



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**

Dissertação

**Processamento Digital de Imagens para a Identificação
Automática de Falhas em Rolos dos Transportadores
de Correias**

Jose Regivaldo de Carvalho Junior

**Ouro Preto
Minas Gerais, Brasil
Abril de 2018**

Jose Regivaldo de Carvalho Junior

Processamento Digital de Imagens para a Identificação
Automática de Falhas em Rolos dos Transportadores
de Correias

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.

Orientador: Prof. Dr. Luis Guilherme Uzeda Garcia.

Co-orientador: Prof. Dr. Andrea Gomes Campos Bianchi.

C331p

Carvalho Júnior, José Regivaldo de.

Processamento digital de imagens para a identificação automática de falhas em rolos dos transportadores de correias [manuscrito] / José Regivaldo de Carvalho Júnior. – 2018.

xxi, 109f. : il., color., graf., tab., mapas.

Orientador: Prof. P.H.D. Luís Guilherme Uzeda Garcia.

Co-orientadora: D.Sc. Andrea Gomes Campos Bianchi.

Dissertação (Mestrado) – Universidade Federal de Ouro Preto/ Instituto Tecnológico Vale. Escola de Minas. Programa de Pós Graduação em Instrumentação, Controle e Automação de Processos de Mineração.

Área de concentração: Engenharia de Controle e Automação de Processos Mineraiis.

1. Aeronave não tripulada. 2. Termografia. 3. Processamento de Imagens. 4. Correias e transmissão por correia. I. Universidade Federal de Ouro Preto. II. Título.

CDU: 681.5:622.2

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

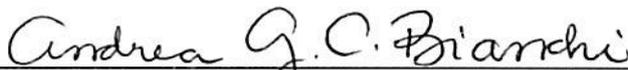
Processamento Digital de Imagens para a Identificação Automática de Falhas
em Rolos dos Transportadores de Correias

José Regivaldo de Carvalho Júnior

Dissertação defendida e aprovada em 19 de abril de 2018 pela banca
examinadora constituída pelos professores:



Ph.D. Luís Guilherme Uzeda Garcia
Orientador – Instituto Tecnológico Vale (ITV)



D.Sc. Andrea Gomes Campos Bianchi
Coorientadora - Universidade Federal de Ouro Preto (UFOP)



D.Sc. Saul Emanuel Delabrida Silva
Membro externo – Universidade Federal de Ouro Preto (UFOP)



D.Sc. Anderson Almeida Ferreira
Membro externo – Universidade Federal de Ouro Preto (UFOP)

*Dedico este trabalho aos meus pais e toda minha família que mesmo a distância são meu
Forte para enfrentar as adversidades da vida.*

Agradecimento

Agradeço aos meus orientadores Luís Uzeda e Andrea Bianchi que não mediram esforços e me direcionaram para "o caminho da pedras", muitas vezes em reuniões que varavam a noite. A todos os meus colegas de mestrado, pelos novos laços de amizade criados e tantos momentos compartilhados. Ao meus líderes na VALE, que me proveram todo o apoio necessário e além disso foram fonte constante de incentivo. A VALE, ITV e UFOP por me proporcionarem esta oportunidade única de desenvolvimento e acesso a novos horizontes de conhecimento. E a minha companheira Ellen Alves que me incentiva diariamente a seguir em frente.

“Once you stop learning, you start dying.”

Albert Einstein

Resumo

A inspeção dos rolos de um transportado de correias é uma tarefa crítica para a indústria da mineração, e vem sendo realizada da mesma maneira a mais de vinte anos, extremamente dependente da experiência das pessoas envolvidas e sujeita a avaliações subjetivas. No caso do Terminal Marítimo de Ponta da Madeira, as falhas em rolos são responsáveis por 325,5 horas de paradas indesejadas. O presente trabalho faz uma breve revisão bibliográfica dos transportadores de correia, passando pelos modos de falhas em rolamentos e meios de identificação dos defeitos e apresenta os princípios básicos da termografia infravermelho e processamento de imagens. É proposto então um método para a identificação dos defeitos com o uso de um drone com uma câmera térmica embarcada. O uso do drone possibilitará o acesso rápido à grande quantidade de rolos e a câmera térmica coletará os dados necessários para o processamento de imagens e identificação de defeitos. Foram então testados dois algoritmos para a identificação da região dos rolos, o Viola & Jones e o Canais de Características Agregados (ACF) de Piotr Dollar. Onde o último atingiu melhores resultados com taxas de falsos negativos de até 5%, demonstrando a robustez da abordagem para esse fator que é considerado crítico para a identificação dos rolos. Entre as contribuições em destaque estão os algoritmos para a identificação dos rolos, o banco de imagens nomeadas e a estruturação de um procedimento para a termografia infravermelho com uso de drones para a inspeção de rolos.

PALAVRAS-CHAVE: Drone, Termografia, Rolos, Processamento de Imagens.

Abstract

The task of assessing the rollers of a belt conveyor is critical for the mining industry and has been carried out in the same way for over twenty years, extremely dependent of the people involved and their experience, and so, exposed to subjective assessment. For example, on the Terminal Marítimo de Ponta da Madeira, rollers failures are responsible for 325,5 hours of unwanted stops. The present work makes a brief bibliographical review of the belt conveyors, also presents the failure modes in bearings, means to identify it and discourse the basics principles of infrared thermography and image processing. A method is then proposed for the identification of defective rollers with the use of a drone with an embedded thermal camera. The use of the drone will enable quick access to a large number of rolls and the thermal camera will collect the data needed for image processing and defect identification. Two algorithms, Viola & Jones and Piotr Dollar Aggregated Charge Channels (ACF), were then tested to recognize the rollers region. The ACF approach achieved better results with false negative rates up to 0,05, showing be robust to a factor considered critical for identification of the rollers. Among the contributions, the most relevant are the algorithms to identify the rollers, the dataset of labeled images and the procedure for the infrared thermography with the use of drones for the inspection of rollers.

KEY-WORDS: Drone, Thermography, Rollers, Image Processing.

Lista de ilustrações

Figura 1 – Vista satélite do TMPM. Fonte: Google Earth, 07/06/2016 – $2^{\circ}33'42.86''S$; $44^{\circ}21'31.38''O$	2
Figura 2 – Incêndio no TR-315K-36 do TMPM.	3
Figura 3 – Análise das principais falhas do TMPM em 2016: (a) Os TCs com 3244,8 horas paradas por falhas são os equipamentos que mais impactam a produção do porto. (b) Tabela com os percentuais acumulados de falhas os TCs representam 39,35% das falhas. (c) As paradas relacionadas à falhas em rolos estão na segunda colocação com 325,5 horas. Fonte: Sistema Informatizado de Produção Vale (GPV).	4
Figura 4 – Configuração básica de um transportador de correia. Fonte: Adaptado de (WOODCOCK; MASON, 2011)	9
Figura 5 – Configuração de um transportador mais complexo com 19 tambores e 1,37 km de extensão. Fonte: Documentos de Engenharia Vale	9
Figura 6 – Algumas falhas em rolos e suas consequências: (a) O tubo externo do rolo travado foi lixado pela correia até se tornar uma "navalha". (b) Correia danificada pelo rolo da Figura 6a. (f) Acúmulo de material no suporte do rolo central, com o endurecimento desse material o rolo ficará travado. (d) A quebra do rolamento provocou o deslocamento do tubo externo do rolo que cortou o seu próprio suporte. (e) A quebra do rolamento super-aqueceu o rolo e suas partes em borracha foram incendiadas. (f) Danos causados pelo rolo da Figura 6e	10
Figura 7 – Quadro de classificação dos tipos de monitoramento dos rolos. Fonte: (NASCIMENTO et al., 2017)	13
Figura 8 – Fluxo da identificação de falhas através do sinal de vibração. Fonte: Autor. Os sinais utilizados para montar o fluxo foram retirados de (MATHWORKS, 2015).	15
Figura 9 – Espectro Eletromagnético. Fonte: Figura foi adaptada de (COMMONS, 2016a) e o arquivo modificado está disponível em (COMMONS, 2017).	19
Figura 10 – Duas representações da mesma cena: (a) A foto em escala de cinza atribui o valor zero para o preto e o valor 250 para o branco, cada cor do plano representa um valor de intensidade coletado pela câmera. (b) Nesta representação cada valor de intensidade é plotado como uma altura no eixo z. Fonte: Autor.	27

Figura 11 – Algumas imagens e suas superfícies: (a) Nesta imagem existe a variação de intensidade no eixo x . (b) A variação de intensidade plotada, se apresenta como uma superfície senoidal com frequência na direção x . (c) Nesta imagem existe a variação de intensidade no eixo y . (d) A variação de intensidade plotada, se apresenta como uma superfície senoidal com frequência na direção y . (e) Nesta imagem existe a variação de intensidade nos eixos x e y . (f) A variação de intensidade plotada, se apresenta como uma superfície senoidal com frequência na direção diagonal. Fonte: Imagem adaptada de (DAS, 2015).	30
Figura 12 – Quatro elementos retangulares para a extração de características. O valor obtido é o resultado da diferença entre o somatório das partes brancas menos as partes pretas em cada tipo de elemento. Fonte: Notas de aula Mor Jakobovits e Roni Karlikar.	39
Figura 13 – Imagem Integral: (a) A imagem integral do ponto (x,y) é o somatório de todos os pontos acima e a esquerda, ou seja, o somatório da região destacada em laranja. (b) Pontos e regiões de uma imagem. Fonte: Notas de aula Mor Jakobovits e Roni Karlikar.	39
Figura 14 – Fluxograma do classificador em cascata. Fonte: Autor.	41
Figura 15 – Fluxograma para a extração de características, mais uso de uma SVM Linear. Fonte: Adaptado de (DALAL; TRIGGS, 2005).	42
Figura 16 – Visão geral do extrator de características HOG. Fonte: Adaptado de (WATANABE; ITO; YOKOI, 2009).	43
Figura 17 – Comportamento do histograma de gradientes para imagens remodeladas por um fator 2. (a) As imagens foram aumentadas por um fator 2 e as distribuições de probabilidade para pedestres e imagens diversas apresentam gradientes que na média também aumentam por um fator 2. (b) As imagens foram diminuídas por um fator 2, mas as distribuições de probabilidade para pedestres e imagens diversas apresentam gradientes que na média diminuem por um fator 0.3 ao invés de 0.5. (c) As imagens foram diminuídas por um fator 2, mas as distribuições de probabilidade para pedestres e imagens diversas apresentam gradientes normalizados que na média diminuem por um fator 0.27 ao invés de 0.5. Fonte: Adaptado de (DOLLÁR et al., 2014).	45
Figura 18 – Comparação visual de duas abordagens para o cálculo de canais em diferentes escalas. Fonte: Adaptado de (DOLLÁR et al., 2014).	46
Figura 19 – Visão geral do método <i>Aggregated Channel Features</i> (ACF). Fonte: Adaptado de (DOLLÁR et al., 2014).	47
Figura 20 – Fluxo de etapas da metodologia do projeto.	49

Figura 21 – Voo realizado pelo RPA da DJI Phantom 3 para adquirir imagens dos rolos do transportador de correia.	51
Figura 22 – Quatro frames distintos retirados do vídeo adquirido com o RPA Phantom 3. Fonte: Autor.	51
Figura 23 – Visão Geral dos pontos inspecionados com o RPA. Fonte: Autor	52
Figura 24 – Drone Inspire I pronto para decolar com o TR-313K-31 ao fundo. . . .	53
Figura 25 – Coleta de imagens térmicas no TR-313K31: (a) O RPA dentro da elipse tracejada em amarelo voa a 5 metros de distância do TC. (b) Nesta imagem não é possível visualizar os rolos centrais, o RPA está voando muito alto. (c) Imagem térmica onde é possível visualizar os rolos centrais, nota-se também que a tela de proteção do TC não interfere na coleta dos dados de temperatura.	54
Figura 26 – Posição recomendada de voo para a captura de imagens de alta qualidade dos rolos. Fonte: Autor	55
Figura 27 – Propagação do erro de configuração inicial na sequência de imagens. Fonte: Autor	55
Figura 28 – Alguns rolos defeituosos encontrados com a abordagem proposta, eles estão destacados pelas elipses pontilhadas em vermelho: (a) Rolo travado encontrado no dia 01/08 a noite. (b) Rolamentos super-aquecidos encontrados na noite do dia 01/08. (c) Rolamento super-aquecido, manhã do dia 02/08. (d) Rolo travado encontrado na tarde do dia 02/08. (e) Rolamento super-aquecido encontrado na manhã do dia 03/08, note que a tela de proteção não impediu a localização do defeito. (f) Rolo travado encontrado na manhã do dia 03/08. Fonte: Autor.	56
Figura 29 – Distância versus visualização de defeitos pelo inspetor. Fonte: Autor . .	57
Figura 30 – Influência da emissividade na temperatura medida: (a) A temperatura máxima encontrada foi de 111 °C com a emissividade de 0,50. (b) Com a emissividade configurada para 0,85 a temperatura máxima foi de 78,5 °C. (c) Máxima temperatura de 73,1 °C para uma emissividade de 0,95. Fonte: Autor, o horário da câmera foi configurado para -3 UTC.	58
Figura 31 – Comportamento da Temperatura x (Emissividade x Distância): (a) Foram configuradas várias distâncias e emissividades diferentes. (b) A distância foi mantida em 2m, e a emissividade foi alterada de 0,5 até 1. Fonte: Autor.	59
Figura 32 – A influência da distância na temperatura: (a) Foto tirada a 11 m de distância, resultando em um MFOV de 76,2 mm. (b) O mesmo rolo com a foto tirada a 3 m de distância, o MFOV calculado é de 20,8 mm. Fonte: Autor.	61

Figura 33 – Esse gráfico mostra como a taxa de operação de um TC pode cair instantaneamente e depois retornar aos seus valores originais. Fonte: Autor.	62
Figura 34 – Visão geral das fases do projeto com uma breve descrição e os principais benefícios de cada uma delas.	64
Figura 35 – Processamento morfológico: (a) Imagem radiométrica com a presença de um rolo defeituoso. (b) Detalhe da região sobreaquecida em que cada pixel contém o valor de temperatura. (c) Máscara da região de interesse, filtrada pela técnica dos 8 vizinhos conectados. (d) Região do rolo defeituoso demarcada. O asterisco azul mostra o ponto de máxima temperatura com 54 °C. Fonte: Autor.	66
Figura 36 – Processamento morfológico: (a) TCs do píer 03, o RPA está dentro da elipse tracejada em amarelo. (b) Regiões demarcadas erroneamente. (c) Melhora do algoritmo delimitando somente o rolo sobreaquecido. Fonte: Autor.	67
Figura 37 – Treinamento para o reconhecimento de objetos: (a) Diferentes regiões dos rolos nomeadas. (b) Rolos centrais esquerdos detectados. (c) O terceiro rolo lateral não foi encontrado pelo detector. (d) O terceiro rolo lateral que não foi encontrado na figura anterior 37c, e agora é o rolo central foi encontrado pelo detector. Fonte: Autor.	69
Figura 38 – Imagens com as regiões detectadas pelo algoritmo em amarelo e as regiões demarcadas como verdadeiras em ciano. Fonte: Autor	71
Figura 39 – Identificação de falhas em rolos: (a) Detector do tipo REC aplicado à imagem. (b) Fluxo para a identificação de falhas em rolos. Fonte: Autor.	72
Figura 40 – Avaliação dos resultados do VJ: (a) Gráfico de precisão x revocação, com a precisão média indicada no título. (b) Gráfico da taxa de falsos negativos x falsos positivos. Fonte: Autor.	74
Figura 41 – Avaliação do detector RLE: (a) Gráfico de precisão x revocação, com a precisão média indicada no título. (b) Gráfico da taxa de falsos negativos x falsos positivos. (c) Avaliação de várias abordagens para a detecção de pedestres no banco de imagens INRIA. (d) Avaliação de várias abordagens para a detecção de pedestres no banco de imagens Caltech. Miss Rate é o mesmo que a taxa de falsos negativos Fonte: Autor (a) e (b). (DOLLAR et al., 2012) (c) e (d).	75
Figura 42 – Avaliação dos detectores REC e RDC: (a) e (c) Gráfico de precisão x revocação, com a precisão média indicada no título. (b) e (d) Gráfico da taxa de falsos negativos x falsos positivos. Fonte: Autor.	76
Figura 43 – Configuração do TR-313K-64 um transportador mais complexo com 19 tambores e 1,37 km de extensão. Fonte: Documentos de Engenharia Vale	81

Figura 44 – Configuração da região do acionamento TR-313K-64. Esta região de apenas 52 metros contém a maior variedade de equipamentos instalados no transportador. Fonte: Documentos de Engenharia Vale	82
Figura 45 – Nomenclatura de alguns dos elementos do TC. Fonte: (NASCIMENTO et al., 2017).	83
Figura 46 – Alguns tipos de roletes de carga: (a) Rolete de carga padrão com 3 rolos idênticos montados em linhas. (b) Rolete de transição que pode ter a inclinação dos rolos laterais ajustados para vários ângulos diferentes. (c) Rolete auto-alinhante com 3 rolos de carga e 2 guias, sua função é corrigir pequenos desalinhamentos. Fonte: Documentos de Engenharia Vale.	84
Figura 47 – Alguns tipos de roletes de retorno: (a) Rolete de retorno plano, neste exemplo o rolo de retorno possui anéis de borracha. (b) Rolete de retorno em V, que além da função de suporte também melhora o alinhamento da correia. Fonte: Documentos de Engenharia Vale.	85
Figura 48 – Alguns tipos de roletes de impacto: (a) Rolete de impacto com 3 rolos coberto com borracha, neste exemplo a lateral do suporte é removível para facilitar a troca dos rolos. (b) Rolete de impacto com 5 rolos cobertos com borracha. Fonte: Documentos de Engenharia Vale.	85
Figura 49 – Detalhes de um rolo de carga: (a) Detalhes do rolamento de um rolo de carga, a Tabela 10 descreve cada numero indicado. (b) Dimensional de um rolo de carga comum.	86
Figura 50 – Tipos de copos rolantes: (a) Montagem típica de um rolamento de esferas para esforços radiais. (b) Rolamento de rolos para cargas radiais. (c) Rolamento de carreira dupla combinado com rolos e esferas, oferece resistência axial e radial. Todas as figuras foram retiradas do catálogo geral de rolamentos da (SKF, 2015). A numeração 2, 20 e 43 foi mantida para facilitar a identificação das figuras no catálogo.	88
Figura 51 – Corte transversal simplificado do olho humano. Fonte: Figura foi adaptada de (COMMONS, 2016b).	90

Lista de tabelas

Tabela 1 – Faixas do Espectro Infravermelho com os Respectivos Comprimentos de Onda	19
Tabela 2 – Tipos de Sensores, Material Utilizado e Faixa de Operação	20
Tabela 3 – Comprimento de Onda do Pico de Radiância Espectral para Várias Temperaturas. Fonte: Adaptada de (BAGAVATHIAPPAN et al., 2013)	23
Tabela 4 – Normas Brasileiras de Termografia e Algumas Normas Internacionais Relevantes	24
Tabela 5 – Taxa de falsos negativos de várias abordagens para a detecção de pedestres em diversos bancos de dados. Fonte: Adaptado de (DOLLÁR et al., 2014).	47
Tabela 6 – Avaliação do Resultado do Algoritmo, Viola e Jones, no Banco de 50 Imagens de Teste	62
Tabela 7 – Avaliação do Resultado do Algoritmo, ACF, no Banco de 50 Imagens de Teste	70
Tabela 8 – Avaliação do Resultado do Algoritmo, Viola e Jones, no Banco de 50 Imagens de Teste	73
Tabela 9 – Avaliação do Resultado do Algoritmo, Viola e Jones, no Banco de 50 Imagens de Teste	73
Tabela 10 – Exemplo de Especificação para um Rolo de Carga	87
Tabela 11 – Avaliação do Resultado do Algoritmo, Viola e Jones, no Banco de 50 Imagens de Teste	100
Tabela 12 – Avaliação do Resultado do Algoritmo, ACF, no Banco de 50 Imagens de Teste. Regiões do Tipo REC.	101
Tabela 13 – Avaliação do Resultado dos Algoritmos ACF e Viola e & Jones, no Banco de 106 Imagens de Teste. Regiões do Tipo REC.	102
Tabela 14 – Continuação da Tabela 13 - Avaliação do Resultado dos Algoritmos ACF e Viola e & Jones, no Banco de 106 Imagens de Teste. Regiões do Tipo REC.	103

