



INSTITUTO TECNOLÓGICO VALE



**Programa de Pós Graduação em Instrumentação, Controle e Automação de
Processos de Mineração - PROFICAM
Universidade Federal de Ouro Preto - Escola de Minas
Associação Instituto Tecnológico Vale - ITV**

Dissertação

**MÉTODO DE VISÃO COMPUTACIONAL BASEADO EM LASER PARA
MONITORAMENTO DE DEFEITOS EM CORREIAS
TRANSPORTADORAS**

Guilherme Gaigher Netto

**Ouro Preto
Abril de 2019**

Guilherme Gaigher Netto

**MÉTODO DE VISÃO COMPUTACIONAL BASEADO EM LASER PARA
MONITORAMENTO DE DEFEITOS EM CORREIAS
TRANSPORTADORAS**

Dissertação apresentada ao curso de Mestrado Profissional em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Controle e Automação.

Linha de Pesquisa: Tecnologias da Informação, Comunicação e Automação Industrial

Orientador: Prof. D.Sc. Andrea G. Campos Bianchi

Coorientador: Prof. D.Sc. Bruno N. Coelho

Ouro Preto, MG – Brasil

Abril de 2019

G137m Gaigher Netto, Guilherme .
 Método de visão computacional baseado em laser para monitoramento de
 correias transportadoras [manuscrito] / Guilherme Gaigher Netto. - 2019.
 51f.: il.: color; grafs; tabs.

 Orientadora: Prof^a. Dr^a. Andrea Gomes Campos Bianchi.
 Coorientador: Prof. Dr. Bruno Nazário Coelho.

 Dissertação (Mestrado) - Universidade Federal de Ouro Preto. Escola de
 Minas. Departamento de Engenharia de Controle e Automação e Técnicas
 Fundamentais. Programa de Pós Graduação em Instrumentação, Controle e
 Automação de Processos de Mineração.
 Área de Concentração: Engenharia de Controle e Automação de Processos
 Minerais.

 1. Correias Transportadoras. 2. Correias Transportadoras - Monitoramento.
 3. Correias transportadoras - Inspeção. 4. Visão computacional. I. Bianchi,
 Andrea Gomes Campos. II. Coelho, Bruno Nazário. III. Universidade Federal
 de Ouro Preto. IV. Título.

Catálogo: www.sisbin.ufop.br CDD 681.5:622.2

Mestrado Profissional em Instrumentação, Controle e Automação de Processos
de Mineração - PROFICAM


Método de Visão Computacional Baseado em Laser para Monitoramento de
Defeitos em Correias Transportadoras

Guilherme Gaigher Netto

Dissertação defendida e aprovada em 26 de abril de 2019 pela banca
examinadora constituída pelos professores:




D.Sc. Andrea Gomes Campos Bianchi
Orientadora – Universidade Federal de Ouro Preto (UFOP)




D.Sc. Bruno Nazário Coelho
Membro interno – Universidade Federal de São João del Rei (UFSJ)

D.Sc. Romuere Rodrigues Veloso e Silva
Membro externo – Universidade Federal do Piauí (UFPI)
Participação por videoconferência



D.Sc. Guillermo Cámara Chávez
Membro externo – Universidade Federal de Ouro Preto (UFOP)



D.Sc. Agnaldo José da Rocha Reis
Membro interno – Universidade Federal de Ouro Preto (UFOP)

À minha família.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior — Brasil (CAPES) — Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), e da Vale SA.

Ademais, gostaria de agradecer às instituições Universidade Federal de Ouro Preto (UFOP), Instituto Tecnológico Vale (ITV), e Fundação Gorceix (FG). Também, gostaria de agradecer à Chagas Soluções pela doação das correias usadas nos testes reais.

Por fim, gostaria de agradecer à minha família por sempre me apoiar e confiar em mim; minha eterna república Vaticano, moradores e ex-alunos; e a todos os professores e pesquisadores, em especial, Andrea e Bruno, que tanto me ajudaram durante essa fase. Meu mais sincero obrigado.

Resumo da Dissertação apresentada à Escola de Minas/UFOP e ao ITV como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

MÉTODO DE VISÃO COMPUTACIONAL BASEADO EM LASER PARA MONITORAMENTO DE DEFEITOS EM CORREIAS TRANSPORTADORAS

Guilherme Gaigher Netto

Abril/2019

Orientadores: Andrea G. Campos Bianchi
Bruno N. Coelho

Projeto: Estudo e desenvolvimento de um arcabouço para teleoperação avançada de equipamentos de mineração: monitoramento de correias transportadoras

Área VALE: Eficiência operacional e exposição ao risco

Linha de pesquisa: Tecnologias da Informação, Comunicação e Automação Industrial

O monitoramento contínuo de correias transportadoras é de extrema importância já que defeitos em sua superfície podem se desenvolver em desgaste, rasgos e até rupturas, o que pode resultar na interrupção do transportador, e consequentemente, perda de capital, ou ainda pior, acidentes sérios ou fatais. Com o propósito de resolver o problema de monitoramento, o estudo apresentado a seguir propõe um método de visão computacional baseado em laser para detecção de defeitos em correias transportadoras. A abordagem transforma a imagem do feixe de laser em um sinal unidimensional, e então analisa o sinal para identificar os defeitos, considerando que variações no sinal são causados por defeitos/imperfeições na superfície da correia. Diferentemente de outros trabalhos, o método proposto consegue identificar defeitos através de uma reconstrução $2D$, e reconstruir uma aproximação $3D$ da correia, simulando um scanner $3D$. Resultados mostram que o método proposto foi capaz de identificar e reconstruir imperfeições superficiais em ambos ambientes, real e simulado, alcançando valores altos em métricas como precisão e revocação. Além disso, análises em imagens com ruído permitiram investigar a robustez da proposta de solução.

Palavras-chave: Correias transportadoras, Monitoramento de defeitos, Inspeção, Visão computacional

Abstract of Dissertation presented to Escola de Minas/UFOP and ITV as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

LASER-BASED MACHINE VISION METHOD FOR DEFECTS MONITORING IN CONVEYOR BELTS

Guilherme Gaigher Netto

April/2019

Advisors: Andrea G. Campos Bianchi
Bruno N. Coelho

Project: Study and development of a framework for advanced teleoperation of mining equipment: monitoring of conveyor belts.

Area VALE: Operational efficiency and exposure to risk

Research line: Information Technology, Communication, and Industrial Automation

Continuous belt monitoring is of utmost importance since wears on its surface can develop into wear, tears and even rupture, which can cause the interruption of the conveyor, and consequently, loss of capital, or even worse, serious or fatal accidents. With the aim of solving the monitoring problem, the following study proposes a laser-based machine vision method for detecting defects into conveyor belts. The approach transforms an image of a laser line into a one-dimensional signal, then analyze the signal to detect defects, considering that variations in the signal are caused by defects/imperfections on the belt surface. Differently from previous works, the proposed method can identify a defect through a *2D* reconstruction of it, and reconstruct a *3D* approach of the belt simulating a *3D* scanner. Results have shown that the proposed method was capable to detect and rebuild superficial imperfections in both simulated and real conveyor belt, achieving high values in metrics like precision and recall. In addition, noise image analysis allowed us to investigate the robustness of the proposed solution.

Keywords: Converyor belts, Defects monitoring, Inspection, Computer vision

Lista de Figuras

1.1	Transportador de correia. Fonte: Metso	1
3.1	Canais RGB de uma imagem digital	11
3.2	Suavização com o filtro bilateral	11
3.3	Binarização com o método de Otsu	12
3.4	Equalização de histograma e detecção de bordas com algoritmo de Canny .	12
3.5	Sinal cossenoidal ruidoso e sua Transformada de Fourier	13
3.6	Sinal cossenoidal filtrado com filtro passa baixa	13
3.7	Gaussiana de $\mu = 0$ e $\sigma = 1, 2$, e 3	14
3.8	Exemplo de um sinal com <i>outliers</i>	15
3.9	Uso do Escore Z para retirada de <i>outliers</i>	15
3.10	Uso do critério de Chauvenet para retirada de <i>outliers</i>	16
3.11	Uso do MAD para retirada de <i>outliers</i>	17
3.12	Uso da técnica IQR para retirada de <i>outliers</i>	17
3.13	Exemplos do uso do K-Médias	18
3.14	Exemplo do uso do DBSCAN	19
4.1	Representação esquemática da montagem experimental	20
4.2	Fluxograma do método proposta para a detecção de defeitos na correia .	21
4.3	Imagem colorida e cada um de seus canais separados	21
4.4	Imagem em tons de cinza do canal vermelho	22
4.5	Resultado da imagem filtrada com filtro bilateral	22
4.6	Resultado da imagem binarizada com método de Otsu	22
4.7	Sinal unidimensional $y(j)$	23
4.8	Curvatura de uma uma seção da correia com e sem defeito	24
4.9	Representação do módulo da curvatura em uma região da correia em vários instantes de tempo. Valores azuis representam curvaturas baixas, enquanto vermelhos apresentam curvaturas altas	25
4.10	Detecção do defeito	26
4.11	Comparação entre o sinal antes e depois da filtragem no domínio da frequência	27
5.1	Irregularidades da simulação	29

5.2	Instante de tempo t na simulação	29
5.3	Sinal unidimensional proveniente do <i>frame</i> da Figura 5.2	30
5.4	Curvatura proveniente do sinal da Figura 5.3	30
5.5	Pontos de defeitos identificados na correia	30
5.6	Pontos de defeitos identificados na correia em uma bolha superficial	31
5.7	Matriz de defeitos	31
5.8	Matriz de defeitos com identificação individual de cada defeito	32
5.9	Imagem de uma câmera à 60° da correia	33
5.10	Deteção do algoritmo e detecção dos humanos	35
5.11	Instante de tempo t em uma correia com ruído	36
5.12	Curvatura de um sinal filtrado e não filtrado	36
5.13	Valores médios de precisão para diferentes valores de ruídos e σ	37
5.14	Valores médios de revocação para diferentes valores de ruídos e σ	37
5.15	Valores médios de $F1$ para diferentes valores de ruídos e σ	38
5.16	Curvaturas com várias intensidades de ruídos em uma seção da correia sem defeito	38
5.17	Curvaturas com várias intensidades de ruídos em uma seção da correia com defeito	39
5.18	Rasgo	41
5.19	Sequência de imagens do defeito passando pelo laser	42
5.20	Matriz de defeitos e detecção de rasgo	42
5.21	Representação 3D da seção do rasgo	42
5.22	Erosão	43
5.23	Matriz de defeitos e detecção de erosão	43
5.24	representação 3D da seção da erosão	43

Lista de Tabelas

5.1	Resultados médio das detecção de defeitos pelo método proposto com diferentes configurações	33
5.2	Resultados da detecção de defeitos pelo método proposto e por humanos .	34

Lista de Algoritmos

4.2.1 Transformação unidimensional	23
--	----

Lista de Abreviaturas e Siglas

AdaBoost Impulso Adaptativo — *Adaptive Boost*

CAPES Coordenação de Aperfeiçoamento de Pessoal de Nível Superior — Brasil

CCD Dispositivos de Carga Acoplada — *Charge Coupled Device*

CMOS Semicondutor de Metal-óxido Complementar — *Complementary Metal Oxide Semiconductor*

CNPq Conselho Nacional de Desenvolvimento Científico e Tecnológico

DBSCAN Agrupamento Espacial Baseado em Densidade de Aplicações com Ruído — *Density Based Spatial Clustering of Application with Noise*

FAPEMIG Fundação de Amparo à Pesquisa do Estado de Minas Gerais

FG Fundação Gorceix

IQR Intervalo Interquartil — *Interquartile Range*

ITV Instituto Tecnológico Vale

MAD Desvio Absoluto da Mediana — *Median Absolute Deviation*

MAE Erro Absoluto Médio — *Mean Absolute Error*

MDNMS Supressão Não-Máxima em Múltiplas Direções — *Multiple Directional Non-Maxima Suppression*

