surface Defect Detection Based on Convolutional Neural Network. **IEEE Access**, v. 8, p. 42285–42296, 2020.
- YANG, J. et al. Infrared Thermal Imaging-Based Crack Detection Using Deep Learning. **IEEE Access**, v. 7, n. Mm, p. 182060–182077, 2019.
- YANG, L.; LIU, Y.; PENG, J. An Automatic Detection and Identification Method of Welded Joints Based on Deep Neural Network. **IEEE Access**, v. 7, p. 164952–164961, 2019.

- ZABIŃSKI, T. et al. Condition monitoring in Industry 4.0 production systems - The idea of computational intelligence methods application. **Procedia CIRP**, v. 79, p. 63–67, 2019.
- ZAJAČKO, I. et al. Application of artificial intelligence principles in mechanical engineering. **MATEC Web of Conferences**, v. 244, p. 1–7, 2018.
- ZENGELER, N.; KOPINSKI, T.; HANDMANN, U. Hand gesture recognition in automotive human–machine interaction using depth cameras. **Sensors (Switzerland)**, v. 19, n. 1, p. 1–27, 2019.
- ZHANG, J. et al. Concrete cracks detection based on FCN with dilated convolution. **Applied Sciences (Switzerland)**, v. 9, n. 13, 2019.
- ZHANG, L. et al. Application of Internet of Things Technology and *Convolutional Neural Network* Model in Bridge Crack Detection. **IEEE Access**, v. 6, p. 39442–39451, 2018.
- ZHANG, P.; KONG, L. Wheel defect segmentation based on improved otsu method. **2018 IEEE 3rd International Conference on Signal and Image Processing, ICSIP 2018**, n. 1, p. 231–235, 2019.
- ZHANG, W. et al. Automatic crack detection and classification method for subway tunnel safety monitoring. **Sensors (Switzerland)**, v. 14, n. 10, p. 19307–19328, 2014.
- ZHANG, Z. et al. Training spiking neural networks with the improved Grey-Level Co-occurrence Matrix algorithm for texture analysis. **Proceedings - International Conference on Natural Computation**, v. 2016-Janua, n. 61179011, p. 1069–1074, 2016.
- ZHENG, M.; LEI, Z.; ZHANG, K. Intelligent detection of building cracks based on deep learning. **Image and Vision Computing**, v. 103, p. 103987, 2020.
- ZHU, J.; SONG, J. An intelligent classification model for surface defects on cement concrete bridges. **Applied Sciences (Switzerland)**, v. 10, n. 3, p. 1–15, 2020.
- ZHU, Y. et al. Metal pitting corrosion characterized by scanning acoustic microscopy and binary image processing. **Corrosion Science**, v. 170, n. April, p. 108685, 2020.