Lista de Abreviaturas e Siglas

- ACF** *Aggregated Channel Features*. [xii](#), [46–48](#), [72–76](#), [78](#), [79](#), [99](#)
- BCF** *Bearing Characteristic Frequency*. [14](#)
- BoW** *Bag of Words*. [37](#)
- BPFI** *Bearing Pass Frequency of Inner Race*. [14](#)
- BPFO** *Bearing Pass Frequency of Outer Race*. [14](#)
- BSF** *Ball Spin Frequency* . [15](#)
- CCD** *Charge Coupled Device*. [26](#)
- CMY** *Cyan, Magenta and Yellow*. [27](#)
- CN** *Carregador de Navio*. [2](#)
- CNN** *Convolutional Neural Network*. [37](#)
- DFT** *Discret Fourier Transform*. [29](#)
- DGNSS** *Differential Global Navigation Satellite System*. [79](#)
- EP** *Empilhadeira*. [2](#)
- EPC** *Equipamento de Proteção Coletiva*. [5](#)
- EPI** *Equipamento de Proteção Pessoal*. [5](#)
- ER** *Empilhadeira/Recuperadora*. [2](#)
- FFT** *Fast Fourier Transform*. [15](#), [16](#)
- FOV** *Field of View*. [52](#), [53](#), [58](#), [65](#)
- FPPW** *False Positives Per Window*. [42](#)
- FTF** *Fundamental Train Frequency*. [15](#)
- GLONASS** *Globalnaya navigatsionnaya sputnikovaya sistema*. [50](#), [52](#)
- GNSS** *Global Navigation Satellite System*. [50](#)

GPS *Global Positioning System*. 50, 52

GPV *Gestão de Processos Vale*. 50

HOG *Histogram of Oriented Gradient*. 42, 43, 46, 68, 69

HSI *Hue, Saturation and Intensity*. 27

IDFT *Inverse Discret Fourier Transform*. 29

IFOV *Instantaneous Field of View*. 52, 58, 61

INMET *Instituto Nacional de Meteorologia*. 60

IR *Infrared*. 18, 20, 21, 23, 90

IRT *Infrared Thermography*. 18, 20, 22, 23, 25, 35, 57, 60, 61, 79

IV *Infravermelho*. 18

LWIR *Long Wavelength Infrared*. 20, 23, 52, 58

MFOV *Measurement Field of View*. 60, 61

MWIR *Mid Wavelength Infrared*. 20

NIR *Near Infrared*. 18, 20

OFNR *Overall False Negative Rate*. 70–73

OFPR *Overall False Positive Rate*. 70–72

RDC *Rolo Direito Central*. 68, 72, 73, 77

REC *Rolo Esquerdo Central*. 68, 70–73, 77, 99

RGB *Red, Green and Blue*. 27, 52

RLE *Rolo Lateral*. 68, 72, 73, 75

ROI *Region of Interest*. 6, 36, 37, 67–71

RP *Recuperadora*. 2

RPA *Remotely Piloted Aircraft*. 1, 5, 6, 49, 50, 52–57, 60, 61, 64, 65, 73, 78–80

SDK *Software Development Kit*. 65

SVM *Support Vector Machine*. 36, 42

SWIR *Short Wavelength Infrared.* 20

TC Transportador de Correia. 1–6, 8, 9, 12–14, 16, 35, 50, 51, 53, 54, 57, 58, 60–62, 78, 79, 81–83, 86, 88

TMPM Terminal Marítimo de Ponta da Madeira. 1, 2, 5, 12, 53, 78

UTC *Universal Time Coordinated.* 60

VANT Veículo Aéreo não Tripulado. 5

VLWIR *Very Long Wavelength Infrared.* 18, 20

VV Virador de Vagão. 2

Sumário

	Lista de ilustrações	xi
	Lista de tabelas	xvi
	Sumário	xx
1	INTRODUÇÃO	1
1.1	Justificativa	2
1.2	Objetivos	5
1.3	Publicações Realizadas	6
1.4	Organização do Texto	6
2	REFERENCIAL TEÓRICO	8
2.1	Transportadores de Correia	8
2.2	Sinais e Instrumentação	11
2.3	Termografia Infravermelho	17
2.4	Processamento de Imagens	25
3	TRABALHOS RELACIONADOS	35
3.1	Processamento de Imagens Térmicas para o Diagnóstico de Falhas	35
3.2	Detecção Rápida de Objetos Alavancada pelo uso de Características Simples em Cascata	38
3.3	Histograma de Gradientes Orientados para a Detecção de Humanos	41
3.4	Pirâmide de Características para a Rápida Detecção de Objetos	43
4	METODOLOGIA	49
4.1	Levantamento e Priorização das Falhas	50
4.2	Definição dos Sensores	50
4.3	Experimentos e Coleta de Dados	57
4.4	Métodos de Processamento de Dados	62
5	DESENVOLVIMENTO E RESULTADOS	64
5.1	Desenvolvimento do Processamento dos Sinais	65
6	CONSIDERAÇÕES FINAIS	78
6.1	Conclusão	78
6.2	Trabalhos Futuros	79

A	FUNCIONAMENTO DE UM TRANSPORTADOR	81
A.1	Estrutura e Funcionamento dos Rolos e Roletes	82
B	VISÃO HUMANA	90
C	CÓDIGOS PARA O MATLAB	92
D	TABELAS	99
	REFERÊNCIAS	104

1 Introdução

Na indústria da mineração, mais especificamente de minério de ferro, o transporte de quantidades gigantescas de materiais com eficiência e baixo custo é fundamental. Em 2016, por exemplo, foram produzidos no mundo 2.230 milhões de toneladas de minério de ferro (U.S. Geological Survey, 2017), sendo o Brasil responsável pela produção de 391 milhões de toneladas. Para a movimentação de todo esse material, um dos métodos amplamente empregados é o uso de Transportadores de Correia (TCs) que são utilizados nos processos de extração da mina, nas usinas de processamento, nas usinas de pelotização, nos portos e também nas siderúrgicas.

O tamanho dos TCs podem variar de apenas algumas centenas de metros, como nas cabeças móveis e TCs de desvio, para algumas dezenas de quilômetros como nos TCs da mina até a usina. É importante ressaltar que o termo transportador de correia utilizado no presente trabalho não se refere somente à correia de borracha utilizada para o transporte, mas sim à toda a estrutura instalada para o transporte do minério, como: rolos, tambores, acionamentos, raspadores, cavaletes, decks, calhas de cabos elétricos e etc.

A manutenção e a operação desses ativos é crítica para os processos de movimentação de material na mineração e a avaria de um TC mediano, com 1 km de extensão, pode envolver custos diretos com reparos que ultrapassam, nos piores casos, a cifra de centenas de milhares de reais, além dos custos indiretos da parada da linha de produção por aproximadamente 96 horas.

O presente trabalho irá focar nos transportadores de correia do Terminal Marítimo de Ponta da Madeira (TMPM), que atualmente é responsável pelo embarque de 150 Mt/ano de minério de ferro e tem projetos em andamento para o embarque de até 250 Mt/ano. Foi desenvolvido um novo método de inspeção dos TCs com o uso de *Remotely Piloted Aircrafts* (RPAs) (em português, Aeronaves Remotamente Pilotadas), com uma câmera térmica embarcada e o processamento digital das imagens.

O processamento dos dados coletados, através do RPA, irá fornecer uma inspeção de maior qualidade e alavancar os níveis de confiabilidade dos equipamentos portuários, além de prover melhores condições de trabalhos para os inspetores de manutenção. Não obstante, os trabalhos desenvolvidos pioneiramente no Porto podem, sem maiores dificuldades, ser replicados para outras áreas operacionais, como o transporte do minério da mina até a usina ou entre os vários processos dentro das usinas.

1.1 Justificativa

O TPM está localizado na cidade de São Luís, capital do estado do Maranhão, e é o ponto final do sistema logístico que transporta o minério de ferro retirado na mina Carajás, para o carregamento dos navios com destino à Ásia e Europa. Ele possui 8 Carregadores de Navios (CNs), 8 Viradores de Vagões (VVs), 7 Recuperadoras (RPs), 4 Empilhadeiras/Recuperadoras (ERs), 5 Empilhadeiras (EPs) e 149 TCs. Com isso tem-se um total aproximado de 120 km de correias e 200 mil rolos em operação que necessitam de inspeção constante, pois são itens que sofrem desgaste acentuado durante a operação, e a quebra de somente um rolo dos 200 mil instalados pode parar toda uma linha de produção com prejuízos milionários para a companhia. Na Figura 1, é apresentada uma visão aérea do porto delimitado pelo polígono em vermelho e que compreende uma área aproximada de 500 hectares.



Figura 1 – Vista satélite do TPM. Fonte: Google Earth, 07/06/2016 – $2^{\circ}33'42.86''S$; $44^{\circ}21'31.38''O$.

A inspeção dos 120 km de TCs e 200 mil rolos hoje é realizada em sua maioria de forma sensitiva, isto é, sem instrumentação, e requer uma grande quantidade de mão de obra pois os 120 km tornam-se 240 km a serem percorridos a pé, já que o inspetor deve verificar os dois lados da correia. Outras dificuldades encontradas na inspeção dos TCs são pontos não acessíveis devido à altura e/ou falta de passarela e à necessidade de se inspecionar o equipamento em operação, que adiciona uma complicação ao planejamento das rotas de inspeção.

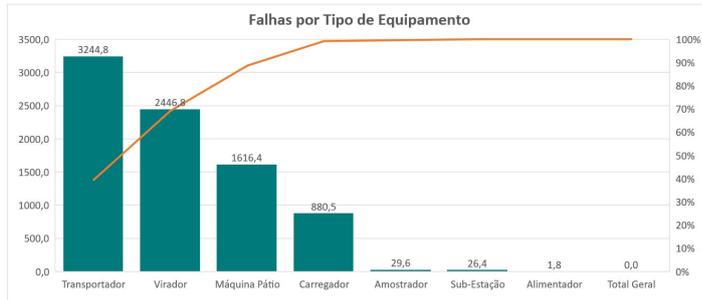
Diante da quantidade de equipamentos a serem inspecionados, da falta de instrumentação aplicada e de outras dificuldades de inspeção correlacionadas. A probabilidade de ocorrer um erro de manutenção é considerável e a ocorrência do evento de quebra pode causar danos extremos, como foi o caso do incêndio ocorrido na correia transportadora TR-315K-36. No evento foram danificados vários rolos, houve a perda de 300 m de correia e todo o sistema elétrico e de automação da área foi danificado, o incêndio foi causado pela quebra do rolamento de um rolo da mesa impacta. Devido à quebra do rolamento, o atrito superaqueceu o rolo que incendiou a correia assim que a mesma parou de operar. A Figura 2 mostra a dimensão do estrago causado por esta falha de manutenção.



Figura 2 – Incêndio no TR-315K-36 do TMPM.

Esse evento ilustra bem os riscos aos quais ficam submetidos os equipamentos por falha na inspeção. Na Figura 3a, pode-se constatar que os TCs com 3244 horas paradas por falhas são um dos principais impactos na produção do porto e representaram 39,35% das horas paradas em 2016, ver Figuras 3b. Já as falhas em rolos são o segundo colocado quando olha-se somente para as falhas dos transportadores, Figura 3c, e das 325 horas paradas por problemas em rolos 169 horas foram apontadas como princípio de incêndio em um total de 94 eventos. Todas essas 94 ocorrências poderiam ter tornado-se eventos catastróficos se as equipes de corretiva não tivessem atuado a tempo. O somatório das horas paradas está de acordo com os apontamentos operacionais adotados pela VALE, então, por exemplo, se a parada de um transportador para 3 rotas distintas, as horas paradas são multiplicadas por 3, refletindo o impacto operacional em todas as rotas paradas. O

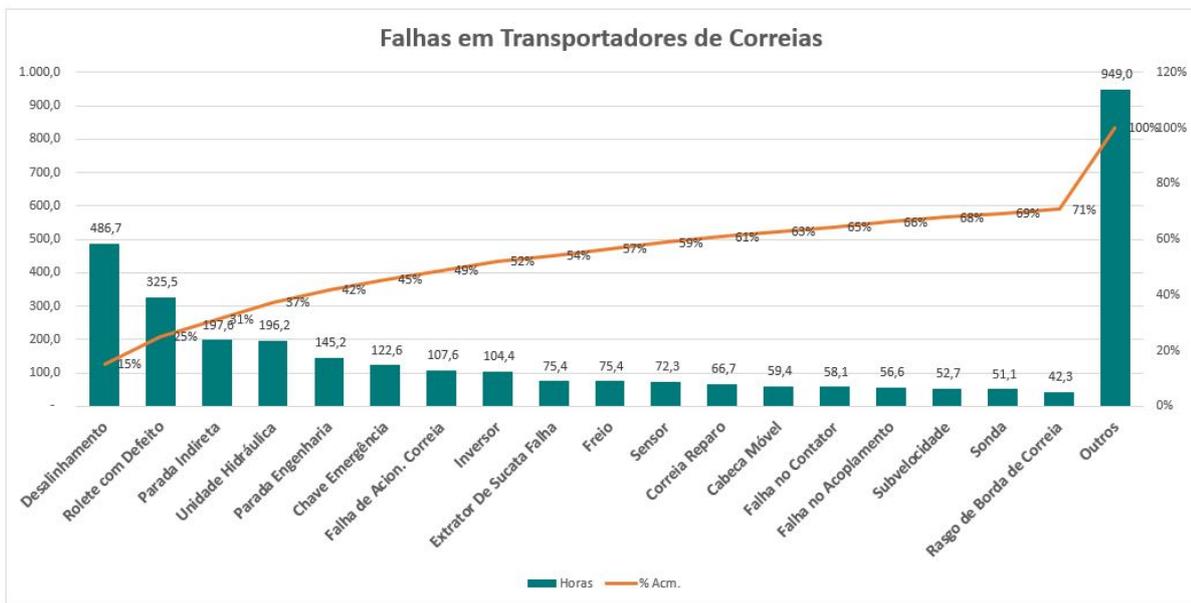
mesmo se aplica aos demais equipamentos.



(a) Gráfico de Pareto por tipo de equipamento.

Tipo Equipamento	Horas	% Acm.
Transportador	3244,8	39,35%
Virador	2446,8	69,02%
Máquina Pátio	1616,4	88,62%
Carregador	880,5	99,30%
Amostrador	29,6	99,66%
Sub-Estação	26,4	99,98%
Alimentador	1,8	100,00%
Total Geral	8246,3	

(b) Porcentagem acumulada de falhas.



(c) Gráfico de Pareto para falhas em TCs.

Figura 3 – Análise das principais falhas do TPM em 2016: (a) Os TCs com 3244,8 horas paradas por falhas são os equipamentos que mais impactam a produção do porto. (b) Tabela com os percentuais acumulados de falhas os TCs representam 39,35% das falhas. (c) As paradas relacionadas à falhas em rolos estão na segunda colocação com 325,5 horas. Fonte: Sistema Informatizado de Produção Vale (GPV).

Além dos impactos operacionais, a atividade de inspeção dos TCs requer que o inspetor se desloque ao lado do transportador, ficando dessa maneira exposto a diversos riscos como os listados a seguir:

Projeção de material, que pode causar sérios danos físicos;

Queda de mesmo nível, causada por desnivelamento do caminho de inspeção ou material acumulado;

Queda de níveis diferentes, causada pela corrosão das passarelas, falta de corrimão ou de barreiras de proteção;

Exposição a ruídos elevados, que pode ao longo dos anos causar hipoacusia;

Exposição a intempéries atmosféricas, como sol, chuva e descargas atmosféricas;
Riscos biológicos, como acidentes com animais peçonhentos, parasitas e etc...

Desse modo, a utilização de sistemas automáticos, que proporcionam maior frequência das inspeções, pode gerar ganhos consideráveis à empresa e preservar a integridade física dos trabalhadores.

1.2 Objetivos

Os maiores ativos do TPM são os TCs e a inspeção desses ativos é feita da mesma maneira há quase 20 anos, com pouca inovação tecnológica e bastante dependente da experiência dos inspetores de manutenção. A manutenção desses ativos enfrenta dificuldades que não estão presentes em outros tipos de indústria, como a distribuição geográfica dos equipamentos e as quantidades de itens a serem inspecionados. Como o modelo de inspeção adotado é altamente dependente da experiência do inspetor, está sujeito a avaliações subjetivas e pouco precisas. Além disso, o acesso às áreas operacionais sempre envolve riscos e a presença frequente de inspetores e ou operadores nas áreas operacionais demanda o investimento constante em segurança, como: Equipamentos de Proteção Pessoal (EPIs), Equipamentos de Proteção Coletiva (EPCs), treinamento de pessoal, reciclagem, técnicos de segurança e muitos outros custos indiretos.

O principal objetivo deste trabalho é desenvolver um método de inspeção para rolos e correias, através de Veículos Aéreos não Tripulados (VANTs), mais especificamente por meio de RPAs, o que permitirá um aumento significativo dos níveis de segurança, pelo fato de diminuir dramaticamente a presença dos inspetores na área operacional.

Pretende-se também aperfeiçoar a qualidade das inspeções executadas, diminuindo a quantidade das manutenções corretivas e preventivas e aumentando a quantidade de manutenções preditivas. Para tal, os RPAs devem possuir a instrumentação necessária para a coleta de dados e métodos para a detecção de defeitos. Eliminando, se possível, os falsos negativos que podem trazer prejuízos gigantescos, e diminuindo os falsos positivos, que trazem maiores custos à manutenção. Uma das principais contribuições do presente trabalho será a identificação de defeitos nos rolos dos TCs através do processamento digital de imagens coletadas pelo RPA.

Objetivos Específicos

Para atingir tal objetivo serão necessárias definições de metas mais específicas, são elas:

- Investigação do uso da câmera térmica embarcado no RPA;
- Desenvolvimento de um algoritmo para a extração dos dados radiométricos da câmera;

- Desenvolvimento de métodos de identificação de defeitos em rolos, através de imagens térmicas;
- Criação de um repositório rotulado das *Region of Interests* (ROIs);
- Desenvolvimento e avaliação de algoritmos para a identificação das ROIs;

1.3 Publicações Realizadas

O presente trabalho, juntamente com a contribuição do trabalho de outros autores foi base para as seguintes publicações:

ICEIS 2017 – 19th International Conference on Enterprise Information Systems.

O artigo foi publicado com o título *An Integrated Inspection System for Belt Conveyor: Advancing in an Enterprise Architecture* (NASCIMENTO et al., 2017). E apresenta as dificuldades na inspeção dos TCs e os problemas causados pela falta de integração entre os sistemas corporativos (ERP e CMMS, por exemplo). Com base nisso, realiza uma revisão das principais técnicas de monitoramento de condições de TCs e propõe um modelo de arquitetura integrada, adotando o uso de UAVs como plataforma de coleta de dados e sensoriamento. O artigo também apresenta resultados preliminares dos testes já realizados em São Luís com alguns dos equipamentos.

First International Conference AIMS 2018: Mines of the Future.

O artigo foi aceito com o título *An UAV-based Framework for Automated Thermographic Inspection of Belt Conveyors in the Mining Industry*. Ele propõe procedimentos para a inspeção dos rolos de um transportador de correia com o uso de RPA e apresenta as técnicas de processamento de imagem utilizadas.

1.4 Organização do Texto

O presente trabalho foi estruturado em seis capítulos, conforme listado abaixo:

Capítulo 1 - Introdução. Apresenta o problema de maneira holística, contextualizando o ambiente operacional dos equipamentos e define os objetivos do trabalho;

Capítulo 2 - Referencial Teórico. Faz uma breve revisão bibliográfica sobre os temas fundamentais para o desenvolvimento do trabalho;

Capítulo 3 - Trabalhos Relacionados. Descreve de maneira detalhada os três artigos que foram chave no desenvolvimento do reconhecimento dos rolos;

Capítulo 4 - Metodologia, Apresenta de maneira sucinta o delineamento das várias etapas do projeto;

Capítulo 5 - Desenvolvimento e Resultados. Detalha o desenvolvimento das várias etapas do projeto, apresentando cada uma das soluções;

Capítulo 6 - Considerações Finais. Traz a conclusão do trabalho desenvolvido e sugere trabalhos futuros.

2 REFERENCIAL TEÓRICO

Neste capítulo, é realizada uma revisão bibliográfica dos conceitos e da fundamentação teórica e prática que suportam o presente trabalho. Para um melhor entendimento, procurou-se dividir o capítulo em várias seções. A Seção **2.1 Transportadores de Correia**, faz um breve histórico dos TCs e apresenta as principais falhas em rolos. Ela é seguida pela Seção **2.2 Sinais e Instrumentação**, que aborda os principais métodos para a identificação de defeitos em rolos dos TC. Na Seção **2.3 Termografia Infravermelho**, faz-se uma breve introdução dos princípios da termografia e de sua aplicação para inspecionar rolos. E a Seção **2.4, Processamento de Imagens**, traz uma visão geral das técnicas de processamento de imagem para a identificação de defeito em rolos.