RFID Identificação por Radiofrequência — *Radio Frequency Identification*

RGB Imagens RGB

RMSE Raiz do Erro Quadrático Médio — *Root Mean Square Error*

ROI Região de Interesse — *Region of Interest*

SSR Retinex de Escala Única — *Single Scale Retinex*

UFOP Universidade Federal de Ouro Preto

VGA *Video Graphics Array*

Lista de Símbolos

b constante de normalidade

R critério de rejeição definido por Chauvenet

FN falso negativo

FP falso positivo

κ curvatura

L_{inf} limite inferior para IQR

L_{sup} limite superior para IQR

M função Mediana

μ média

n número mínimo de pontos dentro da vizinhança

$q_{0,25}$ primeiro quartil

$q_{0,75}$ terceiro quartil

r raio de vizinhança

σ desvio padrão

VP verdadeiro positivo

X critério de rejeição para Escore Z e MAD

Sumário

1	Introdução	1
1.1	Descrição do Problema	1
1.2	Justificativa	3
1.3	Objetivos	3
1.3.1	Objetivo geral	3
1.3.2	Objetivos específicos	4
1.4	Organização do texto	4
2	Revisão Bibliográfica	5
2.1	Visão computacional na indústria	5
2.2	Defeitos em transportadores de correia	6
2.3	Detecção de problemas em correias transportadoras utilizando visão com- putacional	7
3	Fundamentação Teórica	10
3.1	Processamento digital de imagens	10
3.2	Filtragem de sinais	12
3.3	Métodos estatísticos para detecção de <i>outliers</i>	14
3.4	Agrupamento de dados	18
4	Método de visão computacional baseado em laser	20
4.1	Segmentação do laser	21
4.2	Transformação unidimensional	23
4.2.1	Detecção do defeito	24
4.2.2	Reconstrução 3D	26
5	Resultados	28
5.1	Base de dados sintética	28
5.2	Simulação com correias reais	39
6	Conclusões e Trabalhos Futuros	44

Capítulo 1

Introdução

1.1 Descrição do Problema

O transporte de material é um processo crítico em vários campos industriais. Tal cenário instiga o estudo desta ciência com o intuito de melhorar a eficiência e a adaptação dos sistemas de transporte na indústria. Transportadores de correia são equipamentos de alta confiabilidade e grande capacidade de transporte, podendo trabalhar ininterruptamente, apresentando menor custo de instalação do que ferrovias, e menor custo de manutenção do que caminhões. Tais vantagens fazem com que esses equipamentos sejam altamente utilizados para o transporte de material em vários tipos de indústrias (FEDORKO *et al.*, 2016; PANG e LODEWIJKS, 2006). Na mineração, um sistema de transportadores de correia pode ser responsável pelo transporte de materiais em curtas, médias ou longas distâncias, sendo muitas vezes compostos por vários transportadores. Tais equipamentos são compostos por partes mecânicas e elétricas, e de uma maneira sucinta, a correia responsável por carregar o material ao longo do equipamento é sustentada por rolos, sendo tracionada por motores. A Figura 1.1 apresenta um transportador de correia para o transporte de minério de ferro.



Figura 1.1: Transportador de correia. Fonte: Metso

Em grandes empresas mineradoras, transportadores de correia costumam ser equipamentos de grande porte e larga escala, podendo chegar a quilômetros de extensão, com uma velocidade de funcionamento comum de 2 a 5m/s.

O funcionamento correto de tais equipamentos é limitante para o bom desempenho do processo como um todo, visto que a ocorrência de falhas em qualquer transportador de correia implica na interrupção de todo o processo para a manutenção do equipamento, manobra esta que pode equivaler à milhões de prejuízo.

São vários os tipos de falhas que transportadores de correia podem sofrer, por exemplo: desgaste das coberturas, degradação por exposição à intempérie, danos nas extremidades, rasgos longitudinais e perpendiculares em seções da correia, desalinhamento da correia durante o funcionamento, superaquecimento dos rolos, entre outros. Ainda, dependendo da falha ocorrida, pode haver perda substancial de material e, ainda mais crítico, acidentes graves ou fatais com trabalhadores. Sendo assim, é de extrema importância que haja monitoramento dos componentes de um transportador de correia.

Entretanto, esta não é uma tarefa trivial. Além da extensão do transportador poder chegar a ter alguns quilômetros e do ambiente de trabalho ser, em sua grande maioria, insalubre (GUAN *et al.*, 2008), é grande o número de equipamentos necessários para seu monitoramento, se utilizados instrumentos tradicionais. Ademais, certos tipos de defeitos como trava ou aquecimento dos rolos ainda são feitos via inspeção manual.

Apesar de alguns defeitos (*e.g.*: desalinhamento) poderem ser facilmente detectados com sensores de custo relativamente baixo, é extremamente desafiador detectar rasgos e outros defeitos com a tecnologia existente. A grande maioria dos instrumentos existentes são puramente mecânicos, fazendo-se necessário contato direto com partes do transportador, sendo ainda que algumas técnicas podem ser realizadas somente à frio, quando o equipamento está completamente parado e sem material, ou detectam a falha somente após a mesma já ter ocorrido. Isso, sem contar na quantidade de instrumentos necessários para a tarefa, como por exemplo, detectar o desalinhamento da correia transportadora, utilizando chaves de desalinhamento ao longo de todo transportador.

O avanço tecnológico exponencial vem proporcionando o desenvolvimento de técnicas computacionais poderosas e precisas. Isso vem atraindo a atenção de pesquisadores de todas as áreas, desenvolvendo-se instrumentos capazes de processar grandes quantidades de informação em cada vez menos tempo, de maneira cada vez mais precisa. Desse modo, o uso de visão computacional tem se tornado cada vez mais utilizado na indústria por apresentar resultados satisfatórios, já que a técnica tenta mimetizar a inspeção visual humana (SONKA *et al.*, 2014). Ademais, quando combinada com outras técnicas, como Aprendizado de Máquina, consegue-se obter a capacidade de generalização, como no caso do presente trabalho, a capacidade de generalizar tipos de defeitos, sendo também capaz de realizar tarefas com grande acurácia e em tempo real.

O estudo apresentado a seguir contribui com uma nova maneira de identificar defeitos

em correias transportadoras, capaz de identificar não somente rasgos longitudinais, como em grande maioria dos métodos de visão computacional atuais, mas também capaz de identificar defeitos superficiais como erosões e bolhas. Ademais, é apresentado também uma nova abordagem sobre o uso de informações como *outliers*, bem como de algoritmos de agrupamento.

1.2 Justificativa

O desenvolvimento de novas técnicas para o monitoramento de correias transportadoras pode oferecer uma nova maneira de inspeção preditiva das mesmas, aumentando a vida útil dos transportadores de correia, evitando a parada por defeitos graves. De fato, um bom planejamento da manutenção dos equipamentos de transportadores de correia pode gerar economia palpável de capital para empresas de pequeno, médio e, principalmente, grande porte.

Pode ser levado em consideração também que sistemas de monitoramento por visão computacional não são invasivos, dispensando o contato físico direto com o que está sendo monitorado. Há também a possibilidade da melhoria nas condições de trabalho do inspetor, tornando possível o monitoramento remoto do equipamento. Essa abordagem também permite antecipação do estado do defeito através do uso em conjunto de técnicas de inteligência computacional, como algoritmos de treinamento e aprendizagem.

Ademais, o incentivo em pesquisa e desenvolvimento de equipamentos e sistemas mais tecnológicos, ajuda na integração da empresa com a Indústria 4.0 que, no caso do estudo apresentado, oferece uma maneira de monitoramento remoto, com capacidade de uma reconstrução virtual do equipamento que está sendo monitorado.

1.3 Objetivos

1.3.1 Objetivo geral

O presente trabalho tem por objetivo desenvolver uma técnica computacional baseada em laser capaz de detectar defeitos em correias transportadoras por meio de visão computacional. A proposta é avaliar as variações da superfície da correia utilizando imagens de um feixe de laser posicionado perpendicularmente ao sentido de movimento do transportador, fazendo com que defeitos causem variações na imagem do feixe de laser. Utilizando-se de uma abordagem para transformar a imagem do laser em um sinal unidimensional, são capturados pontos de alta curvatura neste sinal, admitindo que esse pontos seria causados por defeitos presentes na correia transportadora, fazendo-se possível a reconstrução e identificação dos defeitos.

1.3.2 Objetivos específicos

Dentre os objetivos específicos podemos destacar:

- desenvolver um método capaz de detectar pontos de deformação na imagem do segmento do laser;
- investigar a robustez da proposta por meio de simulações com ruídos de diferentes tamanhos e formas;
- reconstruir uma aproximação $3D$ da correia;
- desenvolver um aparato experimental para a captura das imagens do feixe de laser em correias transportadoras reais;
- criar de uma base de dados com defeitos sintéticos, com e sem ruídos.

1.4 Organização do texto

Este documento está organizado da seguinte maneira: inicialmente, no Capítulo 2, é apresentada uma revisão bibliográfica sobre assuntos pertinentes à pesquisa; no Capítulo 3 destacamos a fundamentação teórica com métodos utilizados no presente trabalho para o alcance dos resultados; no Capítulo 4 apresentamos uma descrição do método proposto; no Capítulo 5 são apresentados os resultados obtidos; e por fim, no Capítulo 6 são apresentadas as conclusões sobre os resultados, bem como possíveis trabalhos futuros.

Capítulo 2

Revisão Bibliográfica

O presente Capítulo tem por objetivo apresentar uma revisão da literatura nos seguintes assuntos: na Seção 2.1 será apresentada uma revisão sobre o uso de visão computacional na indústria; na Seção 2.2 será apresentado um estudo sobre os defeitos encontrados em transportadores de correia; e por fim, na Seção 2.3 serão apresentados trabalhos que visam o monitoramento de correias transportadoras utilizando visão computacional.

2.1 Visão computacional na indústria

Surgida em meados dos anos 60, a visão computacional vem experimentando um crescimento exponencial desde sua aparição. Graças ao avanço tecnológico, também exponencial, tanto dos hardwares quanto dos softwares (ZHANG *et al.*, 2014), pode-se afirmar que a visão humana é potencialmente substituível por sistemas de visão computacional em escala comercial (LOCHT *et al.*, 1997) para tarefas específicas.

Um sistema de visão computacional se baseia no uso de hardwares e softwares dedicados para reconhecimento, controle, ou qualquer outro tipo de ação que seja tomada através da decisão do próprio sistema, sem a interferência externa, já que esses sistemas têm o objetivo de simular o sentido da visão humana (SONKA *et al.*, 2014), ou seja, a capacidade de generalizar através da visão (ELBEHIERY *et al.*, 2005).

Geralmente os sistemas de visão computacional são constituídos de quatro partes: iluminação externa, câmera, hardware e software para processamento, enquanto o processamento de imagem pode ser dividido geralmente em três partes: baixo, médio e alto nível (BROSNAN e SUN, 2004; SUN, 2000). O processamento de baixo nível pode ser definido pela aquisição e pré-processamento da imagem, onde a aquisição se faz por sensores chamados Dispositivos de Carga Acoplada — *Charge Coupled Device* (CCD), ou Semicondutor de Metal-óxido Complementar — *Complementary Metal Oxide Semiconductor* (CMOS), que geram a imagem através de um processo analógico-digital, e o pré-processamento que tem por objetivo corrigir ruídos, sejam eles na intensidade dos *pixels* da imagem em tons de cinza (correção de histograma), na forma geométrica de objetos aparentes

(transformações morfológicas), entre outras, melhorando assim as características da imagem obtida. O processamento de médio nível tem por objetivo segmentar a imagem em regiões específicas, tornando-as mais aparentes, para então serem extraídas as características mais importantes dessas regiões, podendo ser formas geométricas, cores, entre outros. Finalmente, o processamento de alto nível tem por objetivo reconhecer e interpretar as características obtidas com as operações anteriores, fazendo com que o sistema de visão computacional tenha capacidade de tomar decisões de acordo com sua finalidade.

A necessidade de se obter os mais diferenciados tipos de produtos com altíssima qualidade em todos seguimentos industriais, tais como alimentício, têxtil, entre outros, traz consigo a procura por meios automáticos, precisos, rápidos e economicamente viáveis de supervisionar/controlar os processos industriais de fabricação desses produtos. Ademais, uma variedade de sistemas baseados em operações manuais podem ser bastante tediosos, dispendiosos e facilmente influenciados pelo ambiente em que se encontram (ELMASRY *et al.*, 2012a,b; RAZMJOOY *et al.*, 2012), além de sua acurácia não poder ser garantida (PARK *et al.*, 1996).

Ao longo dos anos, a visão computacional vem se mostrando uma ferramenta capaz de cumprir essas exigências (BROSNAN e SUN, 2004). Atualmente, vários setores industriais utilizam esse tipo de supervisão com sucesso, como os setores de agricultura e alimentício (MAOHUA, 1999; WANG e SUN, 2001; ZHANG *et al.*, 2014), para monitoramento da boa aparência do alimento, por exemplo. Por ser um método que não necessita de contato físico, a visão computacional pode muito bem ser aplicada para suprir a necessidade da indústria moderna (AYDIN *et al.*, 2014; MEGAHED e CAMELIO, 2012). Jemwa e Aldrich (2012) propuseram um sistema de visão computacional para aproximação do tamanho do material presente em transportadores de correia utilizando técnicas de análise de textura de imagens. Hamzeloo *et al.* (2014) propuseram um sistema *online* para estimar o tamanho das partículas num circuito de cominuição de cobre utilizando técnicas de visão computacional e redes neurais artificiais.

2.2 Defeitos em transportadores de correia

Transportadores de correia têm sido desenvolvidos por décadas (PANG e LODEWIJKS, 2005), sendo parte essencial nos processos de transporte e podem ser citados como os equipamentos de melhor custo-benefício para transporte contínuo de grandes quantidades de material devido à sua alta eficiência, grande capacidade, construção relativamente simples e menor necessidade de manutenção (FEDORKO *et al.*, 2014; FU HOU e RUI MENG, 2008).

Um problema encontrado em sistemas de monitoramento tradicionais dos componentes de transportadores de correia é que eles dependem do funcionamento do transportador. De um lado, roletes e polias somente podem ser monitorados enquanto estiverem rodando.

Por outro lado, as correias transportadoras somente podem ser observadas quando não estão em operação. Também, diversas vezes é difícil definir se uma avaria foi provocada pelo funcionamento do transportador ou pelo ato de retirada da amostra quando há necessidade de um ensaio destrutivo na correia (FEDORKO *et al.*, 2018).

Transportadores de correia são propensos à falhas, como por exemplo: desgaste das coberturas, degradação por exposição à intempérie, danos nas extremidades e rasgos longitudinais e perpendiculares em seções da correia, desalinhamento da correia durante o funcionamento, superaquecimento dos rolos, entre outros, acarretando risco na produção (YANG *et al.*, 2014). Falhas em sistemas de tais equipamentos geralmente resultam em parada da produção para reparo, ou em casos mais graves, acidentes com trabalhadores, trazendo graves consequências à empresa.

Entretanto, até hoje são utilizados técnicas e instrumentos tradicionais que exigem contato físico direto com partes do transportador para que haja identificação de falhas, ou mesmo métodos que identificam falhas apenas no momento em que estas ocorrem em seu pior estado, como um rasgo que atravessa toda a espessura da correia, ocorrendo vazamento de material. Um exemplo são os sensores mecânicos como sensores de desalinhamento, que são compostos por chaves de posições que, ao entrar em contato com a correia desalinhada, acionam um alarme, ou dependendo da gravidade do desalinhamento, param o funcionamento do transportador.

Técnicas mais sofisticadas e inteligentes que monitoram o estado de componentes do transportador de correias já foram desenvolvidas. Nicolay *et al.* (2004) propuseram um sistema que fizesse uso de Identificação por Radiofrequência — *Radio Frequency Identification* (RFID) por meio de *tags* espalhadas ao longo de toda a extensão da correia, fazendo com que, ou um tempo muito grande entre leituras ou a falta de uma *tag* disparasse o alarme de rasgos na correia. Pang e Lodewijks (2006) propuseram o uso de ímãs no interior da correia e o uso de um sensor externo, fazendo com que de acordo com as características do sinal obtido no sensor, fosse possível determinar as condições da correia tais como: velocidade de funcionamento, desgaste, entre outros. Guan *et al.* (2008) propuseram o uso de raios-X em conjunto com um receptor para que através da observação da atenuação do sinal recebido pelo receptor, o sistema fosse capaz de identificar rupturas nas almas de aço das correias. Nascimento *et al.* (2017) propuseram o uso de visão computacional para inspeção de rolos através da imagem de uma câmera térmica.

2.3 Detecção de problemas em correias transportadoras utilizando visão computacional

É notável entre os métodos inteligentes de monitoramento do estado das correias transportadoras citados que, mesmo alguns possuindo capacidade de monitoramento melhor

que os métodos mais tradicionais, eles ainda necessitam, ou de uma construção específica dotada de sensores no interior da correia, ou de equipamentos pouco utilizados em áreas industriais agressivas como a de uma mineradora, como emissores de raios-X, prejudicial à saúde humana. Com essa justificativa, o uso de visão computacional tem se tornado um forte candidato para o monitoramento de correias transportadoras.

Fromme *et al.* (2006) propuseram um sistema capaz de detectar defeitos em seções da correia através de dados provenientes de pelo menos uma câmera, utilizando um *encoder* para o ajuste dos *frames* da câmera. Kurihara *et al.* (2006) desenvolveram um aparato utilizando câmera e laser para detecção de rasgos em correias transportadoras através do espaçamento do feixe de laser no caso de rasgo na correia.

Li *et al.* (2011) propuseram um método inteligente utilizando características da imagem binária da correia (como forma, posição e tamanho dos objetos identificados) em conjunto com *ANDs* e *ORs* para determinar se a correia possui ou não rasgos. Peng (2013) propôs o uso do algoritmo Supressão Não-Máxima em Múltiplas Direções — *Multiple Directional Non-Maxima Suppression* (MDNMS) para identificar rasgos em imagens em tons de cinza de correias transportadoras, além de desenvolver um método de detecção automática de falsos positivos utilizando o classificador Impulso Adaptativo — *Adaptive Boost* (AdaBoost).

Yang *et al.* (2014) desenvolveram um aparato utilizando uma câmera focada em uma área fortemente iluminada, proporcionando um sistema capaz de identificar rasgos e desalinhamento em correias transportadoras. Li e Miao (2016) propuseram o uso do algoritmo Retinex de Escala Única — *Single Scale Retinex* (SSR) para identificar rasgos presentes em correias transportadoras através de características da imagem binária resultante, como limites de áreas de retângulos dos objetos identificados, entre outras.

Yang *et al.* (2016) propuseram transformar o sinal de duas dimensões obtido pela câmera em um vetor unidimensional, e a partir daí, detectar os rasgos em correias transportadoras através da diferença entre as intensidades obtidas pelo vetor unidimensional. Qiao *et al.* (2016) propuseram a utilização de duas câmeras (infravermelha e CCD) e um feixe de laser emitido sobre a correia, detectando rasgos através da descontinuidade do laser pela câmera CCD, e pelo histograma obtido pela câmera infravermelha. Qiao *et al.* (2017) utilizaram uma câmera em conjunto com um feixe de laser emitido sobre a superfície da correia para detectar rasgos em correias transportadoras, utilizando detecção de arestas e transformada de Hough.

Embora os trabalhos citados anteriormente consigam, de fato, identificar defeitos como rasgos longitudinais em correias transportadoras, ainda são poucos, ou mesmo nenhum, que conseguem informar quaisquer outras informações ou detalhes a cerca de outros tipos de defeitos, como erosões superficiais, por exemplo. Com o intuito informar mais sobre os defeitos detectados, como forma, além de possibilitar a identificação de mais tipos de defeitos, como bolhas e erosões superficiais, o presente trabalho propõe utilizar uma câmera

focada em uma seção da correia onde se encontre um feixe de laser horizontal perpendicular ao sentido de movimento da correia, assumindo que defeitos presentes no perfil da correia causem deformações no formato do laser capturado pela câmera, e, capturando essas deformações, identificar e reconstruir o formato desses defeitos.

Capítulo 3

Fundamentação Teórica

No presente trabalho foram investigadas diversas técnicas para a detecção dos defeitos na superfície da correia obtidos através das variações do feixe de laser na imagem. Este Capítulo tem por objetivo apresentar e descrever brevemente o funcionamento de cada uma delas, iniciando na Seção 3.1, descrevendo brevemente operações feitas para processamento digital de imagens; na Seção 3.2 serão apresentadas técnicas de filtragem de sinais digitais; a Seção 3.3 descreverá sobre técnicas estatísticas para detecção de *outliers*; e por fim, na Seção 3.4 será descrito brevemente sobre algoritmos de agrupamento de dados.

3.1 Processamento digital de imagens

O processamento de imagens vem se tornando cada vez mais praticável nos dias atuais devido ao aumento do poder computacional. Assim como em sinais de somente uma dimensão, existem diversas técnicas para o processamento de sinais multidimensionais, como é o caso das imagens. Várias técnicas são basicamente a adaptação das técnicas de sinais unidimensionais para sinais de mais de uma dimensão, tendo como objetivo apresentar características de interesse para cada aplicação.

Imagens capturadas por sensores de câmeras digitais possuem, em sua grande parte, três diferentes canais — Vermelho (*Red*), Verde (*Green*), e Azul (*Blue*) — sendo chamadas de RGB. A Figura 3.1 apresenta os três canais de uma imagem digital.

Uma operação comum na primeira fase do processamento é a suavização. Essa operação tem por objetivo retirar ruídos presentes na imagem, através da convolução da imagem por diferentes *kernels*, que são filtros bidimensionais que percorrem a imagem em toda sua dimensão. No presente trabalho, foi utilizado o Filtro Bilateral (ELAD, 2002), um filtro não-linear que tem a capacidade de preservar as bordas de objetos presentes na imagem. A Figura 3.2 apresenta a filtragem do canal R da Figura 3.1 com o filtro bilateral, sendo possível observar que a imagem foi suavizada, porém, ainda apresenta informações evidentes de bordas e contornos.




Figura 3.1: Canais RGB de uma imagem digital



Figura 3.2: Suavização com o filtro bilateral

Outra operação bastante utilizada em processamento digital de imagens é a binarização, que consiste em transformar a imagem, antes com várias intensidades — uma imagem de 8 bits possui intensidades que podem variar de 0 à 255 — em uma imagem binária, ou seja, com apenas duas intensidades: 0 ou 255 (ou 0 e 1). O método de binarização escolhido para o presente trabalho foi o método de Otsu (OTSU, 1979), muito utilizado para definição de limiares em imagens bimodais, ou seja, imagens que possuem duas intensidades predominantes. A Figura 3.3 apresenta o resultado da utilização do método de Otsu para a binarização da Figura 3.2.

Existem diversas outras operações que podem ser feitas em imagens para se obter características de interesse como: equalização de histograma, detecção de bordas, filtragem morfológica, entre outras. Para o presente trabalho, foi utilizado somente as operações de filtragem de ruídos e binarização. Entretanto, para exemplificar, a Figura 3.4 apresenta as operações de equalização de histograma e a detecção de bordas com o algoritmo de Canny (CANNY, 1986).



Figura 3.3: Binarização com o método de Otsu



(a) Imagem com equalização de histograma



(b) Imagem com detecção de bordas

Figura 3.4: Equalização de histograma e detecção de bordas com algoritmo de Canny

3.2 Filtragem de sinais

Sinais digitais podem sofrer com distorções, ruídos, entre outros. Sendo assim, é altamente recomendado que se faça um processamento desse sinal antes que ele possa ser de fato utilizado. Uma das formas de filtragem mais utilizadas é feita no domínio da Frequência (ZADEH, 1953). A transformação do sinal no domínio do tempo para o domínio da frequência se dá pela transformada de Fourier $\hat{f}(\omega)$, descrita nas Equações 3.1 (contínuo), e 3.2 (discreto), que decompõe o sinal nas frequências que, combinadas, compõem o sinal no domínio do tempo.

$$\hat{f}(\omega) = \int_{-\infty}^{\infty} f(t)e^{-i\omega t} dt \quad (3.1)$$

$$\hat{f}(\omega) = \sum_{n=-\infty}^{\infty} f[t]e^{-i\omega t}, n \in \mathbb{Z} \quad (3.2)$$

A Figura 3.5 apresenta um sinal cossenoidal com ruído gaussiano ($\sigma = 1$, $\mu = 0$), e seu respectivo representante no domínio da frequência. É possível observar que a frequência cossenoidal (frequência baixa) está presente, assim como a frequência ruidosa (frequência alta).




Figura 3.5: Sinal cossenoidal ruidoso e sua Transformada de Fourier

A filtragem desse sinal pode ser feita encontrando a frequência cossenoidal no domínio da frequência, mantendo somente ela, e atribuindo zero para todas as outras frequências. Assim, ao retornar o sinal para o domínio do tempo (através da transformada inversa de Fourier), o sinal cossenoidal filtrado terá somente a frequência de interesse. A Figura 3.6 apresenta o sinal cossenoidal filtrado sobreposto sobre seu respectivo ruidoso. Pode ser observado que após a filtragem, somente a frequência cossenoidal permaneceu no sinal.




Figura 3.6: Sinal cossenoidal filtrado com filtro passa baixa

Outros tipos de filtros utilizados para filtrações no domínio da frequência, são os filtros que permitem a passagem de certas frequências (altas, baixas, ou específicas) (BUTTERWORTH, 1930), ou seja, um filtro que após sua utilização, permaneça no sinal no

domínio da frequência somente as frequências escolhidas. Um exemplo de um filtro passa-baixa bastante utilizado, é o Filtro Gaussiano (HADDAD e AKANSU, 1991). A utilização desse filtro consiste em multiplicar o sinal no domínio da frequência (porém, deslocado — *shifted*) pela função Gaussiana $G(x)$, descrita pela Equação 3.3

$$G(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad (3.3)$$

sendo: σ , o desvio padrão, e μ , a média. A Figura 3.7 apresenta uma função gaussiana com $\sigma = 1, 2$, e 3 , e $\mu = 0$. Como pode ser observado, o parâmetro σ é o mais importante na filtragem com a função gaussiana, pois ele é o responsável pela seleção das frequências que permaneceram com seu valor original.