2.1 Transportadores de Correia

Os primeiros registros do uso de TCs são de quase 200 anos atrás para o transporte de grãos e essa foi sua única aplicação pelos próximos 100 anos. Já que, os TCs apresentavam sérios problemas quando se tentava transportar materiais mais pesados, como o desgaste excessivo dos seus componentes ou mesmo o rompimento da correia (WOODCOCK; MASON, 2011). No entanto, nos últimos trinta anos o desenvolvimento dos transportadores de correia deu um salto e hoje os TCs possuem capacidade para 20000 t/h operando a uma velocidade de até 6,3 m/s e são amplamente usados na indústria da mineração.

Não há dúvidas, que hoje o Transportador de Correia (TC) é um dos principais meios de transporte para grandes quantidades de material a granel, capaz de movimentar praticamente qualquer tipo de granel sólido por longas distâncias com taxas elevadas e de forma contínua. Na sua forma mais simplificada, um TC consiste de uma correia de material flexível como borracha, esticada entre dois tambores e suportada por rolos de carga e retorno nesse intervalo, sendo um dos tambores acoplado a um motor de acionamento, ver Figura 4. Já em modelos mais complexos como o da Figura 5, o TC possui um total 19 tambores (contando os 3 tambores do tripper) e possui tambores específicos para tencionar a correia, para virar e revirar a correia e para suportar a inclinação da subida do tripper. Esse transportador estende-se por 1,37 km, com capacidade para transportar até 20000 t/h com velocidade de 4,3 m/s e tem três acionamentos um 1500 cv e dois com 1000 cv. Neste TC são instalados 3 rolos de carga a cada um metro, sendo dois laterais com 45° de inclinação e um na horizontal, tem-se então o total aproximado de 4110 rolos de carga a serem inspecionados.

Uma breve descrição do princípio de funcionamento de um TC e seus principais

componentes pode ser encontrada no Apêndice A. Na seção a seguir, são detalhadas as principais falhas dos rolos de um TC. Componente mais abundante e alvo desse estudo.

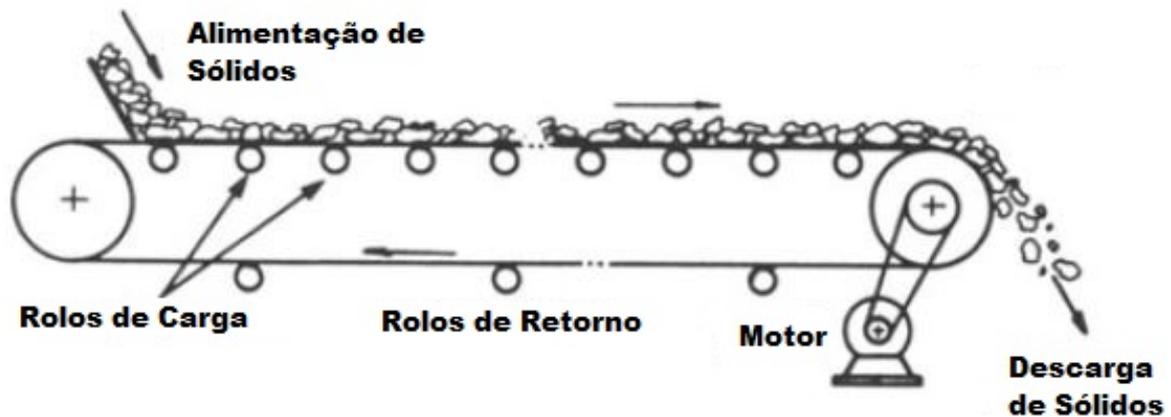


Figura 4 – Configuração básica de um transportador de correia. Fonte: Adaptado de (WOODCOCK; MASON, 2011)

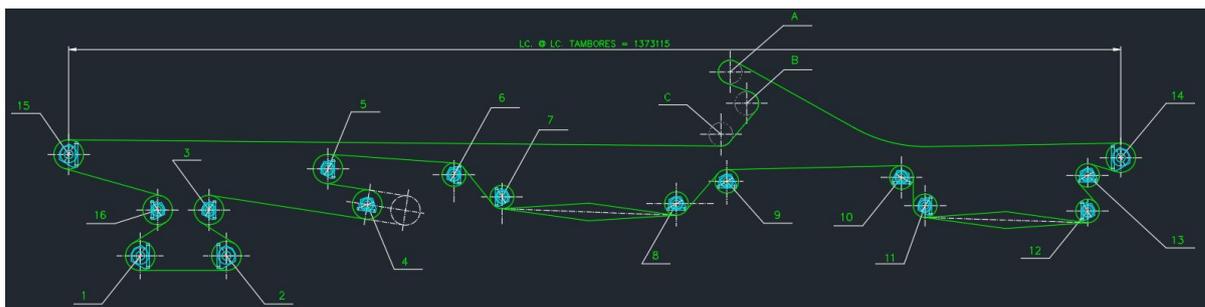


Figura 5 – Configuração de um transportador mais complexo com 19 tambores e 1,37 km de extensão. Fonte: Documentos de Engenharia Vale

Falhas em Rolos

Os rolos dos TCs geralmente falham de duas maneiras distintas, por travamento ou falha no rolamento. O travamento do rolo pode ocorrer por excesso de acúmulo de material no suporte ou pelo travamento do rolamento, nos dois casos o atrito com a correia irá desgastar o tubo externo do rolo e a cobertura da correia. Na Figura 6b é possível ver o desgaste provocado na correia pelo rolo da Figura 6a, em que o atrito da correia com o tubo externo do rolo o transformou em uma "navalha". Nesse caso, houve o travamento do rolamento que não permitiu a rotação do rolo. Na Figura 6c, pode-se ver o acúmulo de minério de ferro no suporte do rolo que irá travá-lo quando a correia parar e esse material endurecer. Para esses dois casos a identificação do defeito é feita de maneira visual, e as técnicas de identificação de defeitos por vibração ou por ultrassom não são otimizadas para esse tipo de defeito uma vez que o rolo não está em movimento e não irá gerar as frequências mapeadas de defeito. Por outro lado, o atrito irá gerar calor e a medição de temperatura pode ser utilizada para identificar esse tipo falha.

As falhas nos rolamentos são mais comuns e já é esperado que um número alto de rolos venha a falhar prematuramente, uma vez que eles são especificados usando a vida útil L_{10} conforme descrito na subseção A.1. Na Figura 6d, a quebra do rolamento levou o tubo externo do rolo a cortar o seu próprio suporte. E, na Figura 6f, é possível ver o dano que o rolo super-aquecido da Figura 6e gerou nos demais rolos, a correia não foi atingida, pois a equipe de corretiva conseguiu agir a tempo. O super-aquecimento ocorreu por uma falha no rolamento.



Figura 6 – Algumas falhas em rolos e suas consequências: (a) O tubo externo do rolo travado foi lixado pela correia até se tornar uma "navalha". (b) Correia danificada pelo rolo da Figura 6a. (f) Acúmulo de material no suporte do rolo central, com o endurecimento desse material o rolo ficará travado. (d) A quebra do rolamento provocou o deslocamento do tubo externo do rolo que cortou o seu próprio suporte. (e) A quebra do rolamento super-aqueceu o rolo e suas partes em borracha foram incendiadas. (f) Danos causados pelo rolo da Figura 6e

Existem diversos fatores que podem levar os rolamentos a falhar, como: carga excessiva, super-aquecimento, esmagamento (falso brinell), brinell, fadiga normal, carga reversa, contaminação, falha de lubrificante, corrosão, desalinhamento e erro de montagem (WYSOCLCI; FEEST, 1997). Cada um deles é brevemente detalhado abaixo:

- **Carga excessiva.** A carga excessiva do rolamento causa a fadiga do aço nas superfícies dos elementos rolantes ou pistas de rolamento. É necessário reduzir a carga operacional ou redimensionar os rolamentos;
- **Super-aquecimento.** Temperaturas elevadas podem resultar na perda de dureza do material, na deformação dos elementos rolantes, na degradação do lubrificante e alterações dimensionais dos elementos do rolamento que poderá resultar na quebra do rolamento;

- **Esmagamento (falso brinell).** O esmagamento ou falso brinell é causado por vibração excessiva do rolamento e deixa marcas elípticas na pista de rolamento. A vibração faz com que o elemento rolante não gire corretamente, e desta forma o filme de óleo que previne o desgaste não é formado;
- **Brinell.** Essa falha ocorre quando a carga excede o limite elástico do anel do rolamento, gerando marcas chamadas de marcas de Brinell. Uma das causas pode ser o uso de marretas durante a montagem do rolamento;
- **Fadiga normal.** Ocorre quando parte superficial do material (descascamento) da pista de rolamento externo ou interno é perdida, e uma vez iniciado esse processo ele é progressivo e irá aumentar a vibração do rolamento e também haverá o espalhamento da perda de material. Esse tipo de falha é relacionada com o tempo de vida útil estimado do rolamento;
- **Carga reversa.** Ocorre em rolamentos de carga axial que são desenhados para girar em somente uma direção;
- **Contaminação.** A contaminação é uma das causas mais frequentes de quebras em rolamentos, ela ocorre pela infiltração de sujeira ou qualquer material abrasivo no rolamento. Para o presente projeto esse é um grande problema, pois o minério de ferro é um grande contaminante dos rolamentos.
- **Falha de lubrificante.** O rolamento de esferas depende da presença contínua de um filme lubrificante muito fino (milionésimos de polegada de espessura) para evitar o desgaste. A lubrificação incorreta irá gerar o desgaste excessivo dos componentes causando sobre-aquecimento ou mesmo a quebra do rolamento;
- **Corrosão.** Resulta da exposição do rolamento a materiais ou ambientes corrosivos, a lubrificação ajuda a evitar essa falha;
- **Desalinhamento.** Quando os elementos rolantes giram, eles deixam marcas na pista de rolamento, se essas marcas não são paralelas à pista é um sinal de desalinhamento, podendo gerar sobre-temperatura e desgaste excessivo.
- **Erro de montagem.** A montagem do rolamento obedece a limites de folgas pré-definidos, se o rolamento é montado muito apertado ou muito folgado. Haverá falhas prematuras no mesmo.

Existem diversos meios e sinais para se identificar as falhas acima e cada um deles será melhor detalhado na Seção 2.2.

2.2 Sinais e Instrumentação

Cada uma das inúmeras falhas que podem ocorrer nos rolos geram sinais característicos que podem ser identificados sem instrumentação para as fases avançadas das falhas e com instrumentação no seu princípio.

Inspeção Sensitiva (Não instrumentada)

Durante uma inspeção sensitiva, ou seja sem instrumentação, o inspetor fará uso da sua visão, audição e tato para identificar e registrar as falhas para posterior tratamento. A lista a seguir retirada da ordem de manutenção para a inspeção mecânica de roletes em um transportador do TMPM resume as atividades que o inspetor deve executar.

1. Verificar condições inadequadas de limpeza;
2. Verificar ruído anormal;
3. Verificar vibração excessiva;
4. Verificar travamento, avarias e/ou ausência de rolos de carga, retorno e impacto;
5. Verificar corrosão, avarias e/ou ausência de cavaletes de carga, retorno e impacto;
6. Verificar parafusos, arruelas e porcas de cavaletes de carga, retorno e impacto folgados, avariados e/ou ausentes;
7. Verificar ausência, corrosão, deformações, empenos, trincas, defeitos em cordões de solda e/ou avarias em telas e/ou chapas de proteção instaladas na região de retorno;
8. Verificar parafusos, arruelas e porcas externas folgados, avariados e/ou ausentes de telas e/ou chapas de proteção instaladas na região de retorno;
9. Verificar incompatibilidade de dimensões e/ou componentes de telas e/ou chapas de proteção instaladas na região de retorno com especificações de projeto;
10. Verificar cavaletes auto alinhantes de carga e de retorno com altura inadequada em relação aos cavaletes fixos;
11. Verificar distância entre cavaletes de impacto;
12. Verificar travamento, avarias e/ou ausência de rolos de proteção de estrutura;
13. Verificar corrosão, avarias e/ou ausência de suportes de rolos de proteção de estrutura;
14. Verificar parafusos, arruelas e porcas de suportes de rolos de proteção de estrutura folgados, avariados e/ou ausentes.

Das 14 atividades previstas doze usam o sentido da visão (algumas com o uso de trena), uma o da audição (atividade 2) e outra a audição mais o tato (atividade 3). Note que, a inspeção visual dos rolos se limita a investigar o travamento, avarias visíveis ou a ausência do mesmo. A vibração e o ruído dependem totalmente da experiência do inspetor e não existe um limite a ser seguido. Se a inspeção for realizada em um TC de 1 *km* serão 3000 avaliações subjetivas realizadas com base na experiência do inspetor, o que aumenta a chance de erro.

Inspeção Instrumentada

As inspeções instrumentadas requerem a coleta de sinais de áudio, temperatura ou vibração para posterior tratamento, sendo possível a aplicação de diversas abordagens. Na Figura 7, o monitoramento do rolos é dividido em 3 colunas por tipo de sinal, por posição do sensor e ciclo de coleta de dados. Os três tipos de sinais utilizados podem ser

instalados em posições fixas, semifixas ou móveis e possuir ciclos periódicos ou online. A instalação fixa permite a coleta online de dados, por outro lado ela requer um grande número de sensores instalados. Já as instalações semifixas e móveis podem apenas coletar os dados periodicamente, no entanto um único sensor é capaz de inspecionar todo um TC ou vários deles.

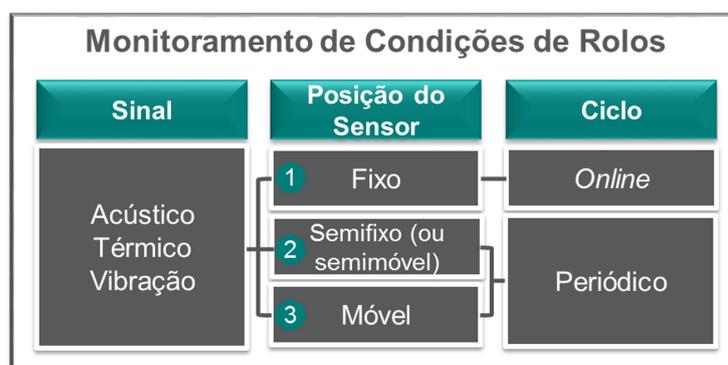


Figura 7 – Quadro de classificação dos tipos de monitoramento dos rolos. Fonte: (NASCIMENTO et al., 2017)

Sinal Acústico

Os sensores de áudio e de vibração são capazes de identificar falhas iniciais nos rolamentos e possuem sensibilidade equivalente (REZAEI et al., 2011). No entanto, o sinal de áudio não necessita de contato com o componente a ser inspecionado, sendo essa uma vantagem, já que muitas vezes a área operacional oferece risco aos empregados ou, no caso dos sensores fixos, requer a instalação de uma infraestrutura prévia.

O som de operação do TC é diferente quando os rolos estão em perfeita condição ou com falha, e essa diferença varia de falha para falha. Os distintos sons emitidos possuem informações sobre as características das falhas, o que pode ser usado para sua detecção. Porém, o sinal de áudio não provém apenas das falhas, ele também contém informação do ambiente e da operação normal da correia (Xiao-ping Jiang; Guan-qiang Cao, 2015). Além disso, o som ambiente muda com facilidade e o som de operação normal da correia muda com o tempo e também de TC para TC. Para diferenciar os sinais provenientes das falhas dos demais, são realizadas análises no domínio do tempo e da frequência e para tal vários métodos estão disponíveis como, por exemplo, a transformada de Fourier, a transformada rápida de Fourier e *wavelets*.

Um método promissor é proposto em (Xiao-ping Jiang; Guan-qiang Cao, 2015), usa *wavelets*, também conhecida como microscópio matemático. Ela realiza a análise no domínio do tempo e da frequência localmente, com as janelas de tempo e frequência móveis, o que significa que na parte de alta frequência, ela possui uma alta resolução temporal e baixa resolução da frequência, enquanto ela permanece com alta resolução de frequência e baixa resolução temporal na parte de baixa frequência. A transformada *wavelet* pode

automaticamente se adaptar para a análise de tempo e frequência do sinal, focando nos seus detalhes. Sendo assim, ela é um ótimo meio para a análise dos sinais de falha presentes no áudio. Após a extração das características do sinal, um método com o uso de Redes Neurais é proposto para a identificação automática das falhas.

Apesar de promissora, a proposta para a identificação de defeitos em rolos, automaticamente com o uso de áudio, possui dois obstáculos a serem superados. O primeiro deles é a localização do rolos defeituosos, pois o sensor de áudio estará recebendo a informação de vários rolos ao mesmo tempo. E o segundo, tem relação com generalidade da rede neural que deverá ser treinada para diversos tipos de TCs com diversos tipos de rolos nos mais variados ambientes. Por último, existe ainda a questão dos rolos travados, que por não estarem em movimento, não serão, em princípio, detectados. Após busca, não foram encontradas referências para a detecção de rolos travados com o uso de áudio ou vibração, (JANSSENS et al., 2015) explicam que essa falha é muito difícil de detectar pois não gera um novo ciclo de frequência.

Sinal de Vibração

Por décadas, a análise de vibração com acelerômetros vem sendo utilizada para identificar e acompanhar falhas em rolamentos. E, por muito tempo, os acelerômetros foram mais precisos que os sensores acústicos. Em 1997, por exemplo, (SHIROISHI et al., 1997) concluíram em seu artigo com o título de *Bearing Condition Diagnostics Via Vibration and Acoustic Emission Measurements* (em português, Diagnóstico da Condição do Rolamento Através da Medição de Vibração e Emissão Acústica), que em geral os acelerômetros eram melhores que os sensores acústico. Eles demonstraram que os acelerômetros podiam identificar defeitos da ordem de $15,4 \mu m$ e que, apesar de identificar defeitos na pista externa do rolamento, os sensores acústicos eram insensíveis a defeitos na pista interna. Hoje, no entanto, os dois tipos de sensores possuem sensibilidade equivalentes, conforme citado anteriormente na subseção 2.2 e também conforme descrito em (HE; HE, 2013).

Os rolamentos de carga radial se comportam como fontes de vibração, mesmo se os seus elementos estiveram em perfeito estado. Isso ocorre porque os rolamentos possuem um número finito de elementos rolantes e sua posição na zona de carga muda com a rotação, gerando um sinal periódico (TONDON; CHOUDHURY, 1999). A presença de um defeito aumenta substancialmente os níveis de vibração, uma vez que, a cada instante que uma esfera passa sobre um ponto defeituoso, uma série de impulsos são gerados. A frequência em que esses impulsos são gerados irá depender da *Bearing Characteristic Frequency* (BCF) (em português, Frequência Fundamental do Rolamento), que é característica da geometria, velocidade e componentes do rolamento. Geralmente, um rolamento de esferas possui quatro tipos principais de BCFs: *Bearing Pass Frequency of Outer Race* (BPFO) (em português, Frequência de Passagem da Pista Externa), *Bearing Pass Frequency of Inner Race* (BPFI)

(em português, Frequência de Passagem da Pista Interna), *Ball Spin Frequency* (BSF) (em português, Frequência de Rotação da Esfera), e *Fundamental Train Frequency* (FTF) (em português, Frequência Fundamental da Gaiola), que correspondem respectivamente ao defeito na pista externa, defeito na pista interna, defeito na esfera e defeito na gaiola (RAI; UPADHYAY, 2016). O conhecimento dessas frequências é imprescindível para a classificação das falhas.

O diagnóstico de falhas por meio de sensores de vibração geralmente obedece os seguintes passos: coleta dos dados de vibração com o acelerômetro, amplificação do sinal, filtragem, conversão analógica/digital, armazenamento dos dados, extração de características do sinal e identificação da falha. Na Figura 8, ver-se o fluxo de identificação das falhas com alguns modelos para a extração das características do sinal.