Figura 3.7: Gaussiana de $\mu = 0$ e $\sigma = 1, 2$, e 3

3.3 Métodos estatísticos para detecção de *outliers*

Outliers são observações distantes do restante dos dados (GRUBBS, 1969), podendo ocorrer devido à variabilidade dos dados, erros experimentais, entre outros motivos. Existem diversas técnicas estatísticas para detecção de *outliers*: Escore Z (*Z-Score*), Critério de Chauvenet, Desvio Absoluto da Mediana — *Median Absolute Deviation* (MAD), Intervalo Interquartil — *Interquartile Range* (IQR), entre outras. A Figura 3.8 exemplifica um sinal randômico com distribuição normal, com a presença de *outliers*. Será usado esse sinal para ilustrar os métodos de detecção de *outliers* descritos a seguir.

A técnica conhecida por Escore Z (*Z-Score*) utiliza para identificação dos *outliers* os cálculos da média (μ) e desvio padrão (σ) dos dados observados. Um dado é definido como *outlier* se a diferença entre ele e a média for maior que X vezes o desvio padrão (HODGE e AUSTIN, 2004), podendo ser definido como mostra a Equação 3.4

$$\text{Se } \frac{|x_i - \mu|}{\sigma} > X, \text{ rejeite } x_i, \quad (3.4)$$




Figura 3.8: Exemplo de um sinal com *outliers*

sendo: x_i , o i -ésimo dado observado; e X , o critério de rejeição proposto por Leys *et al.* (2013), que admite como $X = 3$ muito conservador (99,74% dos dados seriam aceitáveis), $X = 2$ pouco conservador (95,44% dos dados seriam aceitáveis), entre outros valores. A Figura 3.9 mostra o resultado da filtragem de *outliers* utilizando a técnica Escore Z com um critério de rejeição igual à três.




Figura 3.9: Uso do Escore Z para retirada de *outliers*

O critério de Chauvenet utiliza a média e o desvio padrão de janelas de tamanho conhecido que dividem os dados observados, para definir se um dado dentro dessas janelas é um *outlier* ou não (LIN e SHERMAN, 2007). O critério de Chauvenet pode ser definido como mostra a Equação 3.5

$$\text{Se } \frac{|x_i - \bar{\mu}|}{\bar{\sigma}} > R, \text{ rejeite } x_i, \quad (3.5)$$

sendo: $\bar{\mu}$, a média de cada janela; $\bar{\sigma}$, o desvio padrão de cada janela; e R , o critério de rejeição definido por Chauvenet para o tamanho da janela utilizada. A Figura 3.10 mostra o resultado da filtragem de *outliers* utilizando o critério de Chauvenet com uma janela de tamanho 10, fazendo $R = 1,96$.




Figura 3.10: Uso do critério de Chauvenet para retirada de *outliers*

MAD é um método que, diferentemente do Escore Z e do critério de Chauvenet, utiliza o desvio absoluto de cada dado em relação à mediana do sinal, não utilizando média nem desvio padrão. A mediana é uma medida que divide um conjunto de dados ordenados em dois grupos (também podendo ser chamada de segundo Quartil), sendo um com dados inferiores à mediana e outro, superiores (MONTGOMERY *et al.*, 2000).

O cálculo do MAD pode ser definido como mostra a Equação 3.6

$$MAD = M(|x_i - M(x)|)b, \quad (3.6)$$

sendo: x , os dados observados; M , a função da mediana; e b , a constante ligada à normalidade dos dados, com valor geralmente utilizado de 1,4826.

Em outras palavras, o MAD pode ser definido como a mediana do vetor formado pelo desvio absoluto entre cada um dos dados observados e a mediana desses dados. A detecção de *outliers* utilizando MAD pode ser definida como mostra a Equação 3.7

$$\text{Se } \frac{x_i - M}{MAD} > |\pm X|, \text{ rejeite } x_i, \quad (3.7)$$

onde o critério de rejeição X pode ser considerado da mesma forma como na definição do Escore Z. A Figura 3.11 mostra o resultado da filtragem de *outliers* utilizando técnica MAD com um critério de rejeição também igual à três.

A regra para detecção de *outliers* definida pelo IQR define valores limites de aceitação ou rejeição do dado observado de acordo com a Equação 3.8 (JEONG *et al.*, 2017)

$$IQR = q_{0,75} - q_{0,25}, \quad (3.8)$$

em que: $q_{0,75}$ e $q_{0,25}$, ou terceiro quartil e primeiro quartil, representam os valores onde se encontram 75% e 25% dos dados ordenados, respectivamente (LEROY e ROUSSEUW, 1987). O critério para rejeição é definido como mostra a Equação 3.9




Figura 3.11: Uso do MAD para retirada de *outliers*

$$\text{Se } L_{inf} \leq x_i \leq L_{sup}, \text{ aceite } x_i, \quad (3.9)$$

sendo: L_{inf} , o limite inferior, definido por $q_{0,25} - 1,5 \times \text{IQR}$; e L_{sup} , o limite superior, definido por $q_{0,75} + 1,5 \times \text{IQR}$. A Figura 3.12 mostra o resultado da filtragem de *outliers* utilizando a técnica IQR.





Figura 3.12: Uso da técnica IQR para retirada de *outliers*

Não há uma maneira de definir qual técnica apresentada obtém melhor resultado para identificação de *outliers*, já que as mesmas utilizam informações diferentes do sinal. Por exemplo, Escore Z e Chauvenet utilizam média e desvio padrão, enquanto MAD e IQR utilizam quartis. Ademais, existem ainda outras técnicas para detecção de *outliers* que não foram descritas nesta Seção. Geralmente para o tratamento de sinais, a comparação entre cada técnica vem de métricas para cálculo de erros, como Raiz do Erro Quadrático Médio — *Root Mean Square Erro* (RMSE), Erro Absoluto Médio — *Mean Absolute Erro* (MAE), entre outras, o que não é relevante para o presente trabalho.


3.4 Agrupamento de dados

Técnicas de Aprendizado de Máquina tem sido amplamente utilizada nos últimos tempos em áreas da tecnologia como Análise de Dados (*Data Analytics*), Mineração de Dados (*Data Mining*) e *Big Data*. Uma grande ferramenta nessas áreas são os algoritmos de agrupamento, como o K-Médias (*K-Means*), *Mean Shift*, Agrupamento Espacial Baseado em Densidade de Aplicações com Ruído — *Density Based Spatial Clustering of Application with Noise* (DBSCAN), entre outros.

Um dos mais simples, e primeiramente utilizado por MacQueen *et al.* (1967), o algoritmo de agrupamento de dados K-Médias, é um algoritmo largamente utilizado para este fim, possuindo convergência rápida (dependendo da quantidade de dados). A ideia é agrupar dados em um número de grupos conhecidos, de acordo com a distância entre cada um dos dados, e o centroide de cada grupo (HARTIGAN e WONG, 1979; KANUNGO *et al.*, 2002; LLOYD, 1982). A Figura 3.13 apresenta o agrupamento de dados unidimensionais (Figura 3.13a), e bidimensionais (Figura 3.13b).



(a) K-Médias em dados 1D



(b) K-Médias em dados 2D

Figura 3.13: Exemplos do uso do K-Médias

Uma das desvantagens do K-Médias é que o algoritmo necessita de conhecer previamente o número de grupos nos dados. Ou seja, se a quantidade de grupos nos dados é desconhecida, ele pode convergir para valores não interessantes para o utilizador.

Uma saída para o problema do desconhecimento da quantidade de grupos presentes nos dados é o DBSCAN. O algoritmo é utilizado para identificar um número desconhecido de agrupamentos presentes em uma base de dados, de tamanhos e formatos também desconhecidos, de acordo com a densidade das observações, separando os ruídos desses agrupamentos identificados (ESTER *et al.*, 1996).

Esse algoritmo usa conceitos de vizinhança, pontos centrais, pontos de fronteira, entre outros. A vizinhança de um ponto é formada por um círculo de raio r . Seja um ponto que contenha um número mínimo de pontos que estejam dentro ou no limite de sua vizinhança, esse ponto é então chamado de ponto central. Caso um ponto contenha menos que esse

número mínimo, este ponto é chamado de ponto de fronteira. Um agrupamento é formado por pontos centrais que sejam conectados através de pontos centrais e/ou pontos de fronteira. Caso um ponto qualquer não esteja contido em qualquer agrupamento, este ponto é definido como ruído na base de dados. Os principais parâmetros a serem configurados para o algoritmo são: o tamanho do raio r , e a quantidade de pontos mínimos presentes na vizinhança n . A Figura 3.14 exemplifica o uso do algoritmo DBSCAN reconhecendo em dados bidimensionais três diferentes grupos, e uma certa quantidade de ruídos.




Figura 3.14: Exemplo do uso do DBSCAN

Capítulo 4

Método de visão computacional baseado em laser

O objetivo deste trabalho é detectar defeitos na superfície de correias transportadoras por meio de visão computacional. A proposta é utilizar, além de uma câmera, um feixe de laser para salientar as imperfeições e defeitos presentes na correia, transformando a imagem do feixe de laser em um sinal unidimensional, utilizando diferentes abordagens para reconstrução e identificação dos defeitos.

A Figura 4.1 apresenta um esquema da montagem experimental do sistema câmera-laser. O laser emite um feixe horizontal perpendicular ao sentido de movimento do transportador de correia, sobre a parte de recebimento de carga, porém, no momento de retorno da correia, onde ela se encontra vazia e com a superfície mais plana. Um bom local para a montagem do equipamento seria próximo aos mancais, onde a correia se torna mais reta (devido ao mancal), e depois dos raspadores, onde ela se encontra mais limpa de material. A câmera então é focada onde se encontra o feixe de laser, porém, com uma inclinação em seu plano de θ graus do plano do feixe de laser, e perpendicular ao plano da correia.




Figura 4.1: Representação esquemática da montagem experimental

A ideia de tal configuração é fazer com que a câmera capture a deformação na linha horizontal do feixe de laser sobre a correia causada pelas deformações presentes em sua

superfície. A Figura 4.2 apresenta o fluxograma do método proposto. A imagem do feixe é capturada pela câmera e transformada em um sinal unidimensional capaz de descrever o formato do feixe. A curvatura desse sinal é calculada para a extração dos pontos de alta curvatura, assumindo que esses pontos se localizam onde algum defeito presente na correia deforma o formato do laser na imagem. Esses pontos são então identificados como *outliers* da curvatura através de uma análise estatística, sendo agrupados em seguida, resultando na identificação do defeito. Também foi proposto utilizar o sinal unidimensional para a reconstrução de uma aproximação 3D da correia, assumindo que as distorções na imagem do laser, e em seguida no sinal unidimensional, pudessem ser representadas em função da profundidade.



Figura 4.2: Fluxograma do método proposta para a detecção de defeitos na correia

4.1 Segmentação do laser

A primeira etapa é a captura da imagem pela câmera, seguida pela escolha da Região de Interesse — *Region of Interest* (ROI), para que seja processada somente a parte da imagem que contenha o feixe de laser, excluindo o ambiente ao redor, tornando o processamento mais rápido e simplificado. Essa seleção deverá ser feita pelo operador no ato de inicialização do sistema. A Figura 4.3 apresenta um exemplo de uma ROI escolhida onde há a presença do laser sobre a correia. A imagem mostra a imagem da correia simulada que foi utilizada no presente trabalho. Também, a Figura mostra que a informação do laser está predominantemente presente no canal vermelho (4.3b) da imagem RGB, devido ao seu espectro.



Figura 4.3: Imagem colorida e cada um de seus canais separados

Em seguida, o laser foi segmentado do fundo da imagem. Foi utilizado somente o canal vermelho da imagem, visto que ele possui parcela mais significativa sobre a informação da

cor do laser, facilitando assim a segmentação. A imagem resultante é então uma imagem em tons de cinza onde os pixels na região do laser possuem intensidades altas, e o restante, intensidade baixa. A imagem em tons de cinza referente ao canal vermelho é apresentada na Figura 4.4, onde tal Figura apresenta agora a imagem da emissão do laser em uma correia real, que será utilizado para o restante da explicação do método, por se tratar de um ambiente mais real.




Figura 4.4: Imagem em tons de cinza do canal vermelho

Devido ao ambiente agressivo das indústrias mineradoras (luz, particulado suspenso, água, entre outros), a imagem capturada pela câmera pode possuir vários ruídos. Ademais, imagens digitais apresentam ruídos de discretização. Assim, é usual fazer operações de filtragem em sistemas de processamento digital de imagens. Essa operação foi realizada com o Filtro Bilateral, um filtro não-linear capaz de retirar grande parte dos ruídos presentes na imagem capturada, sem alterar as características principais da mesma, como por exemplo, bordas de objetos. O resultado da filtragem com o filtro bilateral é apresentado na Figura 4.5.




Figura 4.5: Resultado da imagem filtrada com filtro bilateral

A segmentação do laser foi realizada através do método de Otsu, bastante utilizado para binarização de imagens bimodais, ou seja, com a presença de duas intensidades predominantes. Essa operação transforma a imagem em tons de cinza em uma imagem binária, sendo a região do laser com intensidade alta (objeto de interesse na imagem), e o restante com intensidade baixa (fundo). O resultado da imagem binarizada é apresentado na Figura 4.6.



Figura 4.6: Resultado da imagem binarizada com método de Otsu

Algoritmo 4.2.1: Transformação unidimensional

```
1 for  $j = 1 \rightarrow N$  do
2    $m \leftarrow 0; cont \leftarrow 0;$ 
3   for  $i = 1 \rightarrow M$  do
4     if  $I(i, j) \neq 0$  then
5        $m \leftarrow m + i;$ 
6        $cont \leftarrow cont + 1;$ 
7     end
8   end
9   if  $cont = 0$  then
10     $cont \leftarrow 1;$ 
11  end
12   $y(j) = \frac{m}{cont};$ 
13 end
```

4.2 Transformação unidimensional

Como descrito na seção anterior, imagens binárias são compostas por duas intensidades: alta e baixa. Entretanto, devido a largura do laser, a região segmentada possui também uma determinada largura. Sendo o processamento de uma imagem (sinal de duas dimensões) mais custoso e complexo que o de um sinal unidimensional, a região bidimensional foi transformada em um sinal unidimensional. Considere a imagem denotada por $I(i, j)$ de tamanho $M \times N$ onde i representa as linhas, e j as colunas da imagem, sendo $i = 1$ até M , e $j = 1$ até N . A transformação ocorre atribuindo a cada coluna j da imagem o valor médio das posições dos índices i de cada linha quando $I(i, j) = 1$. O Algoritmo 1 mostra o pseudocódigo do cálculo do sinal unidimensional $y(j)$, enquanto a Figura 4.7 apresenta a transformação unidimensional da imagem binária 4.6.




Figura 4.7: Sinal unidimensional $y(j)$

4.2.1 Detecção do defeito

Para a detecção do defeito, foi proposto calcular a curvatura do sinal unidimensional, e então identificar os pontos de alta curvatura como pontos que descrevem o formato $2D$ do defeito. A curvatura $\kappa(j)$ pode ser obtida através da Equação 4.1

$$\kappa = \frac{|y''|}{\sqrt{(1 + y'^2)^3}} \quad (4.1)$$

onde y' é a primeira derivada de y ; e y'' a segunda derivada. O cálculo da curvatura está claramente explicada em Xianguo *et al.* (2018).

Detecção de pontos de alta curvatura

A detecção dos pontos de alta curvatura é um desafio, uma vez que a escolha de limiares fixos nem sempre é a melhor opção devido à natureza variável da curvatura. Foi proposto então fazer uma análise estatística para identificar tais pontos. A Figura 4.8 apresenta a curvatura calculada a partir de um sinal unidimensional em uma região da correia com defeito (curva azul) e sem defeito (curva laranja). Podemos observar que ambas são bem similares, exceto no local onde está presente o defeito. Nesse local, a curvatura é muito maior que o restante, fortalecendo a ideia que ela seja um bom descritor de defeitos em sinais unidimensionais.




Figura 4.8: Curvatura de uma uma seção da correia com e sem defeito

A Figura 4.9 apresenta uma imagem do módulo da curvatura $|\kappa(j)|$ do sinal em diferentes instantes de tempo. Para cada instante de tempo t era obtido o sinal unidimensional do laser e sua curvatura era calculada. A Figura 4.9 mostra esses valores em módulo e ilustra que próximo ao defeito, os valores de curvatura são altos (cores próximas ao vermelho), enquanto que no restante da correia, os valores de curvatura são relativamente baixos (cores próximas ao azul).

Foi então proposto admitir os valores de alta curvatura (local das bordas do defeito) como *outliers*. Das técnicas de detecção de *outliers* citadas na Seção 3.3, umas utilizam o




Figura 4.9: Representação do módulo da curvatura em uma região da correia em vários instantes de tempo. Valores azuis representam curvaturas baixas, enquanto vermelhos apresentam curvaturas altas

conceito de média e desvio padrão (Escore Z e critério de Chauvenet), e outras utilizam conceitos de quartis (MAD e IQR). É difícil a comparação de tais técnicas, já que as mesmas não utilizam dos mesmos meios para a detecção dos *outliers*. O proposto então foi, utilizar as quatro técnicas e admitir como *outlier* os pontos que forem identificados por pelo menos três das quatro técnicas ao mesmo tempo. Isso torna a detecção mais robusta à ruídos, já que um *outlier* deve ser detectado por pelo menos duas técnicas (Escore Z $\wedge$ critério de Chauvenet, ou MAD $\wedge$ IQR) de um dos conceitos (média e desvio padrão, ou quartil), mais pelo menos uma das duas técnica do outro conceito.

Geralmente, em tratamento de sinais digitais, as observações ditas como *outliers* são retiradas da base de dados, e muitas vezes substituídas por outros valores interpolados entre os dados aceitáveis. Entretanto, para o presente trabalho não interessa a retirada dessas observações, e sim, a identificação da posição das mesmas no sinal de curvatura, admitindo esses pontos como pontos de defeito.

Detecção do defeito

Dependendo da velocidade e da forma do defeito, são capturados vários *frames* com informação do defeito no feixe de laser. Sendo assim, vários pontos são também identificados como *outliers* devido aos vários pontos de alta curvatura. Esses pontos são então alocados em uma “matriz de defeitos” com o mesmo formato da imagem (*linha $\times$ coluna*), na coluna equivalente ao índice em que foram identificados no sinal, porém, com o valor de linha atualizado em cada *frame* de acordo com a velocidade do transportador. Após a passagem completa do laser sobre o defeito, os pontos identificados e alocados nessa matriz apresentam um formato aproximado do defeito, definido como a reconstrução 2D do defeito.

A detecção de um defeito é feita através da identificação de pontos que fazem parte de um mesmo aglomerado local presente na matriz de defeitos. Essa identificação é feita




Figura 4.10: Detecção do defeito

pelo algoritmo DBSCAN, que tem a capacidade de agrupar pontos de acordo com a densidade espacial desses pontos. O algoritmo analisa a matriz de defeitos e agrupa os pontos próximos em um único defeito. Esse algoritmo foi escolhido pois não há como saber a quantidade de defeitos que poderiam estar presentes em uma mesma seção da correia, e porque o mesmo funciona de forma não-supervisionada. A Figura 4.10 mostra a marcação (*bounding box*) do resultado do agrupamento dos *outliers* em uma imagem da reconstrução *2D* de um defeito.

4.2.2 Reconstrução *3D*

Como uma imagem digital é composta por pixels, podem ser observados “degraus” no sinal unidimensional. Tais degraus são provenientes do processo de discretização do sinal (já que este é proveniente de uma imagem binarizada), representando uma forma menos contínua, como seria em um sinal analógico. Para remover esse efeito, o sinal foi filtrado no domínio da frequência, admitindo que esses degraus são equivalentes às frequências altas, e que a informação do sinal estaria presente somente nas frequências mais baixas. A filtragem ocorreu convoluindo o sinal no domínio da frequência com uma função gaussiana. Essa operação tem a capacidade de facilmente suavizar o sinal, preservando somente as frequências baixas, e eliminando as altas (ESTROZI *et al.*, 2003). A Figura 4.11 apresenta um sinal filtrado e um não filtrado no domínio da frequência.

O sinal unidimensional representa o perfil da superfície da correia naquele exato *frame*. Sendo assim, as deformações no sinal causadas por imperfeições na superfície da correia dariam noções de profundidade. Então, para a reconstrução *3D* do defeito foi considerado:




Figura 4.11: Comparação entre o sinal antes e depois da filtragem no domínio da frequência

- a amplitude do sinal é equivalente às coordenadas do eixo Z (profundidade);
- o comprimento do sinal é equivalente às coordenadas do eixo X (largura da correia);
- os *frames* são equivalentes às coordenadas do eixo Y (extensão da correia).

Capítulo 5

Resultados

Este Capítulo apresenta os resultados da detecção de defeitos, além de uma discussão sobre os resultados obtidos.

Todo o código foi desenvolvido utilizando a linguagem de programação *Python*, sistema operacional Ubuntu 16.04 64 bits, rodando em um computador com processador Intel® Core™ i7 – 6700HQ 2.60Hz $\times$ 8, com SSD 120Gb, 16Gb de RAM. Foi utilizada a biblioteca OpenCV, uma biblioteca *open source* desenvolvida originalmente pela *Intel* para uso acadêmico e comercial, escrita em *C/C++* otimizado com foco em eficiência computacional e aplicações de tempo-real.

Para o desenvolvimento desse projeto, foi necessário a criação de imagens com defeitos em correias, gerando assim uma base de dados com vídeos de escaneamento de correias utilizando laser. Foram construídos dois tipos de ambientes. O primeiro, um ambiente computadorizado simulando possíveis defeitos reais, como bolhas, erosões, e rasgos, tanto superficiais quanto transpassando toda a espessura da correia, em uma correia com a superfície perfeita e ruidosa. No segundo ambiente, foi utilizado pedaços de uma correia real, com a presença de defeitos reais já presentes na superfície da mesma, e outros inseridos manualmente. Nos dois casos foram gravados vídeos simulando o laser e o movimento da correia. A seguir segue uma descrição mais detalhada da base de dados sintética e dos dados reais.

5.1 Base de dados sintética

A base de dados sintética foi obtida por meio de uma simulação gerada com o software 3D Studio Max®, desenvolvido pela Microsoft Windows, gerando um vídeo de 30 segundos de duração, com uma taxa de 30 *frames* por segundo, de uma correia de 4500mm $\times$ 900mm $\times$ 20mm. A simulação teve como objetivo descobrir a melhor configuração entre laser, câmera e correia, bem como analisar a capacidade de detecção do algoritmo.

Para a análise das configurações entre câmera e laser, foram construídas várias simulações com as mesmas características de vídeo, como duração, tamanho e defeitos na

correia, etc, porém, mudando as posições tanto da câmera quanto do laser. O laser foi posicionado 30°, 45° e 60° graus em relação ao plano da correia, enquanto a câmera era posicionada perpendicularmente ao plano da mesma correia. Também foram construídas simulações com o inverso dessa configuração, com a câmera posicionada nos mesmos ângulos citados anteriormente em relação à correia, enquanto o laser era posicionado perpendicularmente. Para simular os defeitos na superfície da correia, foram inseridas irregularidades de vários tamanhos e formas, em vários ângulos de entrada no plano da correia, visíveis e invisíveis a olho nu. A Figura 5.1 apresenta os defeitos inseridos na correia, porém com um melhor contraste para melhor visualização dos defeitos, principalmente dos que seriam invisíveis a olho nu.




Figura 5.1: Irregularidades da simulação

A forma, tamanho e ângulo dos defeitos influenciam diretamente em como o laser será capturado pela câmera. A Figura 5.2 apresenta um instante de tempo t com o laser sobre duas imperfeições que ultrapassam a profundidade da correia na simulação, com um ângulo de entrada defasado (oblíquo e agudo, dependendo da posição do observador/câmera) ao plano da correia. Nesse caso, devido ao buraco, o laser possui uma forma descontínua, sendo que somente é possível sua visualização enquanto ele é refletido na correia.




Figura 5.2: Instante de tempo t na simulação

Esta seria a situação mais fácil para a detecção dos defeitos pelo algoritmo, visto que, neste caso, o sinal unidimensional teria degraus muito acentuados nos índices entre a presença e falta do laser, fazendo com que a curvatura nesses índices se tornem muito mais elevadas que no restante do sinal, facilitando assim a análise estatística de detecção




Figura 5.3: Sinal unidimensional proveniente do *frame* da Figura 5.2




Figura 5.4: Curvatura proveniente do sinal da Figura 5.3

de *outliers*. A Figura 5.3 apresenta o sinal unidimensional proveniente da Figura 5.2 e calculado de acordo com o Algoritmo 1, e a Figura 5.4 apresenta a curvatura calculada desse sinal.