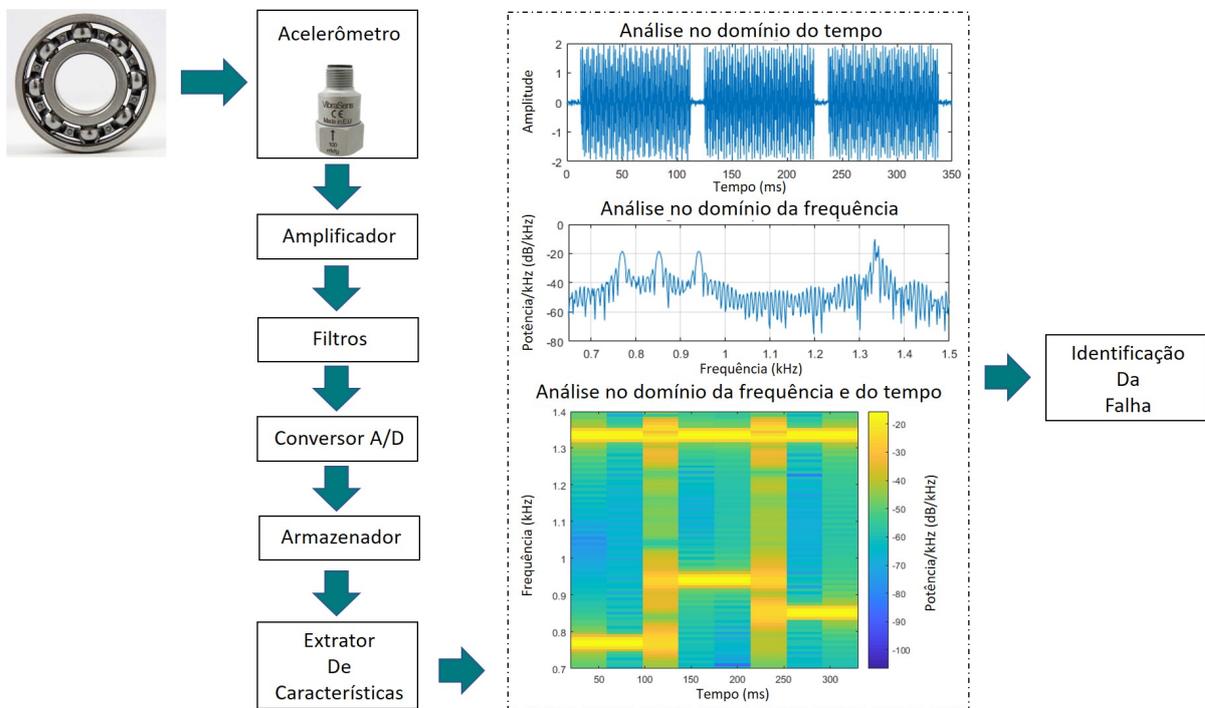


Figura 8 – Fluxo da identificação de falhas através do sinal de vibração. Fonte: Autor. Os sinais utilizados para montar o fluxo foram retirados de (MATHWORKS, 2015).

Tem-se três modelos principais para a análise do sinal de vibração:

- **A análise no domínio do tempo** é um modelo mais simplificado e que, entre as principais técnicas, tem-se a mensuração da raiz quadrada da média geral, o fator de crista e a relação do valor de pico. As técnicas no domínio do tempo têm sucesso limitado para identificar defeitos locais (TONDON; CHOUDHURY, 1999).
- **A análise no domínio da frequência** ou análise espectral é a abordagem atualmente mais utilizada para a identificação de defeitos. Com o surgimento da *Fast Fourier Transform* (FFT) (em português, Transformada Rápida de Fourier) foi possível obter, eficientemente, faixas curtas do espectro. Nesse modelo, as baixas

e altas frequências são utilizadas na identificação do defeito a depender da técnica utilizada.

- **A análise no domínio da frequência e do tempo** é a abordagem mais recente e utiliza a transformada *wavelet* (em tradução direta, Transformada de Onda Curta), para extrair sinais muito fracos onde a FFT se torna ineficiente. A transformada wavelet possui uma resolução variável na frequência-tempo, que permite a detecção de cada elemento do rolamento quando o mesmo passa sobre o defeito (RAI; UPADHYAY, 2016).

Uma classificação completa sobre as técnicas para cada uma dessas abordagens pode ser encontrada em (CHANDEL; PATEL, 2013), (RAI; UPADHYAY, 2016), (RAN-DALL; ANTONI, 2011) e (TONDON; CHOUDHURY, 1999).

Apesar de amplamente estudada e da sua precisão na identificação e classificação dos defeitos, a aplicação para os rolos de um TC não é trivial, pois deve-se coletar o sinal de vibração dos 200.000,00 rolos instalados no porto, além de que, a coleta de dados deve durar um certo tempo para posterior processamento dos dados. Ele também não é eficiente para detectar rolos travados conforme citado em 2.2.

Sinal de Temperatura

A fricção dos elementos rolantes resulta no aumento de temperatura do rolamento e, em condições normais de operação, esse calor é dissipado pela condução, convecção e radiação através do rolamento. O calor é gerado pela fricção entre as esferas, as pistas de rolamento e o arrasto e agitação do lubrificante. A fricção resulta na perda de potência que por sua vez resulta na geração de calor. Segundo (HANNON; HOUPERT, 2013), para um rolamento de esferas, o calor total gerado q_{total} pode ser definido como a soma dos fatores definidos na Equação 2.1.

$$q_{total} = q_{BDC} + q_{drag} + q_{CLR} + q_{CPB} + q_{HD} \quad (2.1)$$

Onde q_{BDC} é o calor gerado pela fricção das esferas e a pista de rolamento, q_{drag} é a parcela de calor gerada pelo arrasto e agitação do lubrificante, q_{CLR} é a parcela de calor gerada entre a gaiola e a pista de rolamento, q_{CPB} é a parcela gerada de calor entre a gaiola e as esferas e q_{BDC} é a parcela de calor que provém da contribuição hidrodinâmica. Normalmente, os fatores q_{CLR} e q_{CPB} gerados pela interação com a gaiola são pequenos e podem ser desconsiderados. O fator q_{BDC} é o somatório do calor gerado por cada elemento de ($j=1$ até Z) para as pistas externa e interna ($n=i$ ou $n=0$), ver Equação 2.4. E o valor de cada esfera pode ser calculado nos termos do contato elíptico nas dimensões a e b , direções x e y do toque τ e velocidade v deslizante.

$$q_{ynj} = \int_{-a}^a \int_{-b}^b \tau_{ynj} v_{ynj} dA_{nj} \quad (2.2)$$

$$q_{xnj} = \int_{-a}^a \int_{-b}^b \tau_{xnj} v_{xnj} dA_{nj} \quad (2.3)$$

$$q_{BDC} = \sum_{n=i}^{n=0} \sum_{j=i}^Z (q_{ynj} + q_{xnj}) \quad (2.4)$$

O calor gerado pelo arrasto viscoso nas esferas e gaiola é função do volume do lubrificante, da área da esfera, velocidade e o coeficiente de arrasto.

$$q_{drag} = \frac{d_m \omega_m Z}{2} (C_v \pi (1 - \chi) D_2 (d_m \omega_m)^{1,95}) \quad (2.5)$$

Na Equação 2.5, d_m é o diâmetro de passo, χ é a proporção de gás com relação ao volume total possível de lubrificante, D é o diâmetro da esfera, Z é o número de esferas, ω é a velocidade orbital da gaiola e C_v é o coeficiente de arrasto. A contribuição hidrodinâmica q_{HD} não é detalhada neste trabalho mas pode ser encontrada em (AI; HANNON; KOTZALAS, 2013). Quando o rolamento opera dentro das suas especificações e sem defeitos, o calor gerado é dissipado para o ambiente através da convecção, condução e radiação. No entanto, a presença de um defeito faz com que o atrito cresça consideravelmente, aumentando a geração de calor, podendo levar o rolamento a entrar em círculo vicioso. Onde o calor irá gerar a deterioração do lubrificante que é o responsável por grande parte da dissipação do calor, levando o rolamento a patamares inaceitáveis de temperatura que irão ocasionar sua quebra.

O sinal de temperatura pode ser considerado um indicador universal de falhas em rolamentos, pois todas as falhas irão gerar calor quando um certo nível de atrito for atingido. E, apesar de não ser o mais preditivo dos sinais, sua identificação é fácil e rápida tornando-a aplicável para o elevado número de rolos do porto.

2.3 Termografia Infravermelho

Na Grécia antiga, havia muitas teorias para a luz e, de acordo com Demócrito, por exemplo, os corpos emitiam partículas que interagiam com os olhos. Permanecendo a natureza da luz filosófica até que em 1637, quando René Descartes publicou sua dissertação *La Dioptrique*, que apresentava equações para a refração matematicamente corretas (DUFOUR, 2009). Isaac Newton também mostrou interesse pela decomposição da luz branca por um prisma, mas suas teorias ainda suportavam a natureza corpuscular da luz. Somente em 1690 Christiaan Huygens com a publicação do seu livro *Traité de la lumière* (Tratado sobre a luz) expõe pela primeira vez a natureza ondulatória da luz, que se propagava em um meio chamado "éter". Em 1801, Thomas Young prova experimentalmente

a natureza ondulatória da luz e consegue medir o comprimento de onda médio da luz solar, obtendo o valor de 570 nm incrivelmente próximo do valor atualmente aceito de 555 nm (HALLIDAY; RESNICK; WALKER, 2009). James Clerk Maxwell desenvolveu a teoria do eletromagnetismo e demonstrou de forma detalhada como a luz se deslocava baseado no efeito ondulatório do campo eletromagnético. E, finalmente, com o desenvolvimento da física quântica, a dualidade da natureza ondulatória e corpuscular da luz foi demonstrada por dois trabalhos fundamentais, o estudo da radiação emitida por corpos negros de Max Planck e o efeito fotoelétrico de Albert Einstein (DUFOUR, 2009).

A luz visível, que despertou o interesse de grande parte das pesquisas no passado, ocupa apenas uma pequena faixa no espectro de radiação eletromagnética, com comprimento de onda de 400 nm até 700 nm aproximadamente como ser visto na Figura 9. Já a banda infravermelha, que, assim como a luz visível também é uma radiação eletromagnética, ocupa uma banda mil vezes maior com comprimentos de ondas entre 0,78 μm a 1 mm (CANIOU, 2013). Mas, por ser invisível ao olho humano só foi descoberta em 1800 por William Herschel, que com a ajuda de um termômetro posicionado próximo a parte vermelha do espectro da luz visível comprovou a existência de uma energia invisível através do aquecimento. Mais tarde ele também provou que essa radiação também seguia as mesmas leis da luz visível (GAUSSORGUES; CHOMET, 1994).

Radiação Infravermelho

Primeiramente é importante definir a *Infrared Thermography* (IRT) ou em português Termografia Infravermelho. Muitas vezes na literatura encontramos a palavra termografia utilizada para descrever a IRT ou mesmo a palavra *Infrared* (IR), em português Infravermelho (IV), com a mesma finalidade. A palavra termografia tem o significado de mapa de temperaturas que pode ou não ser obtido através da radiação IR, que por sua vez pode ou não ser utilizada para gerar um mapa de temperaturas. Uma definição criteriosa é dado a IRT por (MALDAGUE, 2001), como uma ciência dedicada a aquisição e processamento da informação térmica mensurada através de um dispositivo sem contato com o objeto. Neste trabalho, será dado preferência pelo uso dos acrônimos em inglês IRT e IR.

A Tabela 1 detalha a região de radiação térmica, destacada em rosa na Figura 9, que engloba parte da radiação ultravioleta, toda a região de luz visível, parte da região infravermelho e uma pequena parte da região de micro-ondas que possui sobreposição com a região de *Very Long Wavelength Infrared* (VLWIR), ou em português ondas muito longas de infravermelho.

As faixas de frequência IR têm várias definições possíveis dependendo do tipo de aplicação, neste trabalho foi usada a classificação apresentada em (LIU et al., 2015). O espectro IR foi dividido em cinco faixas, a primeira delas a *Near Infrared* (NIR) que

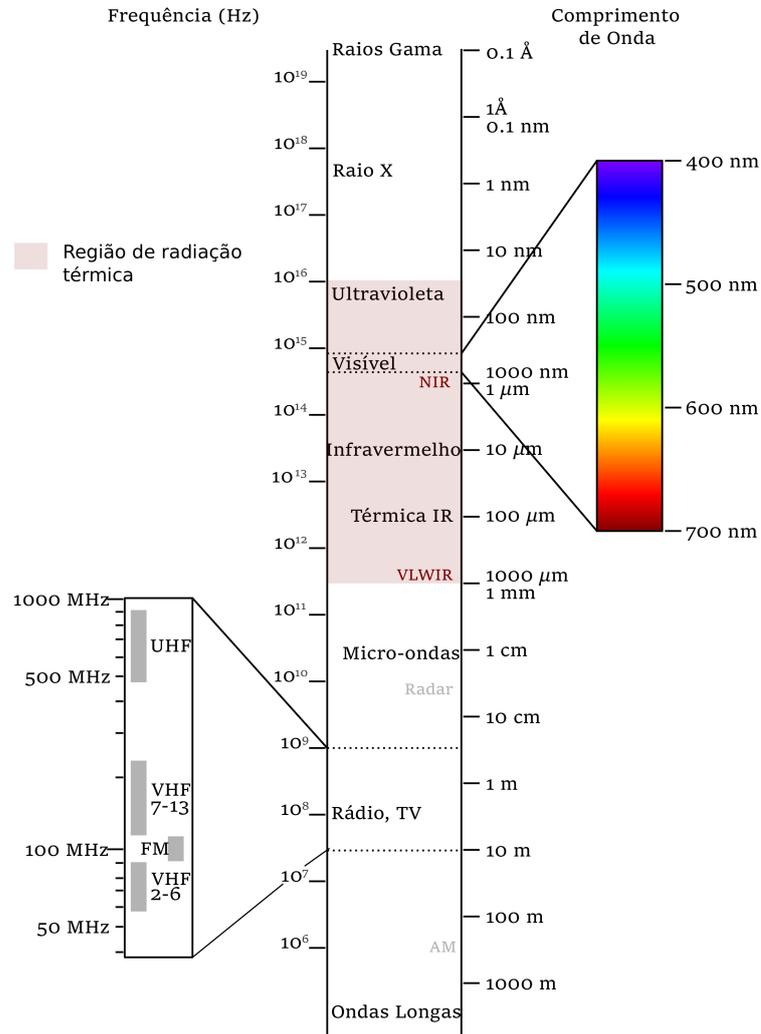


Figura 9 – Espectro Eletromagnético. Fonte: Figura foi adaptada de (COMMONS, 2016a) e o arquivo modificado está disponível em (COMMONS, 2017).

Tabela 1 – Faixas do Espectro Infravermelho com os Respectivos Comprimentos de Onda

Acrônimo	Descrição em Inglês	Descrição em Português	Comprimento de Onda
NIR	<i>Near Infrared</i>	Próximo ao Infravermelho	0,7 – 1 μ m
SWIR	<i>Short Wavelength Infrared</i>	Ondas Curtas de Infravermelho	1 – 2,5 μ m
MWIR	<i>Mid Wavelength Infrared</i>	Ondas Médias de Infravermelho	3 – 5 μ m
LWIR	<i>Long Wavelength Infrared</i>	Ondas Longas de Infravermelho	7,5 – 14 μ m
VLWIR	<i>Very Long Wavelength Infrared</i>	Ondas Muito Longas de Infravermelho	14 – 1000 μ m

contém os comprimentos de onda de $0,7$ a $1\mu m$, a *Short Wavelength Infrared* (SWIR) com comprimentos de onda de 1 até $2,5\mu m$, a *Mid Wavelength Infrared* (MWIR) com comprimentos de onda variando de 3 a $5\mu m$, a *Long Wavelength Infrared* (LWIR) cujos comprimentos de onda começam em $7,5$ e vão até $14\mu m$ e a VLWIR com comprimentos de onda de 14 a $1000\mu m$. Outra classificação também apresentada em (LIU et al., 2015) é a dos tipos de sensores para cada uma das faixas do espectro IR. A Tabela 2 apresenta o tipo de material utilizado nos sensores e seus respectivos comprimentos de onda. A quarta coluna da Tabela 2 classifica-os entre térmicos e não térmicos, essa distinção é necessária para diferenciá-los em relação a origem da radiação recebida. Nas faixas NIR e SWIR, o princípio de detecção se baseia na radiação refletida ou transmitida pelo objeto de interesse. Por outro lado, o alicerce da detecção das faixas MWIR, LWIR e VLWIR provém da radiação emitida pelo corpo de interesse.

Tabela 2 – Tipos de Sensores, Material Utilizado e Faixa de Operação

Espectro IR	Comprimento de Onda	Material Típico dos Sensores	Tipo do Sensor
NIR	$0,7 - 1\mu m$	Si ($0,5 - 1,1\mu m$) InGaAs ($0,8 - 1,8\mu m$)	Não Térmico
SWIR	$1 - 2,5\mu m$	PbS ($1,3 - 3,5\mu m$) InGaAs ($0,8 - 1,8\mu m$) InAs ($1 - 3,8\mu m$)	
MWIR	$3 - 5\mu m$	InSb ($3 - 5,5\mu m$) PbSe ($2 - 6\mu m$) HgCdTe ($2 - 14\mu m$)	Térmico
LWIR	$7,5 - 14\mu m$	Microbolometers HgCdTe ($2 - 14\mu m$)	
VLWIR	$14 - 1000\mu m$	-	

A Lei de Planck

A IRT é baseada na radiação infravermelho que é uma forma de radiação eletromagnética com comprimentos de ondas maiores que a luz visível e frequências menores que a da cor vermelha. O princípio básico de seu funcionamento é de que qualquer objeto com temperatura acima do zero absoluto $T > 0K$ emite radiação IR (MODEST, 2013a). Sendo a intensidade e o comprimento de onda dependente da temperatura do material.

A lei de Planck define a radiação emitida por um corpo negro a certa temperatura. O corpo negro ideal é capaz de absorver a totalidade da radiação incidente, não importando o comprimento de onda. Ele também emite a radiação de maneira uniforme em todas as direções e quando atinge o equilíbrio térmico para uma certa temperatura, a radiância

espectral $N_{\lambda,b}$ é dada pela lei de Planck (Equação 2.6):

$$N_{\lambda,b} = \frac{2hc^2}{\lambda^5} \frac{1}{\exp\left(\frac{hc}{\lambda kT} - 1\right)} \quad (Wm^{-2}sr^{-1}\mu m^{-1}) \quad (2.6)$$

Onde h é a constante de Planck, c é a velocidade da luz, k é a constante de Boltzmann, λ é o comprimento de onda em (μm), T é a temperatura do corpo negro em (K) e o subscrito b em $N_{\lambda,b}$ indica tratar-se de um corpo negro (MALDAGUE, 1993). No caso de objetos reais em que a absorção é limitada, apenas parte da energia será irradiada pela superfície, essa fração da da energia que um corpo negro emitiria é dada pela propriedade da superfície do material chamada emissividade ε . Por exemplo, um objeto com 0.5 de emissividade irá emitir apenas 50% da energia de um corpo negro na mesma temperatura. Existem duas classificações adicionais para os objetos que não são corpos negros. A primeira delas, os corpos cinzas, são objetos cuja emissividade não depende do comprimento de onda. A segunda e mais comum são os chamados corpos coloridos, em que a emissividade do objeto depende do comprimento de onda, da temperatura e do ângulo de visão. Para esses dois tipos, a lei de Planck pode ser dada em função do corpo negro na mesma temperatura, conforme mostra equação 2.7:

$$N_{\lambda} = \varepsilon N_{\lambda,b}(\lambda, T) \quad (Wm^{-2}sr^{-1}\mu m^{-1}) \quad (2.7)$$

Na Equação 2.7 a radiância espectral para um dado comprimento de onda é dado por N_{λ} e a emissividade ε é função da temperatura $T(K)$, do ângulo de visão θ e do comprimento de onda λ , tem-se então $\varepsilon(T, \theta, \lambda)$.

Quando a radiação IR incide sobre um objeto, parte dela irá ser refletida, parte irá ser absorvida e o restante será transmitida. Pode-se então definir-se três propriedades fundamentais da radioatividade incidente em um corpo, ver equações 2.8, 2.9 e 2.10. Essas três propriedades estão relacionadas pela equação 2.11.

$$\text{Refletância} \Rightarrow \rho \equiv \frac{\text{Parte da radiação incidente refletida}}{\text{Total da radiação incidente}} \quad (2.8)$$

$$\text{Absortância} \Rightarrow \alpha \equiv \frac{\text{Parte da radiação incidente absorvida}}{\text{Total da radiação incidente}} \quad (2.9)$$

$$\text{Transmitância} \Rightarrow \tau \equiv \frac{\text{Parte da radiação incidente transmitida}}{\text{Total da radiação incidente}} \quad (2.10)$$

$$\text{Relação entre as propriedades} \Rightarrow 1 = \rho + \alpha + \tau \quad (2.11)$$

Para os corpos opacos, a transmitância é $\tau \approx 0$ e pode ser considerada nula (MODEST, 2013b). Tem-se então $1 = \rho + \alpha$, e, de acordo com a lei de Kirchhoff's, quando um corpo está em equilíbrio termodinâmico a taxa de radiação absorvida α deve ser igual a taxa de radiação emitida ε , resultando na Equação 2.12.

$$1 = \rho + \varepsilon \quad (2.12)$$

Em face dessas considerações, pode-se introduzir a equação fundamental da IRT, Equação 2.13, que governa o total de radiação recebida pela câmera radiométrica.

$$N_{cam} = \varepsilon\tau_{atm}N_{obj} + (1 - \varepsilon)\tau_{atm}N_{amb} + (1 - \tau_{atm})N_{atm} \quad (2.13)$$

Onde:

$N_{cam} \Rightarrow$ Total de radiação térmica incidente nas lentes da câmera;

$N_{obj} \Rightarrow$ Total de radiação radiada proveniente da superfície do objeto;

$N_{amb} \Rightarrow$ Total de radiação radiada proveniente do ambiente;

$N_{atm} \Rightarrow$ Total de radiação radiada proveniente da atmosfera;

$\varepsilon \Rightarrow$ Emissividade do objeto;

$\tau_{atm} \Rightarrow$ Transmitância da atmosfera.