A Figura 5.5 apresenta o resultado da detecção dos pontos de alta curvatura utilizando a análise estatística para detecção de *outliers*. Os pontos em amarelo na imagem representam a identificação feita pelo algoritmo, sendo possível observar que tais pontos estão posicionados exatamente nas bordas do defeito.



Figura 5.5: Pontos de defeitos identificados na correia

Como dito anteriormente, o caso de detecção de defeitos que transpassassem todo o perfil da correia seria o melhor caso para o método. Entretanto, este seria claramente o pior caso em um ambiente real, pois seria um defeito grave presente na correia. Porém,

mesmo em defeitos superficiais, o algoritmo também foi capaz de realizar a detecção dos pontos de defeito, como apresentado na Figura 5.6.




Figura 5.6: Pontos de defeitos identificados na correia em uma bolha superficial

Os pontos em amarelo são os pontos que descrevem imperfeições na superfície da correia, devido ao alto valor de curvatura que apresentam. Esses pontos são alocados em uma matriz de defeitos após cada *frame*, e após a passagem completa do laser sobre algum(s) defeito(s), essa matriz possuirá vários pontos capazes de descrever o formato *2D* desse(s) defeito(s) presente(s) na correia. Para a identificação desses pontos como um agrupamento de pontos (*cluster*) descrevendo somente um defeito por vez, foi utilizado o algoritmo DBSCAN. A Figura 5.7 apresenta a matriz de defeito, após a passagem do laser por vários defeitos presentes na correia simulada.



Figura 5.7: Matriz de defeitos

A Figura 5.8 apresenta o resultado do agrupamento usando o algoritmo DBSCAN na matriz de defeito. Pode ser observado que o mesmo conseguiu agrupar os defeitos separadamente, mesmo que não tenha sido inserida a informação da quantidade de defeitos presentes na matriz. A entrada do algoritmo foi um vetor composto pelos índices (linha $\times$ coluna) dos pontos na matriz de defeito. Entretanto, tais dados de entrada são compostos por valores inteiros e grandes, já que representavam índices de pixels em uma imagem. Sendo assim, eles foram normalizados para uma melhor sintonização dos parâmetros do algoritmo. Entretanto, como os parâmetros *default* do DBSCAN já conse-

guiram identificar cada defeito separadamente, foi então utilizado esses parâmetros, que são $r = 0.1$ e $n = 10$.




Figura 5.8: Matriz de defeitos com identificação individual de cada defeito

Foram realizados diversos experimentos durante o projeto. Foram eles:

- determinação da melhor configuração entre câmera, laser e correia;
- detecção de defeitos na simulação e comparação com a identificação perfeita do defeito (*Ground Truth*);
- comparação dos resultados obtidos com o método e marcações humanas;
- resultados de detecção de defeitos em simulações com adição de ruídos.

Para avaliação do método apresentado, foi proposto utilizar três métricas bastante comuns para comparação de resultados na área de reconhecimento de padrões. São elas: Precisão (*Precision*), Revocação (*Recall*), e Medida F1 (*F1 Score*).

Precisão e revocação são métricas utilizadas para medidas de relevância (PERRUCHET e PEEREMAN, 2004), já que apontam a quantidade de dados obtidos que são relevantes (precisão), bem como a quantidade de dados relevantes obtidos (revocação). As Equações 5.1 e 5.2 descrevem as métricas de precisão e revocação, respectivamente

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (5.1)$$

$$\text{Revocação} = \frac{VP}{VP + FN} \quad (5.2)$$

sendo: VP , verdadeiro positivo; FP , falso positivo; e FN , falso negativo.

Utilizando a precisão e a revocação, pode-se calcular a Medida F1 (SASAKI *et al.*, 2007) que representa o balanço entre as duas medidas, ou uma semelhança espacial entre amostras, como descrito na Equação 5.3.

$$F1 = 2 * \frac{\text{Precisão} * \text{Revocação}}{\text{Precisão} + \text{Revocação}} \quad (5.3)$$

Após o primeiro experimento, foi obtido que a melhor configuração seria com o laser em 30° de defasagem em relação à câmera (60° em relação à correia). A Tabela 5.1 apresenta o resultado médio para os valores das métricas para cada configuração entre laser e câmera, utilizando os mesmos parâmetros do DBSCAN.

Tabela 5.1: Resultados médio das detecção de defeitos pelo método proposto com diferentes configurações

Laser 90°			
Câmera	Precisão	Revocação	F1
30°	0,88	0,91	0,89
45°	0,87	0,89	0,88
60°	0,86	0,90	0,88
Câmera 90°			
Laser	Precisão	Revocação	F1
30°	0,92	0,94	0,93
45°	0,90	0,93	0,91
60°	0,89	0,92	0,90

Um fato a ser analisado com a configuração do laser em 90° à correia, é que como a câmera captura uma imagem “defasada” ao plano da correia, uma transformação afim deveria ser realizada, descrevendo então um formato dos defeitos mais fiel ao real, de modo que um observador pudesse ter uma melhor perspectiva de fato da correia. A Figura 5.9 apresenta a imagem capturada por uma câmera defasada à 60° da correia.




Figura 5.9: Imagem de uma câmera à 60° da correia

Com a melhor configuração, o método foi também comparado com a detecção de defeitos feita por humanos. Para essa análise, foi pedido para que 30 pessoas marcassem um retângulo (*bounding box*) que melhor limitasse cada defeito que encontrassem na correia em um vídeo gerado com as mesmas características utilizadas no vídeo simulado,

porém, sem a presença do laser. Essa identificação seria também comparado com o *ground truth* através das mesmas métricas utilizadas na avaliação do algoritmo, utilizando dos valores médios encontrados pelos humanos.

A Tabela 5.2 apresenta a comparação entre o resultado da detecção obtida pelo algoritmo e pelos humanos. A precisão média do algoritmo foi de 92% contra 70%, o que indica que o algoritmo conseguiu capturar uma maior razão de informações relevantes (razão entre verdadeiro positivo e falso positivo) que as pessoas.

A revocação média foi de 94% contra 97% o que já era esperado, já que humanos são capazes de facilmente identificar objetos através de forma, textura, e outros padrões. Assim, a informação relevante (objeto completo, ou nenhum falso negativo) capturada pelas pessoas foi maior. Apesar do resultado ter sido inferior ao humano, o algoritmo apresentou um resultado relevante (94%), sendo que a literatura mostra que bons valores para precisão e revocação são valores superiores à 87%. A medida F1 para o algoritmo foi 91% contra 81% das pessoas, indicando que o algoritmo conseguiu discriminar melhor os defeitos, ou ter uma melhor semelhança espacial com o que seria uma detecção perfeita do defeito. A Figura 5.10a apresenta o resultado da detecção do algoritmo, enquanto a Figura 5.10b apresenta o resultado obtido pelos humanos, onde a cor verde representa o verdadeiro positivo, azul o falso negativo, e o vermelho o falso positivo.

Tabela 5.2: Resultados da detecção de defeitos pelo método proposto e por humanos

Defeito	Algoritmo			Humanos		
	Precisão	Revocação	F1	Precisão	Revocação	F1
1	0,97	0,91	0,94	0,64	1,00	0,78
2	0,97	0,94	0,96	0,73	1,00	0,84
3	0,86	0,98	0,92	0,66	1,00	0,79
4	0,92	1,00	0,96	0,59	1,00	0,74
5	0,99	0,98	0,98	0,52	0,77	0,62
6	0,93	0,89	0,91	0,57	1,00	0,72
7	0,93	0,97	0,95	0,61	1,00	0,75
8	0,76	0,93	0,84	0,67	1,00	0,80
9	0,92	0,93	0,92	0,60	1,00	0,75
10	0,99	0,89	0,94	0,86	0,85	0,85
11	0,93	0,99	0,96	0,56	1,00	0,71
12	0,90	0,92	0,90	0,73	1,00	0,84
13	0,80	0,80	0,80	0,57	1,00	0,72
14	0,86	0,98	0,92	0,97	0,99	0,97
15	0,98	0,98	0,98	0,98	0,96	0,96
16	0,97	0,95	0,95	0,96	1,00	0,97
média	0,92	0,94	0,93	0,70	0,97	0,81
Algoritmo: 1,00 / 1,00 VP				Humanos: 0,93 / 0,62 VP		

A Medida F1 também permite a comparação da detecção como um todo. A literatura diz que valores acima de 70% significam detecção positiva (RADAU *et al.*, 2009),




Figura 5.10: Detecção do algoritmo e detecção dos humanos

ou seja, um verdadeiro positivo. Sendo assim, temos que a detecção do método no ambiente simulado foi de 100%, já que todos os resultados obtidos foram superiores à 70%, maior que o resultado humano, que foi de 93%, devido à um falso negativo (62%). Para precisão e revocação no entanto, valores positivos seriam valores superiores acima de 60% (GENÇTAV *et al.*, 2012), mostrando mais uma vez que o algoritmo conseguiu atingir 100% de detecção positiva.

Para confirmar a capacidade de detecção do método e sua robustez, foi proposto também testá-lo em simulações onde a correia construída tivesse uma superfície ruidosa, retirando assim a forma de uma linha de laser perfeita nos locais da correia onde não se encontram defeitos, o que simula a condição real de uma correia transportadora. A inserção de ruído na correia foi feita com imperfeições de $1mm$, $3mm$, $5mm$, e $10mm$ de altura/profundidade em relação à correia perfeitamente reta, e a identificação dos defeitos foi feita utilizando os mesmos parâmetros do algoritmo DBSCAN para a identificação dos defeitos na correia sem ruídos.

Em uma situação real de detecção de defeitos, é mais importante o fato de conseguir detectar o defeito de fato, do que com qual precisão esse defeito foi identificado, desde que tenha sido. Também, em um ambiente com ruídos, o sinal unidimensional tende a se tornar menos uniforme, o que torna a curvatura também ruidosa. Sendo assim, a identificação de mais pontos que descrevam o defeito pode facilitar o agrupamento do algoritmo DBSCAN. Para a obtenção de mais pontos, foi proposto utilizar o sinal filtrado no domínio da frequência para o cálculo de curvatura. A Figura 5.11 apresenta um instante de tempo t em uma simulação com a presença de ruído, enquanto a Figura 5.12 mostra a curvatura do sinal obtido, filtrado e não filtrado.

Como pode ser visto na seção com zoom, o sinal filtrado apresenta mais pontos que seriam identificados como *outliers* que um sinal não filtrado. Isso ajudaria no caso da




Figura 5.11: Instante de tempo t em uma correia com ruído




Figura 5.12: Curvatura de um sinal filtrado e não filtrado

identificação do defeito pelo algoritmo DBSCAN, visto que o mesmo agrupa pontos de acordo com a densidade local. Além disso, a operação de filtragem de frequências altas no domínio da frequência tem a capacidade de suavizar o sinal, mantendo a informação mais relevante presente. Sendo assim, pode-se esperar também que essa operação suavize os ruídos no sinal unidimensional causados pelos ruídos da correia, como também é mostrado na Figura 5.12. Ademais, a qualidade da filtragem está diretamente ligada a função de filtragem (no caso do presente trabalho, uma função Gaussiana). Sendo assim, um parâmetro a ser analisado neste caso é o σ da função gaussiana.

Para avaliar o resultado do método no ambiente ruidoso, foi proposto um conjunto de experimentos onde o algoritmo foi executado nas simulações com cada uma das intensidades de ruídos ($1mm$, $3mm$, $5mm$, e $10mm$), alterando-se o valor de σ para 6%, 9%, 12%, 15%, 18%, e 21% do tamanho do sinal unidimensional. A Figura 5.13 apresenta o resultado da precisão média. Pode ser observado na Figura 5.13 que mesmo com ruídos, o método ainda se mostrou capaz de identificar com precisão os defeitos para vários valores (valores acima de 60%, tanto de intensidade de ruído quanto de σ , ou seja, mesmo no ambiente ruidoso, o método ainda conseguiu capturar detectar defeitos de uma forma efetiva.

Os valores médios obtidos para revocação são apresentados na Figura 5.14. Pode-se observar que, assim como na precisão, foram obtidos valores superiores à 60%, indicando uma baixa taxa de falsos negativos, ou seja, identificação da maior porção do defeito, ou




Figura 5.13: Valores médios de precisão para diferentes valores de ruídos e σ

se não, o defeito completo.




Figura 5.14: Valores médios de revocação para diferentes valores de ruídos e σ

A Figura 5.15 apresenta os valores médios obtidos para a medida $F1$. Por também ser uma média harmônica entre precisão e revocação, os resultados apresentados na Figura 5.15 confirmam que o método é, de fato, capaz de detectar defeitos no ambiente ruidoso, devido à razão relevante entre as medidas de precisão e revocação.

Uma análise interessante é que, aparentemente, com o aumento da intensidade do ruído, os resultados das métricas parecem melhorar. Isso se dá pelo fato de que com uma intensidade de ruído menor (*e.g.*: 1mm), o formato da correia se parece mais com a correia perfeita. Isso influencia diretamente no formato do laser, que por sua vez influencia diretamente na detecção de *outliers* na curvatura. Quanto mais parecido com o formato perfeito do laser, mais fácil um ponto será identificado como *outlier* se ele se distanciar desse formato (devido ao ruído), podendo então serem identificados falsos positivos com mais facilidade. Por outro lado, quanto maior a quantidade de ruídos, mais curvas o sinal terá, fazendo com que a taxa de falsos positivos caia, já que o “padrão” do sinal se tornou, de certa forma, irregular. Entretanto, esse mesmo efeito pode acarretar na diminuição da identificação de *outliers* verdadeiros (verdadeiro positivo), obtendo-se então, falsos negativos. A Figura 5.16 apresenta a forma das curvatura para cada ruído em um mesmo




Figura 5.15: Valores médios de $F1$ para diferentes valores de ruídos e σ

instante de tempo t , onde não há presença de defeitos.




Figura 5.16: Curvaturas com várias intensidades de ruídos em uma seção da correia sem defeito

Essa situação poderia ser resolvida, por exemplo, com a análise prévia dos valores de curvatura obtidos ao longo dos vídeos como um pré-treinamento. Analisando esses valores, podemos identificar valores extremamente baixos, que provavelmente seriam causados somente por ruídos. Neste caso, um limite fixo pode ajudar na filtragem, fazendo com que um *outlier* seja reconhecido somente se for maior que esse limite.

A discussão levantada anteriormente é de extrema importância, pois apresenta uma característica do comportamento do método em um ambiente ruidoso, ambiente este, que pode ser considerado como um ambiente real. Entretanto, a Figura 5.17 mostra mais uma vez que a curvatura do sinal unidimensional pode, de fato, caracterizar a presença de um defeito, pois mesmo no ambiente ruidoso, a curvatura apresentada nos índices relativos às bordas do defeito continuam tendo uma amplitude muito maior que no restante do sinal, mesmo com a presença de ruídos.

Outra análise que pode ser feita através dos resultados no ambiente ruidoso é sobre a capacidade de detecção em determinadas amplitudes de defeitos. Foram inseridos ruídos com amplitudes de vários tamanhos sobre a correia. Os resultados apresentados nas




Figura 5.17: Curvaturas com várias intensidades de ruídos em uma seção da correia com defeito

Figuras 5.13, 5.14, e 5.15 mostram que o algoritmo seria capaz de identificar defeitos com dimensões variando de $1mm$ à $10mm$ de profundidade/altura. Defeitos em que suas dimensões sejam abaixo de $1mm$ ainda devem ser investigados para a obtenção da performance do método, ao passo que, defeitos com dimensões maiores que $10mm$, seriam provavelmente identificados.

Ademais, uma investigação mais apurada para a sintonização dos parâmetros relevantes para o método (σ — filtragem gaussiana no domínio da frequência —, r e n — algoritmo de agrupamento DBSCAN) podem trazer melhorias substanciais ao método no ambiente ruidoso. No presente trabalho, a inserção de ruídos na correia foi feita para se analisar a performance do algoritmo em relação ao ambiente perfeito. Sendo assim, foram mantidos os mesmos parâmetros para o algoritmo DBSCAN, e, observando as Figuras 5.13, 5.14, e 5.15, pode-se dizer que o melhor valor de σ utilizado foi em torno de 12% do tamanho do sinal.

5.2 Simulação com correias reais

As simulações com correias reais foram realizadas com a mesma configuração utilizada para a metrificação do desempenho do algoritmo (câmera perpendicular à esteira, e laser defasado 30° graus do plano da câmera e 60° graus do plano da correia). Como os pedaços das correias utilizadas para o ambiente real apresentavam uma superfície uniforme, foi então utilizado o sinal não filtrado para o cálculo de curvatura. O laser utilizado foi um laser modular MXD1230, de comprimento de onda $650nm$ (espectro vermelho), de $5mW$. Para o método apresentado neste trabalho, pode ser feita a seguinte comparação:

- a resolução em largura do *frame* é equivalente à resolução do sinal;
- a resolução em altura do *frame* é equivalente à amplitude do sinal;

- a taxa de *frames* por segundo que a câmera consegue capturar é equivalente à taxa de aquisição do sinal.

Para o método, o mais importante é a taxa de aquisição (*fps*). Como um transportador de correia pode ter mais de quilômetros de extensão, a correia terá pelo menos o dobro, isso se o transportador não tiver equipamentos esticadores, e tendo em vista que transportadores de correia trabalham com uma velocidade consideravelmente alta (média de $4m/s$), se um transportador possuir uma correia de quatro quilômetros de extensão, uma câmera à uma taxa de aquisição de 30 *fps* e com um laser de um milímetro de espessura, a defasagem entre uma captura e outra seria em torno de $133mm$, tornando o sistema passível de detecção incompleta ou perda de defeitos. Para compensar essa limitação, foi proposto a utilização da câmera industrial USB 3.0 XIMEA xiQ MQ022CG-CM monocromática, ultra-compacta com resolução de +500 *fps* em resolução VGA (*Video Graphics Array*) ou menor. A ROI utilizada foi 544×148 , o que possibilitaria um *fps* de +700, fazendo a defasagem entre capturas permanecer em torno de $5mm$, consideravelmente menor que uma taxa de aquisição normal de 30 *fps*.

Essa taxa de aquisição traz consigo uma limitação de hardware e software, já que é extremamente custoso processar tamanha quantidade de dados em tão curto espaço de tempo. Sendo assim, não foi utilizado essa taxa de aquisição, visto também que a correia utilizada na simulação foi movimentada manualmente, tendo então, uma velocidade baixa. Também, como a câmera se trata de uma câmera monocromática, o experimento foi realizado em um ambiente fechado e com pouca luz, para que houvesse um alto contraste entre laser e correia. Isso simularia a extração do canal vermelho em uma imagem RGB.

Para o ambiente real, foram utilizadas duas correias de materiais diferentes, com diferentes defeitos. O primeiro, um rasgo originalmente presente na correia, apresentado na Figura 5.18. A Figura 5.19 apresenta uma sequência de imagens durante a passagem do rasgo da Figura 5.18 sobre o laser.

Após a passagem de todo o rasgo pelo laser, a matriz de defeitos possui então todos os pontos capazes de descrever o formato $2D$ do defeito, sendo também capaz de identificar o mesmo através do agrupamento dos pontos. A Figura 5.20a apresenta a matriz de defeitos com os pontos descritivos do defeito (reconstrução $2D$ do defeito), enquanto a Figura 5.20b apresenta a detecção de fato.

O presente trabalho também propôs uma representação $3D$ do defeito na correia. O resultado da representação $3D$ da seção onde se encontra o rasgo é apresentado na Figura 5.21. Como a reconstrução $3D$ da seção da correia se faz através do uso do sinal filtrado no domínio da frequência, e como as Figuras 5.13, 5.14, e 5.15 apresentam uma média de melhor resultado para $\sigma = 12\%$ do tamanho do sinal, foi usado esse valor para a função de filtragem.

O segundo defeito foi uma erosão superficial inserida manualmente em outro pedaço de correia, como apresentado na Figura 5.22. Da mesma forma que no defeito da Figura 5.18,



Figura 5.18: Rasgo

após a passagem completa da erosão pelo laser, foram inseridos na matriz de defeitos os pontos descritores do defeito, possibilitando tanto a representação $2D$, quanto a detecção do defeito, como apresentado nas Figuras 5.23a e 5.23b.

Também, da mesma forma como anteriormente, a representação $3D$ da seção onde se encontra a erosão é apresentada na Figura 5.24.

É importante salientar que para medições mais precisas dos defeitos, como tamanho real, profundidade real, etc., devem ser considerados diversos parâmetros intrínsecos e extrínsecos, como a distância entre câmera e a correia, distância focal da câmera, velocidade do transportador, entre outras, no intuito de obter a representação mais acurada possível.

O conhecimento desses parâmetros podem adicionar ao método a capacidade de descrever espacialmente, tanto em duas e três dimensões, a realidade de cada defeito individualmente, tornando-o capaz de indicar uma possível gravidade, tomando em consideração que defeitos com grandes dimensões, tanto de largura $\times$ comprimento quanto de profundidade, são potencialmente perigosos para o funcionamento da correia. Tal análise não necessitaria de uma “inteligência” embarcada no método, como algoritmos de aprendizado de máquinas, pois como a identificação do defeito vem de características espaciais (aglomeração de pontos espacialmente espaçados), tendo-se as características (parâmetros intrínsecos e extrínsecos citados anteriormente) que transformam a medida de pixel para unidade de medida (mm, cm, etc.), um limiar previamente definido já seria capaz de gerar um alerta sobre a condição de um defeito identificado.





Figura 5.19: Sequência de imagens do defeito passando pelo laser



(a) Matriz de defeito de rasgo

(b) Detecção de rasgo real

Figura 5.20: Matriz de defeitos e detecção de rasgo






Figura 5.21: Representação 3D da seção do rasgo



Figura 5.22: Erosão



(a) Matriz de defeito de erosão



(b) Detecção de uma erosão real

Figura 5.23: Matriz de defeitos e detecção de erosão




Figura 5.24: representação 3D da seção da erosão

Capítulo 6

Conclusões e Trabalhos Futuros

O presente trabalho propôs um método de visão computacional para detecção de defeitos em correias transportadoras utilizando laser. Foram investigados dois tipos de imagens: simuladas e reais. Nas simulações investigamos a melhor configuração entre câmera, laser, e correia, bem como a capacidade de detecção do método. Também foram geradas simulações ruidosas para demonstrar a robustez do método proposto. No ambiente real, foram avaliados dois tipos diferentes de defeitos, utilizando a melhor configuração de parâmetros para o método. Além de resultados significantes relativo ao que foi proposto, o método também apresentou um diferente tipo de abordagem para tratamento de *outliers* e algoritmos de agrupamento.

O método proposto conseguiu atingir um bom resultado no ambiente simulado, com 92% de precisão média, 94% de revocação média, e medida F1 média de 91% indicando que o algoritmo atingiu uma boa performance na identificação dos defeitos alvos. Também, para as simulações ruidosas, o algoritmo atingiu médias acima de 70% nas mesmas métricas, indicando ainda um bom resultado para identificação de defeitos mesmo na presença de ruídos de diversas intensidades. Deve-se ressaltar que no ambiente ruidoso, foram utilizados os mesmos parâmetros usados para o algoritmo DBSCAN no ambiente sem ruídos, bem como o sinal filtrado no domínio da frequência. No ambiente real, o método conseguiu identificar os defeitos alvos, bem como reconstruir uma aproximação 3D das seções da correia onde os defeitos estavam presentes.

A performance do algoritmo em ambos os ambientes (simulado e real) mostra que o método proposto tem, de fato, potencial para identificação de defeitos no ambiente real de uma mineradora, ou ainda, em qualquer planta que utilize de sistemas de transportadores de correias. Ademais, é grande a contribuição do método para a indústria visto que, a proposta se trata de um monitoramento remoto, capaz de apresentar defeitos à equipe de manutenção, sem que haja a necessidade de um operador estar presente no local do transportador, ambiente extremamente perigoso e propício à acidentes, oferecendo assim, uma maneira segura e não invasiva de monitoramento da correia.

Para trabalhos futuros, pretende-se realizar a montagem do equipamento em campo

em uma situação real e construir uma base de dados com um maior número e variabilidade de defeitos. Essa nova base de dados permitirá uma investigação exhaustiva da aplicabilidade em situações reais. Também, uma investigação mais profunda sobre os parâmetros utilizados (filtragem no domínio da frequência e algoritmo DBSCAN) pelo método pode melhorar substancialmente a detecção de defeitos em ambientes reais. Ademais, deve-se também ser investigado os parâmetros que possibilitariam as reconstruções, tanto em $2D$ quanto em $3D$, em unidades de medidas, como mm, cm, etc.

Outro ponto a ser investigado diz respeito à execução em tempo real ou não, uma vez que a velocidade da correia implica em uma limitação de “x” mm para a precisão da detecção e, que essa precisão pode variar de acordo com a aquisição da câmera utilizada. Todas essas melhorias seriam de grande valia, pois uma vez detectado o defeito, poderia ser desenvolvido modelos capazes de reconhecer tipos de defeitos, e até mesmo aprender como um defeito já identificado evolui com o tempo. Metodologias de aprendizagem de máquinas podem ser incluídas na investigação da evolução dos defeitos de tal modo que permitam a construção de modelos preditivos que auxiliem na manutenção.