Na equação 2.13, N_{cam} é o total de radiação térmica recebida pela câmera, N_{obj} é a radiação proveniente da superfície do objeto, N_{amb} é a radiação proveniente do ambiente (que é considerado como um corpo negro) e N_{atm} que é a radiação proveniente da atmosfera (considerada constante) (MALDAGUE, 1993). O parâmetro ε é a emissividade do objeto, enquanto que τ_{atm} é a transmitância da atmosfera em uma determinada banda espectral de interesse. Alguns fatores externos tem influência direta nesses parâmetros, como a umidade relativa, a temperatura atmosférica e a distância da câmera ao objeto (Flir System, 2013).

A Lei do Deslocamento de Wien

A curva de radiação espectral a uma temperatura constante passa em um máximo. O deslocamento desse máximo em função da variação de temperatura é dada pela lei do deslocamento de Wien, Equação 2.14. Que pode ser obtida através da diferenciação da Lei de Planck. Por exemplo, para o sol que tem temperatura aparente de $6000K$ o comprimento de onda de pico será de $\lambda_{max} = 0,5\mu m$, que é exatamente o meio da faixa de luz visível (GAUSSORGUES; CHOMET, 1994).

$$\lambda_{max} = \frac{2898}{T} \mu m \quad (2.14)$$

Essa equação mostra que com o aumento de temperatura a abcissa do máximo de radiação espectral é deslocada para menores comprimentos de onda. Então, com o

aquecimento do objeto, o máximo de energia se desloca em direção a banda de comprimentos de onda da luz visível. Na temperatura ambiente, aproximadamente $300K$, o comprimento de onda é de $\lambda_{max} = 10\mu m$, situando-se na faixa LWIR, ou seja, a radiação emitida é invisível ao olho humano.

Tabela 3 – Comprimento de Onda do Pico de Radiância Espectral para Várias Temperaturas. Fonte: Adaptada de (BAGAVATHIAPPAN et al., 2013)

Temperatura (K)	Evento Físico	Comprimento de Onda Máximo (μm)
3864	Limite inferior da região IR	0,75
1811	Ponto de derretimento do aço	1,60
1420	Temperatura eutética do aço carbono	2,04
1000	Ponto eutetóide do aço carbono	2,89
933	Ponto de derretimento do alumínio	3,10
373	Ponto de ebulição da água	7,77
303	Temperatura ambiente	9,56
273	Ponto de fusão da água	10,61
77	Ponto de liquefação do nitrogênio	37,63

Na Tabela 3, estão relacionadas várias temperaturas de objetos, com os eventos físicos correspondentes e o comprimento de onda para o máximo de energia emitido. Todos os objetos na Tabela 3 são considerados corpos negros. Pode-se ver que, para temperaturas superiores a $3864K$, o comprimento de onda se aproxima do espectro visível.

Aplicação para a Identificação de Defeitos

O uso da IRT para inspecionar os mais diversos tipos de falhas cresceu bastante nas últimas décadas. Os principais fatores para esse crescimento foram a queda no preço das câmeras térmicas e o desenvolvimento de equipamentos mais confiáveis. Hoje as câmeras IR têm sido utilizadas com sucesso para inspecionar estruturas civis, equipamentos elétricos, placas de circuitos elétricos, placas de energia solar, vapores químicos, tubulações, linhas de transmissão, plantas nucleares, diagnóstico médico, vigilância e máquinas rotativas. A IRT pode ser dividida em duas categorias principais, a passiva e a ativa. Na IRT ativa uma fonte de calor externa é utilizada para aquecer o objeto sob inspeção, como por exemplo materiais compostos utilizados em aviões. Durante o processo, as regiões com defeitos irão apresentar temperatura diferente das regiões sem defeito (USAMENTIAGA et al., 2014). Já a IRT passiva não utiliza qualquer fonte de calor externa, pois os equipamentos ou componentes sob inspeção, como por exemplo os rolamentos, irão gerar calor em excesso diferente da operação sem falhas.

Para a efetividade de cada tipo de aplicação da IRT certas premissas devem ser atendidas, sendo os três principais fatores: o procedimento adotado, o conhecimento técnico

Tabela 4 – Normas Brasileiras de Termografia e Algumas Normas Internacionais Relevantes

Norma	Tópico	Título da Norma
ABNT NBR 16554:2016	Correção da Transmitância	Ensaaios não destrutivos - Termografia - Medição e compensação da transmitância de um meio atenuante utilizando câmeras termográficas
ABNT NBR 15424:2016	Terminologia	Ensaaios não destrutivos - Termografia - Terminologia
ABNT NBR 16485:2016	Correção da Emissividade	Ensaaios não destrutivos - Termografia - Medição e compensação da emissividade utilizando câmeras termográficas ou radiômetros
ABNT NBR 16292:2014	Correção da Temperatura	Ensaaios não destrutivos — Termografia — Medição e compensação da temperatura aparente refletida utilizando câmeras termográficas
ABNT NBR 15572:2013	Inspeção Equipamentos	Ensaaios não destrutivos — Termografia — Guia para inspeção de equipamentos elétricos e mecânicos
ABNT NBR 15866:2010	Inspeção Elétrica	Ensaio não destrutivo — Termografia — Metodologia de avaliação de temperatura de trabalho de equipamentos em sistemas elétricos
ABNT NBR 15763:2009	Inspeção Elétrica	Ensaaios não destrutivos - Termografia - Critérios de definição de periodicidade de inspeção em sistemas elétricos de potência
ABNT NBR 15718:2009	Teste de Equipamento	Ensaaios não destrutivos — Termografia — Guia para verificação de termovisores
ASTM-E 1862-97	Correção da Temperatura	<i>Standard test methods for measuring and compensating for reflected temperature using infrared imaging radiometers</i>
ASTM-E 1933-99a	Correção da Emissividade	<i>Standard test methods for measuring and compensating for emissivity using infrared imaging radiometers</i>
ANSI/IEEE C37.010-4.4.3	Inspeção Elétrica	<i>IEEE application guide for AC high-voltage circuit breakers rated on a symmetrical current basis</i>
ISO 18434	Inspeção Mecânica	<i>Condition monitoring and diagnostics of machines-thermography</i>
IS 12782	Inspeção Industrial	<i>Guidelines for using thermography for monitoring of industrial components</i>
ASTM-E 2582-07	Inspeção Aeroespacial	<i>Standard practice for infrared flash thermography of composite panels and repair patches used in aerospace applications</i>
ASTM C 1153-10	Inspeção Civil	<i>Standard practice for location of wet insulation in roofing systems using infrared imaging</i>

do objeto e as condições ambientais durante a medição. O adoção do procedimento correto é muito importante e sua falta ou não cumprimento pode levar a erros de medição ou

interpretação. Por exemplo, deve-se realizar a inspeção das linhas de transmissão energizadas e com carga, pois sem a presença de corrente elétrica toda a linha de transmissão estará na temperatura ambiente e os defeitos não serão evidenciados. E dependendo da aplicação os procedimentos adotados podem ser mais rigorosos, os equipamentos militares, por exemplo, requerem uma confiabilidade elevada e seguem parâmetros diferenciados, conforme ([Infraspection Institute, 2008](#)). A Tabela 4 lista as normas brasileiras de termografia e algumas normas internacionais relevantes. Pode-se verificar que existem normas específicas para diferentes tipos de aplicação da IRT.

O conhecimento técnico do instrumento também é fundamental, pois fatores como a emissividade e a distância do objeto até a câmera desempenham um papel fundamental na correta leitura de temperatura, conforme Equação 2.13. A norma ABNT NBR 16485:2016, também listada na Tabela 4, define métodos e ensaios para a correta seleção da emissividade. E, por último, as condições ambientais que não podem ser controladas para medições em campo e também podem sofrer grandes variações instantaneamente ou ao longo do dia. Influenciam de várias maneiras o valor de temperatura medida, por exemplo, um aumento na temperatura ambiente leva a valores medidos de temperatura mais elevados, já a presença de chuva altera a umidade do ambiente, que por sua vez leva a valores mais baixos de temperatura medidos ([BAGAVATHIAPPAN et al., 2013](#)). Também deve-se levar em consideração a hora do dia, uma vez que a radiação solar pode ser refletida na superfície do objeto alterando o valor medido. As Normas ABNT NBR 16554:2016 e ABNT NBR 16292:2014 definem métodos para a correção de parâmetros associados a fatores ambientais como a transmitância e a refletância, respectivamente.

2.4 Processamento de Imagens

A visão é um dos sentidos mais desenvolvidos nos humanos e faz-se um uso extensivo desse sentido. A quantidade de informação recebida em uma única imagem é gigantesca e o cérebro a processa instantaneamente para o posterior processo de decisão. Com a inspeção de equipamentos não é diferente, o inspetor usa constantemente sua visão para identificar defeitos através da comparação entre a imagem atual e o padrão esperado. O processamento digital de imagens despertou o interesse de vários pesquisadores nas últimas décadas e continua em crescimento vertiginoso. O grande desafio é conseguir que as máquinas façam o que o homem faz tão bem, quando trata-se do processamento de imagens, a identificação de padrões. Essa seção faz uma breve introdução dos conceitos básicos do processamento de imagens.

Captura da Imagem

O primeiro passo para se processar uma imagem é adquiri-la. E tanto as câmeras digitais quanto o olho humano possuem uma série de sensores para desempenhar essa tarefa. No entanto, enquanto as câmeras digitais possuem milhares de sensores o olho humano possui milhões. No Apêndice B o leitor interessado pode encontrar uma breve descrição do funcionamento da visão humana.

As imagens digitais são obtidas na forma de sinais elétricos, que posteriormente são digitalizadas em uma sequência de números que podem ser processados pelos computadores. Existem vários arranjos de sensores para capturar as imagens, sendo os mais comuns: o uso de um único sensor, de uma linha de sensores ou de uma matriz de sensores. E entre os arranjos matriciais o tipo de sensor mais utilizado é o *Charge Coupled Device* (CCD) (em português, Dispositivo de Carga Acoplada) que consiste de elementos fotossensíveis que acumulam carga elétrica através da absorção de fótons (JÄHNE, 2005). Dessa maneira a carga de cada elemento é proporcional a radiação eletromagnética emitida pelo objeto, no caso das câmeras digitais, a faixa de frequência para a qual o sensor é mais sensível se situa na banda de luz visível.

Enquanto as cenas e objetos são geralmente tridimensionais, sua representação é realizada em duas dimensões. As câmeras digitais, basicamente transformam uma informação tridimensional analógica em uma representação bidimensional digital. O processo começa com a amostragem do sinal analógico, que é realizado pela matriz de sensores da câmera, ou seja, se a matriz for 640x520 teremos 332.800 amostras. O segundo passo é a quantização, que transforma os valores contínuos de intensidade coletados por cada sensor em valores discretos. Após essa etapa, uma imagem em escala de cinza pode ser representada pela função discreta $f(x, y)$ da Equação 2.15 (SUNDARARAJAN, 2017).

$$f(x, y) = \begin{bmatrix} f(0, 0) & f(0, 1) & f(0, 2) & \dots & f(0, N - 1) \\ f(1, 0) & f(1, 1) & f(1, 2) & \dots & f(1, N - 1) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ f(M - 1, 0) & f(M - 1, 1) & f(M - 1, 2) & \dots & f(M - 1, N - 1) \end{bmatrix} \quad (2.15)$$

Na Equação 2.15, a imagem está descrita em uma matriz $M \times N$ em que cada elemento $f(x, y)$ contém um valor de intensidade que foi quantizado. Eles são chamados de elementos de imagem, elementos pictóricos ou pixels. Esse tipo de abordagem também é conhecido como representação espacial, onde a matriz $f(x, y)$ pode ser mostrada como uma superfície com os eixos m e n definindo o plano de base e os valores de intensidade a altura.

Na Figura 10, tem-se duas representações da mesma cena. Na Figura 10a, para cada valor de intensidade coletado pela câmera foi plotado no plano uma cor em escala de

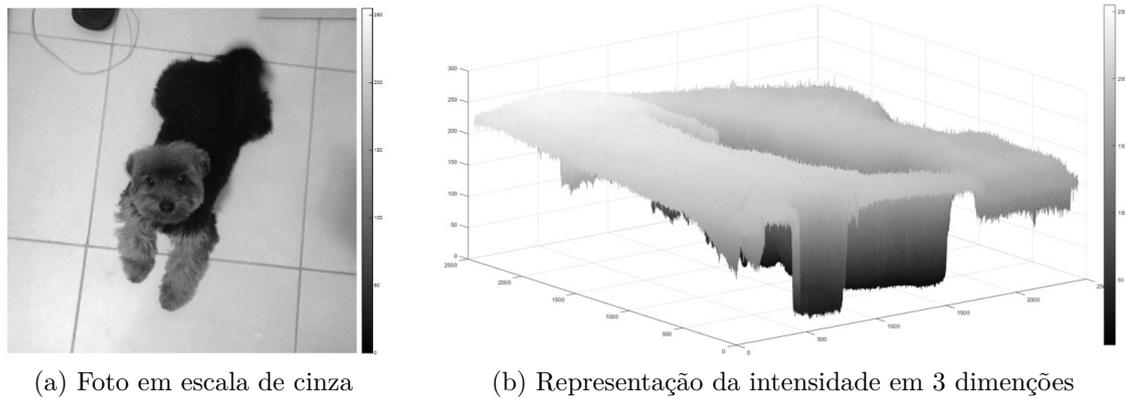


Figura 10 – Duas representações da mesma cena: **(a)** A foto em escala de cinza atribui o valor zero para o preto e o valor 250 para o branco, cada cor do plano representa um valor de intensidade coletado pela câmera. **(b)** Nesta representação cada valor de intensidade é plotado como uma altura no eixo z. Fonte: Autor.

cinza, começando com a cor preta que representa o zero até o branco que representa o valor 250. Na segunda representação, mostrada na Figura 10b, os valores coletados foram plotados em 3 eixos com o eixo vertical z representando a altura e também variando de 0 a 250. O ponto superior esquerdo da Figura 10a é o ponto $(0,0,z)$ da Figura 10b.

Nas imagens coloridas, cada pixel é um vetor que contém 3 valores. Um para cada cor básica: Vermelho, Verde e Azul. Elas podem ser representados por três superfícies, conforme Equação 2.15, uma para cada cor. Esse tipo de representação para imagens coloridas é chamado de *Red, Green and Blue* (RGB) (em português, Vermelho, Verde e Azul). Existem também outros modos de representação de imagens coloridas como o *Cyan, Magenta and Yellow* (CMY) (em português, Ciano, Magenta e Amarelo), que são as cores primárias dos pigmentos. Por exemplo, o ciano subtrai o vermelho e quando uma luz branca incide sobre o ciano nenhuma luz vermelha é refletida. O magenta subtrai o verde e o amarelo subtrai o azul, conforme Equação 2.16.

$$\begin{bmatrix} C \\ M \\ Y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.16)$$

Outro modelo também bastante usado é o *Hue, Saturation and Intensity* (HSI) (em português, Matiz, Saturação e Intensidade). A matiz dá a tonalidade da cor verdadeira, a saturação indica a quantidade de cor branca misturada na cor verdadeira e a intensidade mensura o brilho da cor. Essa abordagem segue o modelo pelo o qual os seres humanos percebem as cores (SUNDARARAJAN, 2017).

Abordagens de Processamento

Duas abordagens de processamento de imagens são amplamente difundidas. A primeira delas é o processamento no domínio espacial que acontece no plano da imagem e faz a manipulação dos pixels. Na segunda, o processamento é feito no domínio da frequência, o que não é muito intuitivo para os humanos, no entanto, algumas características importantes das imagens podem ser adquiridas com maior facilidade nesse domínio. Existem ainda outras transformadas que podem ser utilizadas para o processamento de imagens, mas a análise do domínio da frequência continua sendo a mais utilizada.

Processamento no Domínio Espacial

Conforme explicado na subseção 2.4, as imagens são capturadas no plano espacial e armazenadas em uma matriz ou conjuntos de matrizes. As operações para o processamento de imagens no domínio espacial, são realizadas nos elementos dessas matrizes através de um operador, conforme Equação 2.17 abaixo (GONZALEZ; WOODS, 2010).

$$g(x, y) = T[f(x, y)] \quad (2.17)$$

Em que $f(x, y)$ é a imagem de entrada e $g(x, y)$ a imagem de saída, que foi modificada pelo operador T . Geralmente o operador é uma janela de tamanho muito menor que a imagem, por exemplo 5x5, e o pixel (x, y) a ser modificado está centrado nessa janela. Ele irá usar como entrada o valor de todos os pixels, ou parte deles, da janela para modificar o pixel central. E o processo continuará até que a janela tenha percorrido toda a imagem antiga $f(x, y)$ e modificado todos os pixels para a formação da nova imagem $g(x, y)$.

Entre as principais operações realizadas nesse domínio estão as transformações de intensidade e as filtragens espaciais. As transformações de intensidade são muito úteis para, por exemplo, corrigir o contraste da imagem, que pode ser realizada com a equalização do seu histograma. As filtragens espaciais possuem diversas aplicações e uma das suas principais características é a possibilidade de se criar filtros não lineares, algo que não é possível no domínio da frequência. Outra vantagem das técnicas no domínio espacial é que elas geralmente têm um custo computacional menor que o processamento com o uso de transformadas.

Processamento no Domínio da Frequência

Uma transformada altera a representação do sinal, para facilitar certas operações. O logaritmo, por exemplo, transforma multiplicações em simples somas. E entre todas as transformadas a mais importante é a de Fourier que decompõe um sinal não periódico em

uma composição de senoides. Essa transformada tem diversas aplicações em quase todas as áreas da engenharia e é de fundamental importância no processamento de imagens.

Primeiramente é importante ter-se um entendimento de como funciona a transformada de Fourier para imagens. Como descrito em 2.4, uma imagem digital passa por uma amostragem e quantização do sinal analógico capturado pelos sensores da câmera, ou seja, a imagem digital é um sinal discreto de duas dimensões. Para transformar esse sinal para o domínio da frequência usa-se a *Discret Fourier Transform* (DFT) (em português, Transformada Discreta de Fourier) bidimensional. No entanto, quando fala-se em frequência a ideia inicial é de algo que se repete em um certo intervalo de tempo e na imagem não existe um eixo de tempo. A frequência deve então ser interpretada como algo que se repete a certo intervalo espacial, e como a imagem tem dois eixos espaciais x e y , a frequência sempre conterá uma característica direcional. Pode-se interpretar a frequência de uma imagem como a taxa de variação da intensidade com relação ao espaço, ou plano da imagem (DAS, 2015).

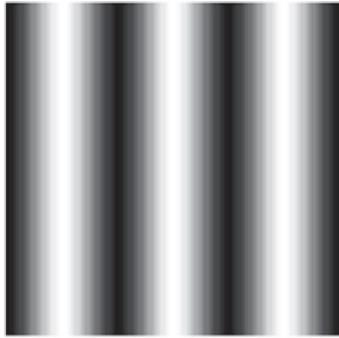
$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \exp(-j2\pi(\frac{ux}{M} + \frac{vy}{N})) \quad (2.18)$$

Na Equação 2.18, $F(u, v)$ é a DFT da imagem de entrada $f(x, y)$. Com a *Inverse Discret Fourier Transform* (IDFT) (em português, Transformada Discreta de Fourier Inversa), Equação 2.19, é possível realizar o processo inverso e obter a imagem $f(x, y)$ através da transformada $F(u, v)$.

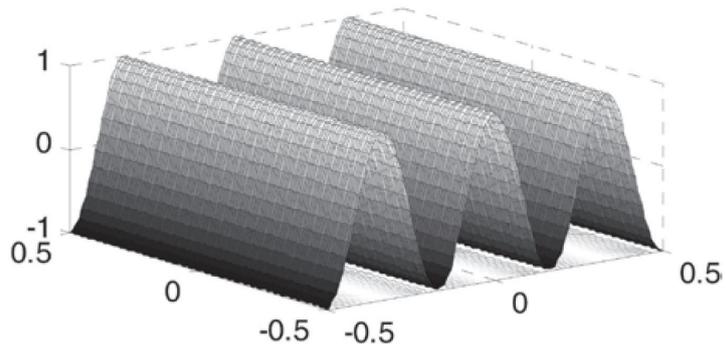
$$f(x, y) = \frac{1}{MN} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u, v) \exp(j2\pi(\frac{ux}{M} + \frac{vy}{N})) \quad (2.19)$$

Na Figura 11, estão plotadas algumas imagens e suas superfícies correspondentes. Na figura 11a existe uma variação de intensidade ao longo de cada linha, mas ela permanece constante ao longo das colunas, como pode ser evidenciado na Figura 11b. O inverso ocorre na Figura 11c, em que a variação agora ocorre ao longo das colunas, ver Figura 11d. Já na Figura 11e a variação de intensidade ocorre verticalmente e horizontalmente, gerando a superfície da Figura 11f.