Referências Bibliográficas

- AYDIN, I., KARAKOSE, M., AKIN, E. “A new contactless fault diagnosis approach for pantograph-catenary system using pattern recognition and image processing methods”, *Advances in Electrical and Computer Engineering*, v. 14, n. 3, pp. 79–88, 2014.
- BROSNAN, T., SUN, D.-W. “Improving quality inspection of food products by computer vision—a review”, *Journal of food engineering*, v. 61, n. 1, pp. 3–16, 2004.
- BUTTERWORTH, S. “On the theory of filter amplifiers”, *Wireless Engineer*, v. 7, n. 6, pp. 536–541, 1930.
- CANNY, J. “A computational approach to edge detection”, *IEEE Transactions on pattern analysis and machine intelligence*, , n. 6, pp. 679–698, 1986.
- ELAD, M. “On the origin of the bilateral filter and ways to improve it”, *IEEE Transactions on image processing*, v. 11, n. 10, pp. 1141–1151, 2002.
- ELBEHIERY, H., HEFNAWY, A., ELEWA, M. “Surface Defects Detection for Ceramic Tiles Using Image Processing and Morphological Techniques”. Em: *WEC* (5), pp. 158–162, 2005.
- ELMASRY, G., CUBERO, S., MOLTÓ, E., et al.. “In-line sorting of irregular potatoes by using automated computer-based machine vision system”, *Journal of Food Engineering*, v. 112, n. 1-2, pp. 60–68, 2012a.
- ELMASRY, G., KAMRUZZAMAN, M., SUN, D.-W., et al.. “Principles and applications of hyperspectral imaging in quality evaluation of agro-food products: a review”, *Critical reviews in food science and nutrition*, v. 52, n. 11, pp. 999–1023, 2012b.
- ESTER, M., KRIEGEL, H.-P., SANDER, J., et al.. “A density-based algorithm for discovering clusters in large spatial databases with noise.” Em: *Kdd*, v. 96, pp. 226–231, 1996.
- ESTROZI, L. F., RIOS-FILHO, L. G., BIANCHI, A. G. C., et al.. “1D and 2D Fourier-based approaches to numeric curvature estimation and their comparative performance assessment”, *Digital signal processing*, v. 13, n. 1, pp. 172–197, 2003.

- FEDORKO, G., MOLNAR, V., MARASOVA, D., et al.. “Failure analysis of belt conveyor damage caused by the falling material. Part I: Experimental measurements and regression models”, *Engineering failure analysis*, v. 36, pp. 30–38, 2014.
- FEDORKO, G., MOLNÁR, V., MICHALIK, P., et al.. “Extension of inner structures of textile rubber conveyor belt–Failure analysis”, *Engineering Failure Analysis*, v. 70, pp. 22–30, 2016.
- FEDORKO, G., MOLNÁR, V., DOVICA, M., et al.. “Analysis of defects in carcass of rubber–textile conveyor belts using metrotomography”, *Journal of Industrial Textiles*, v. 47, n. 7, pp. 1812–1829, 2018.
- FROMME, C., STAGER, D., PILARSKI, T., et al.. “Conveyor belt inspection system and method”. jan. 24 2006. US Patent 6,988,610.
- FU HOU, Y., RUI MENG, Q. “Dynamic characteristics of conveyor belts”, *Journal of China University of Mining and Technology*, v. 18, n. 4, pp. 629 – 633, 2008. ISSN: 1006-1266.
- GENÇTAV, A., AKSOY, S., ÖNDER, S. “Unsupervised segmentation and classification of cervical cell images”, *Pattern recognition*, v. 45, n. 12, pp. 4151–4168, 2012.
- GRUBBS, F. E. “Procedures for detecting outlying observations in samples”, *Technometrics*, v. 11, n. 1, pp. 1–21, 1969.
- GUAN, Y., ZHANG, J., SHANG, Y., et al.. “Embedded sensor of forecast conveyer belt breaks”. Em: *Fuzzy Systems and Knowledge Discovery, 2008. FSKD’08. Fifth International Conference on*, v. 5, pp. 617–621. IEEE, 2008.
- HADDAD, R. A., AKANSU, A. N. “A class of fast Gaussian binomial filters for speech and image processing”, *IEEE Transactions on Signal Processing*, v. 39, n. 3, pp. 723–727, 1991.
- HAMZELOO, E., MASSINAEI, M., MEHRSHAD, N. “Estimation of particle size distribution on an industrial conveyor belt using image analysis and neural networks”, *Powder Technology*, v. 261, pp. 185 – 190, 2014. ISSN: 0032-5910.
- HARTIGAN, J. A., WONG, M. A. “Algorithm AS 136: A k-means clustering algorithm”, *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, v. 28, n. 1, pp. 100–108, 1979.
- HODGE, V., AUSTIN, J. “A survey of outlier detection methodologies”, *Artificial intelligence review*, v. 22, n. 2, pp. 85–126, 2004.

- JEMWA, G. T., ALDRICH, C. “Estimating size fraction categories of coal particles on conveyor belts using image texture modeling methods”, *Expert Systems with Applications*, v. 39, n. 9, pp. 7947 – 7960, 2012. ISSN: 0957-4174.
- JEONG, J., PARK, E., HAN, W. S., et al.. “Identifying outliers of non-Gaussian groundwater state data based on ensemble estimation for long-term trends”, *Journal of Hydrology*, v. 548, n. Supplement C, pp. 135 – 144, 2017.
- KANUNGO, T., MOUNT, D. M., NETANYAHU, N. S., et al.. “An efficient k-means clustering algorithm: Analysis and implementation”, *IEEE transactions on pattern analysis and machine intelligence*, v. 24, n. 7, pp. 881–892, 2002.
- KURIHARA, T., OKUDA, K., YOSHIMOTO, M. “Longitudinal rip detection method and device for conveyor belt”. out. 19 2006. Japan Patent 6,282,319.
- LEROY, A. M., ROUSSEEUW, P. J. “Robust regression and outlier detection”, *Wiley Series in Probability and Mathematical Statistics, New York: Wiley, 1987*, 1987.
- LEYS, C., LEY, C., KLEIN, O., et al.. “Detecting outliers: Do not use standard deviation around the mean, use absolute deviation around the median”, *Journal of Experimental Social Psychology*, v. 49, n. 4, pp. 764–766, 2013.
- LI, J., MIAO, C. “The conveyor belt longitudinal tear on-line detection based on improved SSR algorithm”, *Optik-International Journal for Light and Electron Optics*, v. 127, n. 19, pp. 8002–8010, 2016.
- LI, M., DU, B., ZHU, M., et al.. “Intelligent detection system for mine belt tearing based on machine vision”. Em: *Control and Decision Conference (CCDC), 2011 Chinese*, pp. 1250–1253. IEEE, 2011.
- LIN, L., SHERMAN, P. D. “Cleaning data the Chauvenet way”, *The Proceedings of the SouthEast SAS Users Group, SESUG Proceedings, Paper SA11*, 2007.
- LLOYD, S. “Least squares quantization in PCM”, *IEEE transactions on information theory*, v. 28, n. 2, pp. 129–137, 1982.
- LOCHT, P., THOMSEN, K., MIKKELSEN, P. “Full color image analysis as a tool for quality control and process development in the food industry”. Em: *1997 ASAE Annual International Meeting Technical Papers, Paper*, n. 973006, 1997.
- MACQUEEN, J., OTHERS. “Some methods for classification and analysis of multivariate observations”. Em: *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, v. 1, pp. 281–297. Oakland, CA, USA, 1967.

- MAOHUA, L. Q. W. “DEVELOPMENT AND PROSPECT OF REAL TIME FRUIT GRADING TECHNIQUE BASED ON COMPUTER VISION [J]”, *TRANSACTIONS OF THE CHINESE SOCIETY OF AGRICULTURAL MACHINERY*, v. 6, 1999.
- MEGAHED, F. M., CAMELIO, J. A. “Real-time fault detection in manufacturing environments using face recognition techniques”, *Journal of Intelligent Manufacturing*, v. 23, n. 3, pp. 393–408, 2012.
- MONTGOMERY, D. C., RUNGER, G. C., CALADO, V. *Estatística Aplicada E Probabilidade Para Engenheiros*. Grupo Gen-LTC, 2000.
- NASCIMENTO, R., CARVALHO, R., DELABRIDA, S., et al.. “An Integrated Inspection System for Belt Conveyor Rollers”. Em: *19th International Conference on Enterprise Information Systems (ICEIS 2017)*, v. 2, pp. 190–200, 2017.
- NICOLAY, T., TREIB, A., BLUM, A. “RF identification in the use of belt rip detection [mining product belt haulage]”. Em: *Sensors, 2004. Proceedings of IEEE*, pp. 333–336. IEEE, 2004.
- OTSU, N. “A threshold selection method from gray-level histograms”, *IEEE transactions on systems, man, and cybernetics*, v. 9, n. 1, pp. 62–66, 1979.
- PANG, Y., LODEWIJKS, G. “A novel embedded conductive detection system for intelligent conveyor belt monitoring”. Em: *Service Operations and Logistics, and Informatics, 2006. SOLI'06. IEEE International Conference on*, pp. 803–808. IEEE, 2006.
- PANG, Y., LODEWIJKS, G. “Large-scale conveyor belt system maintenance decision-making by using fuzzy causal modeling”. Em: *Intelligent Transportation Systems, 2005. Proceedings. 2005 IEEE*, pp. 563–567. IEEE, 2005.
- PARK, B., CHEN, Y., NGUYEN, M., et al.. “Characterizing multispectral images of tumorous, bruised, skin-torn, and wholesome poultry carcasses”, *Transactions of the ASAE*, v. 39, n. 5, pp. 1933–1941, 1996.
- PENG, X. “A novel image-based method for conveyor belt rip detection”. Em: *Signal Processing, Communication and Computing (ICSPCC), 2013 IEEE International Conference on*, pp. 1–4. IEEE, 2013.
- PERRUCHET, P., PEEREMAN, R. “The exploitation of distributional information in syllable processing”, *Journal of Neurolinguistics*, v. 17, n. 2-3, pp. 97–119, 2004.

- QIAO, T., LIU, W., PANG, Y., et al.. “Research on visible light and infrared vision real-time detection system for conveyor belt longitudinal tear”, *IET Science, Measurement & Technology*, v. 10, n. 6, pp. 577–584, 2016.
- QIAO, T., LI, X., PANG, Y., et al.. “Research on conditional characteristics vision real-time detection system for conveyor belt longitudinal tear”, *IET Science, Measurement & Technology*, v. 11, n. 7, pp. 955–960, 2017.
- RADAU, P., LU, Y., CONNELLY, K., et al.. “Evaluation Framework for Algorithms Segmenting Short Axis Cardiac MRI.” 07 2009.
- RAZMJOOY, N., MOUSAVI, B. S., SOLEYMANI, F. “A real-time mathematical computer method for potato inspection using machine vision”, *Computers & Mathematics with Applications*, v. 63, n. 1, pp. 268–279, 2012.
- SASAKI, Y., OTHERS. “The truth of the F-measure”, *Teach Tutor mater*, v. 1, n. 5, pp. 1–5, 2007.
- SONKA, M., HLAVAC, V., BOYLE, R. *Image processing, analysis, and machine vision*. Cengage Learning, 2014.
- SUN, D.-W. “Inspecting pizza topping percentage and distribution by a computer vision method”, *Journal of food engineering*, v. 44, n. 4, pp. 245–249, 2000.
- WANG, H.-H., SUN, D.-W. “Evaluation of the functional properties of cheddar cheese using a computer vision method”, *Journal of Food Engineering*, v. 49, n. 1, pp. 49–53, 2001.
- XIANGUO, L., LIFANG, S., ZIXU, M., et al.. “Laser-based on-line machine vision detection for longitudinal rip of conveyor belt”, *Optik*, v. 168, pp. 360–369, 2018.
- YANG, Y., MIAO, C., LI, X., et al.. “On-line conveyor belts inspection based on machine vision”, *Optik-International Journal for Light and Electron Optics*, v. 125, n. 19, pp. 5803–5807, 2014.
- YANG, Y., ZHAO, Y., MIAO, C., et al.. “On-line longitudinal rip detection of conveyor belts based on machine vision”. Em: *Signal and Image Processing (ICSIP), IEEE International Conference on*, pp. 315–318. IEEE, 2016.
- ZADEH, L. A. “Theory of filtering”, *Journal of the Society for Industrial and Applied Mathematics*, v. 1, n. 1, pp. 35–51, 1953.

ZHANG, B., HUANG, W., LI, J., et al.. “Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review”, *Food Research International*, v. 62, pp. 326–343, 2014.