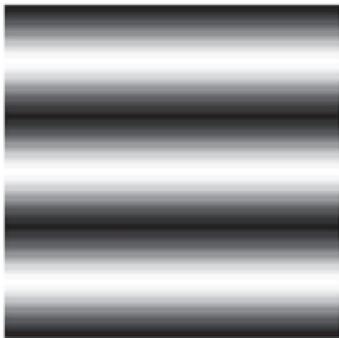
Entre as várias aplicações do processamento no domínio da frequência estão os detectores de bordas, que utilizam filtros passa alta. As bordas dos objetos nas imagens geralmente possuem uma grande diferença de intensidade e isso resulta em uma alta frequência que pode ser filtrada pelos filtros passa alta.



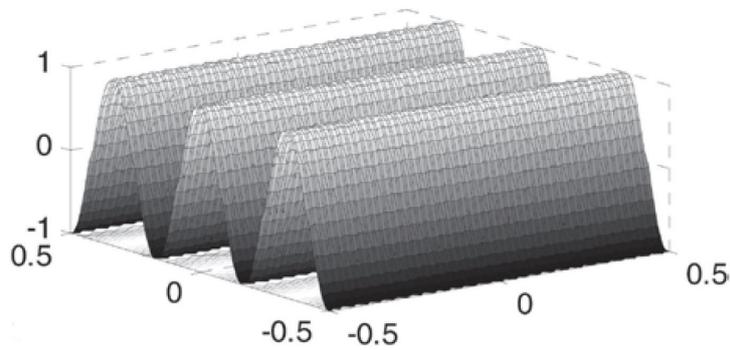
(a) Imagem com listras verticais.



(b) Superfície da Imagem 11a.



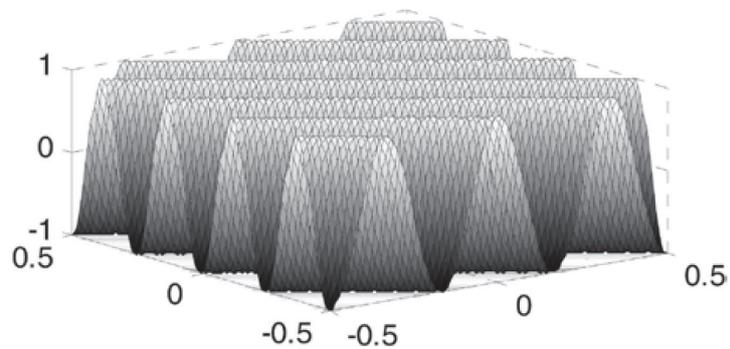
(c) Imagem com listras horizontais.



(d) Superfície da Imagem 11c.



(e) Imagem com listras diagonais.



(f) Superfície da Imagem 11e.

Figura 11 – Algumas imagens e suas superfícies: **(a)** Nesta imagem existe a variação de intensidade no eixo x . **(b)** A variação de intensidade plotada, se apresenta como uma superfície senoidal com frequência na direção x . **(c)** Nesta imagem existe a variação de intensidade no eixo y . **(d)** A variação de intensidade plotada, se apresenta como uma superfície senoidal com frequência na direção y . **(e)** Nesta imagem existe a variação de intensidade nos eixos x e y . **(f)** A variação de intensidade plotada, se apresenta como uma superfície senoidal com frequência na direção diagonal. Fonte: Imagem adaptada de (DAS, 2015).

Extração de Características

Entende-se por característica de um objeto, na imagem, um atributo que se destaca e o distingue dos demais. Por exemplo, algumas das características de um rosto são: os

olhos, a testa, o nariz e a bochecha. Esses elementos podem ser utilizados para identificar um rosto na imagem, e dois objetos que possuam o mesmo conjunto de características devem pertencer a mesma classe de objeto, ou seja, o conjunto de características forma um identificador único. Também é esperado que as características selecionadas para formar o conjunto de identificação sejam invariantes com relação a escala, rotação e translação. A extração de características da imagem é uma pré-etaapa tanto para a segmentação quanto para a classificação.

Segundo (DEMANT; GARNICA; STREICHER-ABEL, 2013), existem diversos tipos de características disponíveis na literatura, mas as de uso mais comum na indústria podem ser divididas em 3 tipos principais: Características Geométricas Básicas, Atributos de Forma e Propriedades em Escala de Cinza.

As Características Geométricas Básicas usam atributos como coordenadas, dimensões e área para diferenciar um objeto dos demais. A lista abaixo apresenta algumas das particularidades que podem ser extraídas.

- **Objeto inscrito no retângulo:** Todo objeto em uma imagem pode estar contido em um retângulo e alguns atributos podem ser extraídos desse fato;
 - **Dimensão:** A largura e altura do retângulo que contém o objeto;
 - **Razão:** A razão entre a altura e largura do retângulo;
- **Área e perímetro:** Geralmente essas propriedades são usadas em um segundo nível, depois de ter segmentado o objeto pela cor, por exemplo;
- **Centroide:** É o centro de gravidade do objeto e pode ser calculado através do seu contorno;
- **Raios:** São calculados o valor máximo e mínimo da distância do centroide até um ponto na borda do objeto.

Apesar de simples essas propriedades encontram uma vasta gama de aplicações. Já os Atributos de Forma, que também usam propriedades externas do objeto, se diferenciam dos primeiros pela complexidade dos seus algoritmos. Estão listados a seguir alguns atributos de forma.

- **Curvatura do contorno:** Coleta a inclinação ao longo do contorno do objeto e armazena em um vetor;
- **Tipo de Fibra:** Coleta a distância entre vários pontos do contorno, como a linha interna de um ponto a outro, a distância entre pontos opostos e etc.;
- **Número de Euler:** Conta o número de buracos contidos em um objeto;
- **Momento:** É usado para descrever peculiaridades do objeto invariantes em escala, rotação e translação;
- **Descritores de Fourier:** Usa a transformada de Fourier para descrever o contorno através de números complexos.

E por último as Propriedades em Escala de Cinza que utilizam a intensidade da imagem para obter características básicas como a intensidade média, mínima e máxima. E também complexas, como a textura, que descreve a aparência da superfície do objeto e dependendo do caso requer um grande esforço matemático. Existe ainda uma infinidade de outras abordagens simples e complexas com aplicabilidade para as mais diversas áreas. Essa subseção apenas apresenta uma pequena parte delas.

Segmentação

Geralmente uma imagem é constituída de regiões com diferentes características. E a segmentação é considerada um pré-processamento essencial para muitas aplicações. Ela consiste em dividir a imagem em várias partes, cada uma contendo informações próprias de cor, intensidade, formato e textura. Por exemplo, na identificação de caracteres, primeiro faz-se a segmentação das regiões da imagem que possuem caracteres e depois é que faz a classificação dos mesmos.

Segundo (GONZALEZ; WOODS, 2010), a segmentação de imagens não triviais é uma das tarefas mais difíceis no processamento de imagens e seu sucesso poderá ser determinante na efetividade da tarefa. É importante então, ter um conhecimento básico das principais técnicas de segmentação de imagens.

Segmentação Baseada nas Bordas

A segmentação baseada nas bordas se utiliza da mudança abrupta dos valores de intensidade nessas regiões para detectá-las. E isso pode ser realizado com o uso de derivadas de primeira e segunda ordem. A derivada de uma função digital é definida em termos de diferenças, e, segundo (GONZALEZ; WOODS, 2010), algumas conclusões podem ser tiradas da aplicação das derivadas em uma imagem:

- As derivadas de primeira ordem em geral produzem bordas mais grossas em uma imagem;
- As derivadas de segunda ordem são melhores para detectar detalhes finos;
- Nas transições de rampa e degrau, as derivadas de segunda ordem produzem resposta dupla;
- Pode-se determinar o tipo de transição, claro-escuro ou escuro-claro, pelo sinal da segunda derivada;

Com o uso dessa técnica, é possível identificar pontos, linhas ou mesmo todo o contorno de um objeto. A detecção de contorno pode ser realizada por um algoritmo sequencial, onde a imagem é lida linha por linha a procura de um máximo valor de derivada. Quando o máximo é encontrado, o algoritmo tenta seguir o valor de máximo nas proximidades da região passo a passo até que o ponto inicial seja novamente atingido

(JÄHNE, 2005).

Segmentação Baseada na Limiarização

Uma das abordagens mais simples para a segmentação da imagem é particioná-la em regiões de acordo com os valores dos pixels. Se for possível determinar as diferentes bandas de valores de intensidade dos objetos e do ambiente, pode-se utilizar a Equação 2.20 para segmentar a imagem.

$$S(x, y) = \begin{cases} obj1, & \text{para } f(x, y) > T1 \\ obj2, & \text{para } T0 < f(x, y) \leq T1 \\ ambiente, & \text{para os demais casos} \end{cases} \quad (2.20)$$

Todos os objetos com intensidade maior que $T1$ serão nomeados com *obj1*, os objetos com intensidade maiores que $T0$ e menores ou iguais a $T1$ serão nomeados com *obj2* e todos os demais pixels fora dos limites estabelecidos serão nomeados como *ambiente*. Deste modo cria-se a máscara de segmentação $S(x, y)$, que poderá ser usada para extrair os objetos desejados da imagem. A chave para o sucesso dessa abordagem é a correta seleção dos limites. Mas, mesmo com alguns algoritmos desenvolvidos para determinar um valor ótimo para os limites, em alguns casos a seleção manual ainda é a melhor solução. Por outro lado, se torna inviável o uso de meios manuais quando a quantidade de imagens é muito grande e para tal os algoritmos de determinação de limites são imprescindíveis (SUNDARARAJAN, 2017).

Segmentação Baseada na Região

O princípio de funcionamento dessa técnica é assumir que os pixels adjacentes de uma mesma região possuem propriedades similares como textura, intensidade e cor. E com base na descontinuidade desses parâmetros as regiões são segmentadas. Geralmente dois tipos de abordagens são utilizados: O crescimento de regiões e a divisão e fusão.

A segmentação baseada no crescimento de regiões agrupa progressivamente pixels adjacentes que possuem as mesmas características. Ela começa em um ponto de referência, ou pontos, e continua até que as diferenças entre as regiões não tenha ultrapassado o limite estabelecido. A seleção correta do ponto de referência é importante, pois diferentes seleções geram diferentes segmentações.

Já a segmentação baseada na divisão e fusão, divide a imagem sucessivamente em regiões menores e a cada divisão realiza um teste para verificar se a imagem necessita ser fundida. O algoritmo funciona da seguinte maneira (JAIN; LAXMI, 2018): Se qualquer região é não homogênea, ela é dividida em regiões menores, se ainda assim essas regiões são não homogêneas, uma nova divisão é feita. E, em seguida, cada bloco é avaliado e

se necessário os blocos são novamente fundidos. O algoritmo continua até que não sejam mais encontradas partes não homogêneas ou não seja possível realizar uma nova divisão.

Segmentação Baseada em Watershed

Watershed em português significa bacia hidrográfica e essa poderosa ferramenta de segmentação morfológica faz analogia com esse fenômeno geográfico para a segmentação. A imagem é interpretada como uma superfície, como na Figura 10b, com duas coordenadas espaciais x e y e a intensidade como a altura, plotada no eixo z . (GONZALEZ; WOODS, 2010) faz uma ótima analogia de como essa técnica funciona. Segundo o autor, deve ser feito um furo em cada mínimo regional da imagem, em seguida toda a superfície é inundada de baixo para cima pelos furos. Quando a água está prestes a transbordar para um região de mínimo adjacente uma barreira é construída e esse processo continua até que seja possível visualizar somente o topo das barreiras. A segmentação é dada pela linha final da barreira. Um dos problemas apresentados por essa abordagem é a super-segmentação, ou seja um número elevado de regiões de baixa relevância segmentadas. Isso ocorre quando a imagem possui muitos mínimos locais e uma das soluções adotadas é o pré-processamento com o uso de um filtro de suavização.

O processo de segmentação de imagens é extremamente relevante para o reconhecimento de padrões e inteligência visual e deve se tornar ainda mais importante nos próximos anos. Nesta Subsecção de Segmentação 2.4 foi dada uma visão básica dos processos de segmentação clássicos, e uma consulta ao estado da arte e novas tendências podem ser encontrados em (JAIN; LAXMI, 2018), (LI; NGAN, 2011), (DE et al., 2016), (PLATANIOTIS; VENETSANOPOULOS, 2000) e (DOLLÁR et al., 2014).

O intuito do presente autor com a Secção de Processamento de Imagens 2.4 foi de fazer uma introdução básica sobre este assunto de suma importância para o presente trabalho. Abstendo-se de falar sobre todas as áreas do processamento de imagens ou mesmo se aprofundar em qualquer uma delas, pois isso iria requerer muito mais que uma dissertação. No entanto, detalhes das técnicas de processamento de imagem utilizadas serão dadas nos Capítulos Trabalhos Relacionados 3 e Desenvolvimento e Resultados 5.

3 Trabalhos Relacionados

No capítulo anterior, foi visto a teoria geral que suporta o presente trabalho, através de uma breve introdução sobre os TCs, meios de sensoriamento, princípios da termografia e uma visão geral sobre o processamento de imagens. Neste capítulo, é apresentada uma pesquisa de aplicações semelhantes à aqui proposta, com o uso do processamento de imagens e da termografia infravermelho. Alguns artigos encontrados nessa pesquisa são brevemente comentados na Seção 3.1. Logo após serão detalhados 3 artigos que foram chave para o desenvolvimento da solução de identificação de rolos através do processamento digital de imagens. O primeiro deles (VIOLA; JONES, 2001) (Seção 3.2), escrito a 16 anos atrás foi um marco na identificação de faces e mesmo hoje continua entregando bons resultados. O segundo (DALAL; TRIGGS, 2005) (Seção 3.3) lançou em 2005 um poderoso extrator de característica e hoje é amplamente usado nas mais variadas técnicas. E por último o (DOLLÁR et al., 2014) (Seção 3.4) que contém certa inspiração na abordagem proposta por (VIOLA; JONES, 2001) e hoje figura entre um dos algoritmos mais eficientes na detecção de pedestres.

3.1 Processamento de Imagens Térmicas para o Diagnóstico de Falhas

Após uma extensa busca não foram encontrados artigos que apresentem a mesma proposta, deste trabalho, para a detecção de defeitos em rolos. No entanto, foram encontradas várias abordagens semelhantes para o monitoramento de condição em outros tipos de objetos. O uso das técnica de IRT está mais desenvolvido para aplicação em equipamentos elétricos, e durante a última década o seu uso foi estendido para diversas outras áreas industriais (BAGAVATHIAPPAN et al., 2013). Em artigos recentemente publicados o processamento de imagens juntamente com a IRT foram utilizados para obter melhores resultados ou mesmo identificar falhas, que antes não era possível por somente um dos processos.

O artigo *A new thermographic NDT for condition monitoring of electrical components using ANN with confidence level analysis* (HUDA et al., 2014) (em português, Um novo teste não destrutivo (NDT) termográfico para monitorar as condições de componentes elétricos usando redes neurais artificiais (ANN) com análise dos níveis de confiança) propõe uma maneira de se eliminar a análise humana para identificar regiões sobreaquecidas em equipamentos elétricos. O método usa redes neurais artificiais para classificar as regiões em sobreaquecidas ou normais. Um total de 15 características são extraídas das imagens

em escala de cinza e utilizadas como entrada da rede neural, mas a temperatura não é uma delas, e o próprio autor reconhece na conclusão que isso é uma melhoria a ser adicionada no futuro. Outro ponto importante é que apesar da proposta de automaticamente classificar as regiões em sobreaquecidas ou normais, a delimitação das ROIs continua sendo executada de maneira manual.

Já no artigo *A novel intelligent fault diagnosis method for electrical equipment using infrared thermography* (ZOU; HUANG, 2015) (em português, um novo método inteligente para diagnosticar falhas em equipamentos elétricos usando termografia infravermelho) é apresentada uma maneira de identificar automaticamente defeitos em equipamentos elétricos. O primeiro passo adotado pelos autores é de identificar as ROIs usando um algoritmo de agrupamento da média-K (em inglês, *K-means clustering*). Depois, em cada uma destas regiões são extraídas características de temperatura e área. Esses dados são então utilizados como entrada de uma *Support Vector Machine* (SVM) para a classificação das regiões como defeituosas ou não. A temperatura de cada ponto é adquirida através de uma equação que transforma os valores em escala de cinza em valores de temperatura, no entanto, esses valores poderiam ser adquiridos diretamente da câmera térmica eliminando o erro dessa transformada. O único processamento de imagem proposto pelo autor é o agrupamento de regiões com mesma intensidade, em escala de cinza, e o cálculo de sua área. Portanto o método proposto não irá conseguir diferenciar regiões com alta temperatura que não pertencem a equipamentos elétricos e não possuam falhas. Na sua conclusão o autor reconhece a dificuldade na identificação das ROIs, mas como os defeitos que ele se propõe identificar possuem temperatura próximas a 100 °C a acurácia calculada do método foi de 97,84%.

Em (YOUNUS; YANG, 2012) e (JANSSENS et al., 2015) são propostos modelos automáticos para a identificação de falhas em equipamentos rotativos utilizando o processamento de imagens térmicas. O foco do artigo *Intelligent fault diagnosis of rotating machinery using infrared thermal image* (YOUNUS; YANG, 2012) (em português, Diagnóstico inteligente de máquinas rotativas utilizando imagem térmica) é diferenciar entre os numerosos tipos de falhas que uma máquina rotativa pode apresentar. À vista disso, são extraídas características da imagem térmica que serão depois classificadas com o uso de uma SVM. No entanto, não é proposto nenhum método para a detecção da ROI, pois o experimento é realizado em laboratório com uma câmera térmica diretamente apontada para a máquina sob inspeção. E também a temperatura não é diretamente usada como uma das entradas pois as características são extraídas da imagem em escala de cinza. Já no artigo *Thermal image based fault diagnosis for rotating machinery* (JANSSENS et al., 2015) (em português, Diagnóstico de falhas baseado em imagem térmica para máquinas rotativas) o autor propõe dois fluxos, um para a detecção de desbalanceamento e outro para a identificação de falhas em rolamentos. O método também é baseado na extração de características da imagem em escala de cinza, que servem de entrada para uma SVM

que classifica os diversos tipos de defeitos em rolos. Novamente o valor de temperatura é usado indiretamente e não é proposto qualquer algoritmo para selecionar as ROI.

Entre os artigos pesquisados o que possui maior semelhança com a abordagem aqui proposta é o *On-line automatic detection of foreign bodies in biscuits by infrared thermography and image processing* (SENNI et al., 2014) (em português, Detecção automática em tempo real de corpos estranhos em biscoitos usando termografia infravermelho e processamento de imagens). O autor propõe a utilização do processamento de imagens para delimitar a região de cada biscoito e seguir cada uma delas para que a análise do mesmo biscoito não seja realizada mais de uma vez. Esta etapa é realizada através de uma imagem de referência previamente adquirida que é comparada com a imagem coletada para a identificação dos biscoitos. A câmera térmica foi instalada na saída do forno para medir a temperatura dos biscoitos enquanto ainda aquecidos, e assim pode-se afirmar que é utilizado a termografia ativa. Como todos os biscoitos devem ser iguais e também homogêneos na sua composição, uma temperatura interna diferente pode indicar um corpo estranho. Apesar das semelhanças a identificação de defeitos em rolos possui complexidades não presentes na aplicação acima, como por exemplo: os dados dos rolos são coletados em ambiente externo e sujeitos a interferências como a luz solar, as distâncias a serem percorridas e nem todos os rolos são iguais.

Exceto por (SENNI et al., 2014), todas as abordagens aqui descritas utilizaram indiretamente o valor de temperatura ou obtiveram a temperatura de uma transformada aproximada. Somente (ZOU; HUANG, 2015) e (SENNI et al., 2014) propõem modelos para calcular as ROIs mesmo que baseados em métodos morfológicos. E tirando as abordagens para equipamento elétricos propostas por (HUDA et al., 2014) e (ZOU; HUANG, 2015), as demais são experimentos de laboratório ou em ambientes controlados.

Apesar dos artigos citados terem utilizado mecanismos menos robustos para a identificação de ROIs. Existem inúmeras abordagens mais eficientes para a identificação de ROIs nas imagens (UIJLINGS et al., 2013), como a busca por janela de inspeção em toda a imagem (DALAL; TRIGGS, 2005; HARZALLAH; SCHMID; GRENOBLE, 2009; VIOLA; JONES, 2001), métodos de segmentação (MIN-CUTS; MEMBER; SMINCHISESCU, 2012; ENDRES; HOIEM, 2014), e outras estratégias como o uso de *Convolutional Neural Network* (CNN) (em português, Redes Neurais Convolucionais) (UIJLINGS et al., 2013) e *Bag of Words* (BoW) (em português, saco de palavras) (XIE et al., 2017). Nas próximas Seções 3.2, 3.3 e 3.4 serão detalhas as abordagens selecionadas para o presente problema. A escolha pelo método descrito na Seção 3.2 ocorreu em função da possibilidade de se atingir baixas taxas de falsos negativos (VIOLA; JONES, 2001). E a mudança para o modelo proposto na Seção 3.4, ocorreu de maneira quase que natural já que este pode ser considerado uma evolução do primeiro.

3.2 Detecção Rápida de Objetos Alavancada pelo uso de Características Simples em Cascata

O artigo *Rapid Object Detection Using a Boosted Cascade of Simple Features* (VIOLA; JONES, 2001) (em português, Detecção Rápida de Objetos Alavancada pelo uso de Características Simples em Cascata), foi publicado em 2001 e já foi citado 4798 vezes em outros artigos e 459 vezes em patentes, até janeiro de 2018. Ele foi um marco no processamento de imagens e apresentou três contribuições principais:

Imagem Integral, foi motivada pelo trabalho de (PAPAGEORGIOU; OREN; POGGIO, 1998) e permitiu a extração das características de uma imagem rapidamente. Ela se utiliza de funções Haar Basis.

Método AdaBoost Modificado, garante um rápido processo de classificação excluindo a maioria das características disponíveis e focando apenas nas mais críticas;

Classificador em Cascata, é um método para sucessivamente fazer avaliações mais complexas, reduzindo o tempo de avaliação nos primeiros estágios que possuem mais regiões a serem analisadas. A chave do sucesso dessa abordagem é ter uma taxa de falsos negativos baixa, para não descartar indevidamente regiões de interesse nos primeiros estágios.

Imagem Integral

Os autores usaram 4 elementos retangulares para a extração de características da imagem. O valor obtido por cada elemento é a diferença entre o somatório dos pixels de regiões retangulares. Na Figura 12, o valor obtido pela retângulo A será a diferença do somatório dos pixels da região branca menos o somatório dos pixels da região preta, no retângulo B o processo é o mesmo mudando somente a orientação dos retângulos, no retângulo C o valor será obtido pelo somatório das regiões brancas menos a região preta central e finalmente no retângulo D o processo será realizado entre pares de retângulos diagonais. Todas as demais características extraídas são variações em escala e orientação desses 4 elementos retangulares.

Cada uma dessas características de elementos retangulares pode ser calculada rapidamente com o uso do conceito da imagem integral. A imagem integral em um ponto (x, y) é a soma de todos os pontos acima e a esquerda do ponto especificado.

Na Figura 13a, a região destacada em laranja engloba os pontos que devem ser somados para gerar a imagem integral do ponto (x, y) .

$$ii(x, y) = \sum_{x'=0}^{x'=x} \sum_{y'=0}^{y'=y} f(x', y') \quad (3.1)$$

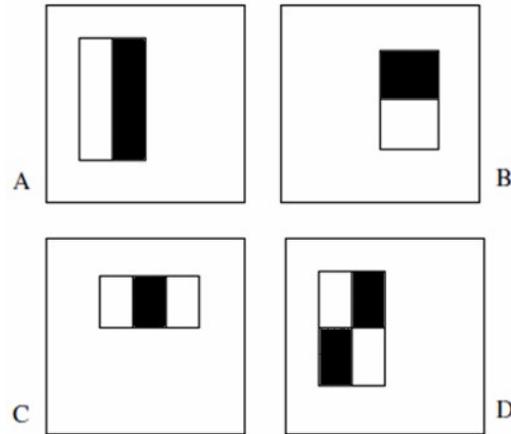


Figura 12 – Quatro elementos retangulares para a extração de características. O valor obtido é o resultado da diferença entre o somatório das partes brancas menos as partes pretas em cada tipo de elemento. Fonte: Notas de aula Mor Yakobovits e Roni Karlikar.

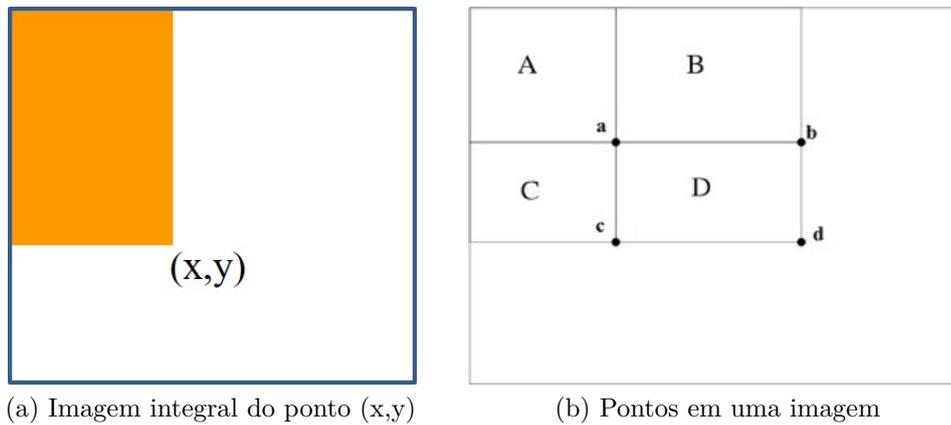


Figura 13 – Imagem Integral: (a) A imagem integral do ponto (x,y) é o somatório de todos os pontos acima e a esquerda, ou seja, o somatório da região destacada em laranja. (b) Pontos e regiões de uma imagem. Fonte: Notas de aula Mor Yakobovits e Roni Karlikar.

Na Equação 3.1, $ii(x,y)$ é a imagem integral do ponto (x,y) e $f(x,y)$ é a imagem original. Na Figura 13b, considere a, b, c e d como pontos específicos da imagem. E A, B, C e D como o somatório de todos os pixels delimitados pelos seus respectivos retângulos. Pode-se então obter-se as seguintes relações.

$$ii(a) = A \quad (3.2)$$

$$ii(b) = A + B \quad (3.3)$$

$$ii(c) = A + C \quad (3.4)$$

$$ii(d) = A + B + C + D \quad (3.5)$$

$$D = ii(d) + ii(a) - ii(b) - ii(c) \quad (3.6)$$

Método AdaBoost Modificado

De posse do banco de características e de imagens negativas e positivas, existem inúmeras abordagens de aprendizagem de máquina que podem ser usadas para classificar um objeto. Em sua forma original o AdaBoost é usado para alavancar o desempenho de classificadores simples, ou fracos. Os autores utilizaram o AdaBoost modificado para selecionar um pequeno lote de características e depois treinar o algoritmo de aprendizagem. Essa simples alteração é importante pois em uma janela de inspeção de apenas 24x24 pixels existem mais de 180 mil características do tipo retangular. E mesmo que o cálculo de cada uma delas seja eficiente, o processamento de todas elas é extremamente custoso e se torna proibitivo.

O desafio principal é encontrar um número pequeno de características que combinadas possam eficientemente classificar o objeto. O algoritmo foi desenvolvido para selecionar a característica retangular que melhor separa as imagens positivas e negativas, chamada de classificador fraco. Depois determina-se o valor de limite ótimo que minimiza o erro de classificação entre imagens positivas e negativas.

$$h_j(x) = \begin{cases} 1, & \text{se } p_j f_j(x) < p_j \theta_j \\ 0, & \text{para os demais casos} \end{cases} \quad (3.7)$$

Na Equação 3.7, $h_j(x)$ é o classificador fraco, f_j é uma característica da imagem, p_j determina o sinal a inequação, x é a janela de inspeção 24x24 e θ_j é o limite que seleciona imagens positivas e negativas. Nos primeiros estágios cada $h_j(x)$ possui um erro entre 10% e 30% e nas etapas finais em que o processo se torna mais difícil o erro fica entre 40% e 50%.

Classificador em Cascata

A ideia principal dessa abordagem é descartar várias sub-regiões da janela de inspeção com o classificador fraco, e ir avançando em complexidade à medida que cada estágio é superado. Em cada etapa pode-se ter uma taxa de falsos positivos elevada, mas deve-se ter uma taxa de falsos negativos próxima a zero para não descartar regiões de interesse prematuramente.

A Figura 14 apresenta um fluxograma simplificado do classificador em cascata proposto por (VIOLA; JONES, 2001). Primeiramente, uma janela de inspeção é retirada da imagem, neste caso o quadrado roxo delimita essa região. Em seguida várias sub-regiões, da janela de inspeção, são analisadas com o conjunto de classificadores fracos definidos para cada estágio, se qualquer um dos estágios classifica a região como falsa ela é descartada e não volta a ser analisada nos demais estágios. Ou seja, só serão analisadas no estágio 2 as regiões que foram confirmadas como verdadeiras no estágio 1, e assim sucessivamente.

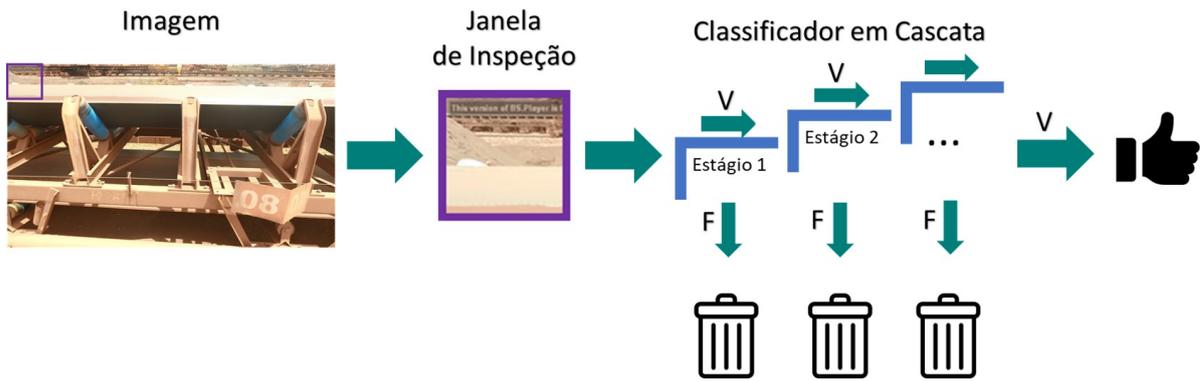


Figura 14 – Fluxograma do classificador em cascata. Fonte: Autor.

À medida que os estágios avançam o classificador se tornar mais complexo, pois ele deve tomar uma decisão em cima das regiões que já passaram no estágio anterior.

O processo de treinamento deve ser balanceado com base nas seguintes trocas. Os classificadores com mais características, geralmente, irão alcançar taxas de detecção melhores e menor taxa de falsos positivos, mas requerem mais tempo de processamento. E cada estágio adicionado reduz a taxa de falsos positivos, mas também reduz a taxa de detecção. Para se otimizar o treinamento do classificador, três parâmetros devem ser definidos, conforme lista abaixo. Infelizmente essa otimização é extremamente difícil.

- O número de estágios;
- A quantidade de características em cada estágio;
- O limite que irá definir o valor de falsos positivos por estágio.

A precisão geral do classificador pode teoricamente ser obtida pelas equações 3.8 e 3.9 abaixo. Considerando que todos os estágios possuam as mesmas taxas.

$$\text{Taxa de Falsos Positivos} = (\text{Taxa de Falsos Positivo do Estágio})^{\text{Número de Estágios}} \quad (3.8)$$

$$\text{Taxa de Falsos Negativos} = (1 - \text{Taxa de Positivo Verdadeiro do Estágio})^{\text{Número de Estágios}} \quad (3.9)$$

3.3 Histograma de Gradientes Orientados para a Detecção de Humanos

O artigo *Histograms of Oriented Gradients for Human Detection* (DALAL; TRIGGS, 2005) (em português, Histograma de Gradientes Orientados para a Detecção de Humanos), foi publicado em 2005 e já foi citado em 8028 artigos e 227 patentes, até janeiro de 2018. Ele propôs um inovador método para a extração de características, com excelentes resultados para a detecção de humanos e até o momento figura entre um dos melhores extratores de características.

Visão Geral da Solução

Os autores estudaram os problemas dos extratores de características para a detecção de humanos, principalmente para ambientes desordenados e com pouca iluminação. E propuseram um método baseado em *Histogram of Oriented Gradients* (HOGs) proveniente dos histogramas orientados de borda e das propriedades das formas. O HOG é calculado com base em uma grade de células igualmente espaçadas e densamente distribuídas, com normalização do contraste localmente e usando sobreposição para aumentar o desempenho.



Figura 15 – Fluxograma para a extração de características, mais uso de uma SVM Linear. Fonte: Adaptado de (DALAL; TRIGGS, 2005).

Na Figura 15, é apresentado o fluxograma para a extração de características com o uso do HOG mais o uso de uma SVM linear para a classificação do objeto. O fluxo é alimentado com uma imagem ou janela de inspeção que pode ou não conter o objeto a ser classificado, em seguida é feita a normalização de gama e cor para diminuir a interferência desses parâmetros. O cálculo dos gradientes é realizado no segundo bloco e na sequência também é calculado a orientação e magnitude de cada célula. A normalização do contraste é então realizada sobre os blocos sobrepostos, antes de se realizar a vetorização dos histogramas. Por fim uma SVM Linear é utilizada para a classificação das imagens ou janelas a depender se elas contém o objeto ou não.

Uma visão geral do processo é dado na Figura 16. Uma imagem ou janela de inspeção é dividida em blocos 16(a) e cada bloco dividido em células igualmente espaçadas, neste caso cada bloco contém 6 células. É então calculado o gradiente orientado para cada célula, representado pelas setas na 16(a). Depois é obtido o histograma de cada bloco 16(b), com a orientação do gradiente no eixo das ordenadas e a frequência nas abscissas. E finalmente o histograma de cada um dos blocos é agrupado em um único vetor, conforme mostra a 16(c).

Resumo

Os autores avaliaram o desempenho do HOG através do *False Positives Per Window* (FPPW) (em português, Falsos Positivos Por Janela) versus a taxa de Falsos Negativos (ou 1 - Revocação), para vários parâmetros. E as principais conclusões são de que se deve usar uma escala fina para o cálculo do gradiente, não se deve "borrar" a imagem, usar um grande número de células, usar blocos de tamanho moderado, realizar uma normalização intensiva e sobrepor os blocos em aproximadamente 50%. Essas avaliações foram feitas para o banco de dados da 'INRIA' criado pelo autor para a detecção de pedestres (disponível em

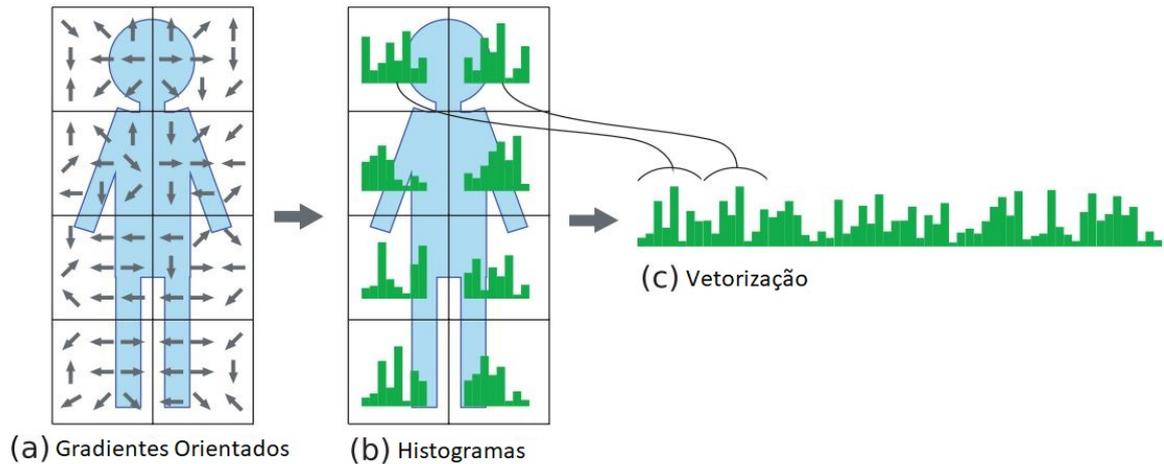


Figura 16 – Visão geral do extrator de características HOG. Fonte: Adaptado de (WATANABE; ITO; YOKOI, 2009).

<http://lear.inrialpes.fr/data>), mas outros tipos de imagens podem requerer um tipo de estruturação diferente. Mais detalhes sobre o HOG podem ser encontrados na tese de doutorado do autor (disponível em <http://lear.inrialpes.fr/people/dalal/NavneetDalalThesis.pdf>).

3.4 Pirâmide de Características para a Rápida Detecção de Objetos

O artigo *Fast Feature Pyramids for Object Detection* (DOLLÁR et al., 2014) (em português, Pirâmide de Características para a Rápida Detecção de Objetos) foi publicado em 2014 pela IEEE Transactions on Pattern Analysis and Machine Intelligence e possui até o momento 470 citações, com 467 em artigos e 3 em patentes, até janeiro de 2018. Ele pode ser considerado como uma evolução do método proposto por (VIOLA; JONES, 2001) mas com uma taxa de falsos positivos muito menor. Hoje ele é um dos métodos mais populares para a detecção de pedestres (MILAN et al., 2016). Entre as principais contribuições desse método estão:

Histogramas de Gradientes Multi-escala, mostra que é possível criar uma ótima aproximação para histogramas de gradientes multi-escala com o gradiente calculado em uma única escala.

Pirâmide de Características Rápida, descreve um método eficiente para calcular pirâmides de características amostradas;

Canais de Características Agregados, apresenta um meio simples e eficiente de se extrair várias características de uma imagem.

Histogramas de Gradientes Multi-Escala

Como uma forma de diminuir o custo computacional no cálculo de gradientes em todas as escalas previstas. Os autores propuseram uma abordagem diferente, em que, o

gradiente é calculado em uma única escala e a partir desse valor se obtém os gradientes das demais escalas. O histograma de gradientes apresenta a distribuição dos ângulos dos gradientes de uma imagem ou região da imagem.

$$M(i, j)^2 = \frac{\partial f}{\partial x}(i, j)^2 + \frac{\partial f}{\partial y}(i, j)^2 \quad (3.10)$$

$$O(i, j) = \arctan\left(\frac{\frac{\partial f}{\partial y}(i, j)}{\frac{\partial f}{\partial x}(i, j)}\right) \quad (3.11)$$

Sendo $f(x, y)$ uma imagem, o cálculo da magnitude e orientação do gradiente pode ser realizado respectivamente pelas equações 3.10 e 3.11. Dentro de cada célula a orientação de cada pixel é ponderada pela sua magnitude e uma vez definida a orientação da célula, o seu valor é quantizado. Tomando-se uma imagem aumentada por um fator k pode-se adotar a equação 3.12, onde $M'(i, j)$ é a magnitude da imagem aumentada $f'(x, y)$ por um fator k . Então o somatório das magnitudes dos gradientes de uma imagem aumentada também é aumentada por um fator k , conforme equação 3.13. Então, de acordo com a definição de histograma de gradientes, tem-se a relação da Equação 3.14, onde h' é o histograma da imagem aumentada e h o histograma da imagem original.

$$M'(i, j) \approx \frac{1}{k}M\left(\frac{i}{k}, \frac{j}{k}\right) \quad (3.12)$$

$$\sum_{i=1}^{kn} \sum_{j=1}^{km} M'(i, j) \approx \sum_{i=1}^{kn} \sum_{j=1}^{km} \frac{1}{k}M\left(\frac{i}{k}, \frac{j}{k}\right) = k \sum_{i=1}^n \sum_{j=1}^m M(i, j) \quad (3.13)$$

$$h' \approx kh \quad (3.14)$$

O mesmo processo pode ser utilizado para imagens reduzidas. Se elas possuírem uma pequena porção de alta frequência a equivalência $h' \approx kh$ continua válida, do contrário o novo histograma ainda será proporcional ao original mas não decrescerá pelo mesmo fator de diminuição, já que durante as transformações para a diminuição da imagem parte da alta frequência é perdida.

Na Figura 17 os autores plotaram o resultado da investigação empírica do comportamento do gradiente de 5.517 imagens, sendo 1.237 pedestres e 4.280 diversas, quando remodeladas por um fator k . As distribuições de probabilidades apresentadas são da razão M'/M , onde M' é o gradiente da imagem aumentada e M o gradiente da imagem original para uma mesma direção. Pode-se notar na Figura 17(a) que, na média, a razão dos gradientes é igual ao fator de aumento, neste caso aproximadamente igual a 2. Na Figura 17(b), a razão entre os gradientes é mais acentuado que o fator de diminuição, isso ocorre porque no processo de diminuição da imagem há uma perda das altas frequências.

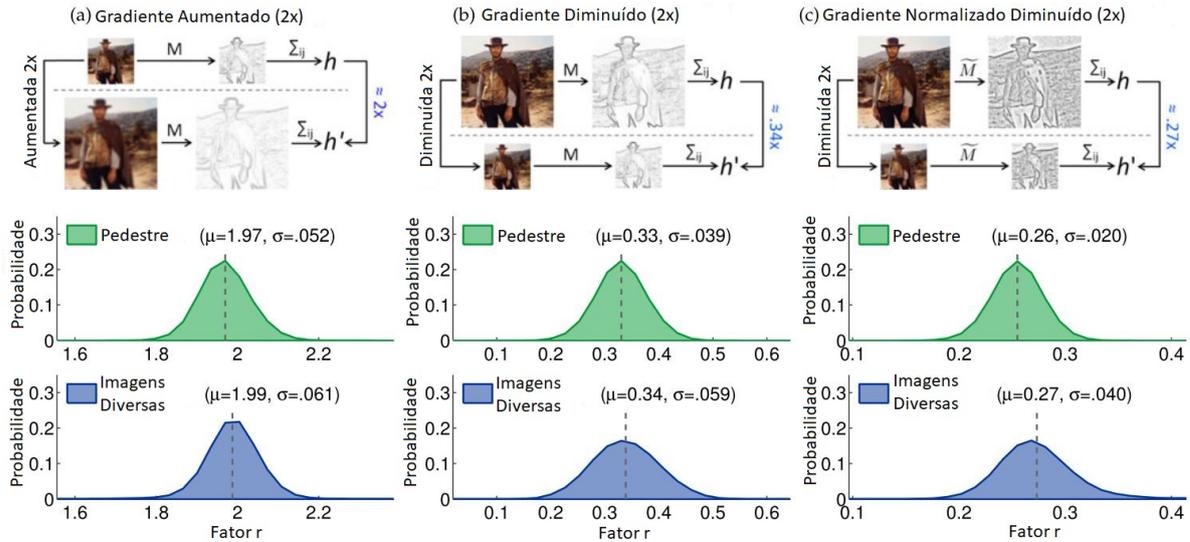


Figura 17 – Comportamento do histograma de gradientes para imagens remodeladas por um fator 2. (a) As imagens foram aumentadas por um fator 2 e as distribuições de probabilidade para pedestres e imagens diversas apresentam gradientes que na média também aumentam por um fator 2. (b) As imagens foram diminuídas por um fator 2, mas as distribuições de probabilidade para pedestres e imagens diversas apresentam gradientes que na média diminuem por um fator 0.3 ao invés de 0.5. (c) As imagens foram diminuídas por um fator 2, mas as distribuições de probabilidade para pedestres e imagens diversas apresentam gradientes normalizados que na média diminuem por um fator 0.27 ao invés de 0.5. Fonte: Adaptado de (DOLLÁR et al., 2014).

Na Figura 17(c), a perda das altas frequências é ainda maior pois os gradientes foram normalizados.

Após demonstrado que o gradiente em uma escala pode ser usado para aproximar o gradiente de outra escala, os autores apresentam um método geral para estimar a relação entre escalas de outras características, já que desenvolver um método analítico para cada uma delas seria muito custoso ou mesmo impossível.

Pirâmide de Características Rápida

Uma pirâmide de características é uma representação em várias escalas de uma imagem, com canais $C_s = \Omega(I_s)$ calculados em todas as escalas. Um canal é um mapa de características de uma imagem calculado através da transformada Ω , e o subscrito s indica a escala do canal C ou da imagem I . Geralmente usa-se de 8 a 12 intervalos igualmente espaçados por oitava, sendo uma oitava o intervalo que uma imagem dobra de tamanho ou diminui pela metade. A abordagem usual para calcular um canal em uma dada escala é $C_s = \Omega(R(I, s))$, em que $R(I, s)$ é a remodelagem de uma imagem para a escala s .

Na Figura 18 os autores fizeram uma comparação visual entre o método tradicional e o proposto. Note que na abordagem tradicional a imagem é remodelada para depois

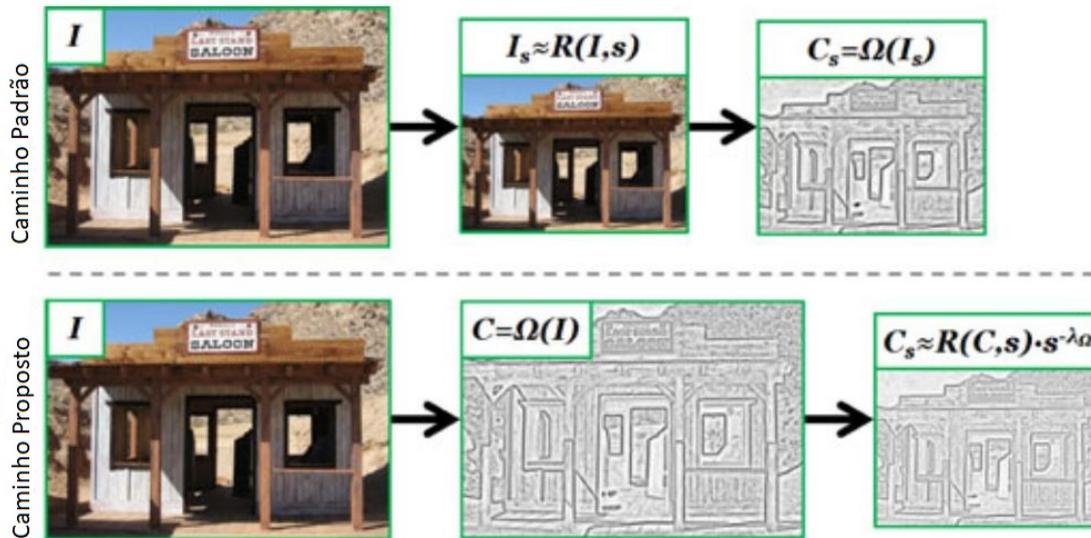


Figura 18 – Comparação visual de duas abordagens para o cálculo de canais em diferentes escalas. Fonte: Adaptado de (DOLLÁR et al., 2014).

obter-se o canal naquela escala e na abordagem proposta o canal é obtido diretamente da imagem original e depois o canal é remodelado. Como o interessante é somente os canais em várias escalas torna-se um desperdício de tempo remodelar a imagem original para cada escala desejada. Para remodelar o canal usa-se a aproximação da Equação 3.15, onde λ_Ω é o fator de escala para esse canal.

$$C_s \approx R(C, s) s^{-\lambda_\Omega} \quad (3.15)$$

Essa aproximação mostra-se bastante robusta como pode ser visualizado pela comparação das duas imagens resultantes na Figura 18.

Canais de Características Agregados

O ACF (em português, Canais de Características Agregados) é uma estrutura simples e direta para a detecção de objetos e com a apropriada escolha dos canais e parâmetros atinge o estado da arte na detecção de pedestres. Na Figura 19, é apresentada uma visão geral do método. Dado uma imagem são calculados inúmeros canais $C = \Omega(I)$, em seguida a resolução dos canais é diminuída com a soma de todos os pixels em cada bloco mais a suavização do canal. Os canais de menor resolução são então agregados e logo em seguida vetorizados. Cada vetor é então analisado por uma pilha de árvores de decisão, para a classificação do objeto.

Os autores utilizaram um total de 10 canais, um canal normalizado da magnitude dos gradientes, seis canais HOG com diferentes parâmetros, 3 canais LUV (CIELUV - CIE ISO 11664-5:2016) espaciais de cor e mais um canal de suavização direta da imagem com o filtro $[1 \ 2 \ 1]/4$. Os blocos utilizados foram de tamanho 4×4 . Também foi adotado



Figura 19 – Visão geral do método ACF. Fonte: Adaptado de (DOLLÁR et al., 2014).

um espaçamento mínimo 8 escalas por oitava e utilizado o algoritmo de aprendizagem AdaBoost (FREUND; SCHAPIRE, 1997) com árvore de decisão.

Tabela 5 – Taxa de falsos negativos de várias abordagens para a detecção de pedestres em diversos bancos de dados. Fonte: Adaptado de (DOLLÁR et al., 2014).

Abordagem	Bancos de Dados				Média
	INRIA	Caltech	TUD	ETH	
Shapelet	82	91	95	91	90
Viola e Jones	72	95	95	90	88
PoseInv	80	86	88	92	87
HikSvm	43	73	83	72	68
HOG	46	68	78	64	64
HogLpb	39	68	82	55	61
MF	36	68	73	60	59
PSL	40	62	71	55	57
MF+CSS	25	61	60	61	52
MF+Motion	-	51	55	60	-
LatSvm V2	20	63	70	51	51
FPDW	21	57	63	60	50
ChnFtrs	22	56	60	57	49
Crosstalk	19	54	58	52	46
VeryFast	16	-	-	55	-
MultiResc	-	48	-	-	-
ICF-Exact	18	48	53	50	42
ICF	19	51	55	56	45
ACF-Exact	17	43	50	50	40
ACF	17	45	52	51	41

A acurácia do ACF foi comparada com 17 abordagens concorrentes em 4 bancos de dados diferentes para a detecção de pedestres. O parâmetro de comparação utilizado foi a média logarítmica da taxa de falsos negativos para uma taxa de falsos positivos entre 10^{-2} e 10^0 . Os bancos de dados utilizados foram: INRIA, Caltech, TUD e ETH. Verifica-se que o ACF-Exact foi a melhor abordagem em 3 dos 4 bancos de dados utilizados e que ficou em segundo lugar no banco de dados INRIA, ver Tabela 5. Também foi realizada a comparação do uso da pirâmide de características aproximada, como proposta em 3.4, e o seu cálculo exato. Demonstrado a validade da proposta dos autores pois a diferença entre elas foi desprezível com o ACF-Exact atingindo uma média de 40 e a solução aproximada ACF com uma média de 41.

O código completo da aplicação ACF foi disponibilizado pelos autores em:
<http://vision.ucsd.edu/pdollar/toolbox/doc/index.html>.

4 Metodologia

O projeto consiste no desenvolvimento de um RPA com uma câmara térmica embarcada para a coleta de dados dos transportadores de correia. Posteriormente, esses dados são tratados para identificar os rolos nas imagens, sua localização e distinguir os defeituosos dos bons. O processamento das imagens foi realizado no Matlab devido a facilidade de implementação dos algoritmos e das várias ferramentas de processamento de imagens disponíveis. O script desenvolvido realiza a importação dos arquivos, pré-processa a imagem quando necessário, segmenta as regiões de interesse, realiza o reconhecimento dos padrões e classifica os rolos. A Figura 20 apresenta os estágios do projeto.

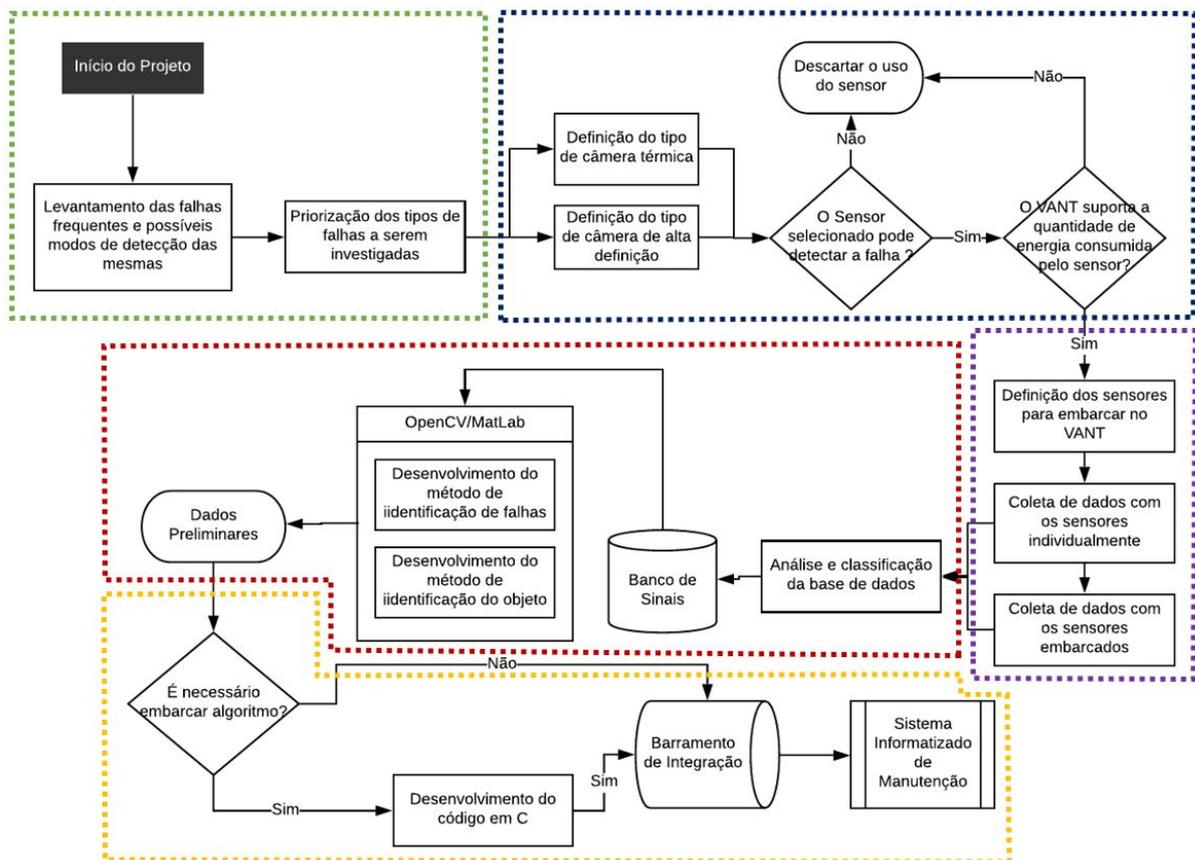


Figura 20 – Fluxo de etapas da metodologia do projeto.

Este capítulo está dividido da seguinte maneira: Na Seção 4.1, **Levantamento e Priorização das Falhas**, é descrito de maneira sucinta como foi definido o modo de falha a ser investigado, bloco pontilhado em verde do fluxograma 20. A Seção subsequente 4.2, **Definição dos Sensores**, relata o motivo da seleção dos sensores e apresenta os dados técnicos, bloco pontilhado em azul. Logo em seguida a Seção 4.3, **Experimentos e Coleta de Dados**, delinea sobre os experimentos realizados para a coleta de dados nos transportadores, bloco pontilhado em roxo. E por último a Seção 4.4, **Métodos de**

Processamento de Dados, proporciona uma visão geral das técnicas de processamento de imagem selecionadas, bloco pontilhado em vermelho. A parte pontilhada em amarelo do fluxograma 20 é proposta como trabalhos futuros na Seção 6.2.

4.1 Levantamento e Priorização das Falhas

Para o levantamento das falhas frequentes nos TCs foi utilizado o sistema de Gestão de Processos Vale (GPV), que registra todos os eventos operacionais. O período inspecionado foi de janeiro de 2016 a dezembro de 2016 e, como esperado, as falhas em rolos se mostraram como uma das principais causas de paradas em TCs, conforme aponta o gráfico de Pareto da Figura 3c. Dentre esses eventos, um dos mais críticos e frequentes são as paradas por princípio de incêndio, sendo este o modo de falha selecionado para tratamento. Existem diversas maneiras de se detectar o princípio de incêndio ou outras falhas em rolos e seus componentes, conforme descrito na Seção 2.2, e a inspeção por imagens térmicas é um dos meios mais efetivos apesar de não ser o de maior previsibilidade.

4.2 Definição dos Sensores

A escolha dos sensores a serem embarcados no RPA, foi realizada com base na sua eficácia de detecção de defeitos e consumo de energia, já que este último é um recurso escasso.

É Possível Inspeccionar Rolos com um RPA?

Nesta primeira fase do projeto, o objetivo era verificar se as imagens coletadas por um RPA poderiam servir para a inspeção dos rolos do TC, além disso era necessário verificar as condições de segurança durante a operação do equipamento. Foi utilizado o quadricóptero Phantom 3 PRO da DJI, que possui uma câmera de alta definição de 12 megapixels montada em um gimbal de 3 eixos proporcionando estabilidade para filmar e fotografar. Ele pesa apenas 1280 g, incluindo a bateria e as hélices, atinge uma velocidade máxima de 16 m/s, resiste a ventos de até 10 m/s, possui uma autonomia de 23 min sendo compatível com os sistemas de *Global Navigation Satellite System* (GNSS): *Global Positioning System* (GPS) e *Globalnaya navigatsionnaya sputnikovaya sistema* (GLONASS). O rádio tem frequência operacional entre 2,400 GHz e 2,483 GHz e alcança a distância máxima de transmissão para ambientes desobstruídos de 2 km (DJI, 2015). A Figura 21 mostra o RPA Phantom 3 voando ao lado de um TC.

Os resultados dessa fase foram animadores e pela qualidade das imagens coletadas, ver Figura 22, observou-se ser plenamente possível realizar a inspeção dos rolos com o uso de um VANT. Na Figura 22, é possível identificar os dois rolamentos do rolos laterais,



Figura 21 – Voo realizado pelo RPA da DJI Phantom 3 para adquirir imagens dos rolos do transportador de correia.

um dos rolamentos do rolo central, ver a integridade do suporte dos rolos e também da estrutura do transportador como um todo.



Figura 22 – Quatro frames distintos retirados do vídeo adquirido com o RPA Phantom 3. Fonte: Autor.

Com relação a segurança os ganhos possíveis são imediatos uma vez que o inspetor não irá mais precisar se deslocar por todo o TC e poderá realizar a inspeção de um ponto fixo. Como pode ser visto na Figura 21 a berma dos TCs geralmente são irregulares oferecendo

risco de queda de mesmo nível ou de níveis diferentes. Existe ainda a possibilidade de encontrar animais peçonhentos no trajeto.

Apesar dos resultados positivos relatados, alguns problemas ficaram evidentes nos primeiros testes. O primeiro deles está relacionado à produtividade, além de fazer a coleta do vídeo com o RPA o inspetor precisará de um tempo adicional em sala para avaliar todo o vídeo com cuidado e identificar os possíveis defeitos. O segundo e mais grave está ligado às limitações de sensoriamento do equipamento utilizado, que não fornece dados adicionais para a confirmação dos defeitos encontrados visualmente. Geralmente o inspetor durante a investigação dos defeitos também mede a temperatura do rolo suspeito com um pirômetro e avalia o som emitido. Nenhum desses dois sinais está disponível nos dados coletados com o Phantom 3, pois a câmera é RGB e o vídeo não tem som.

VANT com Câmera Térmica

Uma vez que ficaram evidentes os possíveis ganhos do uso de um RPA para a inspeção dos rolos e também dos obstáculos a serem superados, partiu-se para a segunda fase do projeto que foi o embarque da câmera térmica no RPA, conforme sensor definido na Seção 2.2.

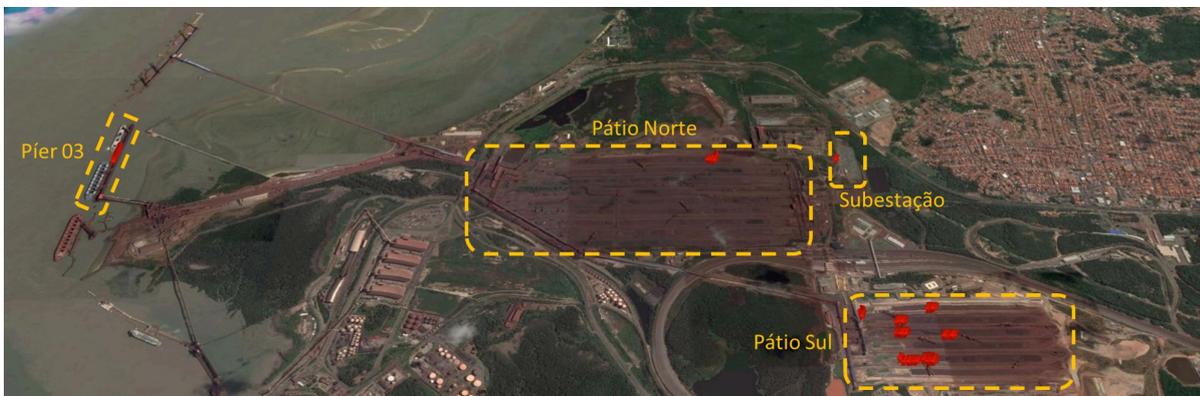


Figura 23 – Visão Geral dos pontos inspecionados com o RPA. Fonte: Autor

Desta vez os testes foram realizados com o uso do quadricóptero Inspire I da DJI e com a câmera Zenmuse XT da FLIR. Esse RPA possui um peso de 2845 g, incluindo a bateria, tem velocidade máxima de 22 m/s, resiste a ventos de até 10 m/s, tem autonomia de 18 min, possui sistema de posicionamento compatível com o GPS e GLONASS e pode operar entre -10°C e $+40^{\circ}\text{C}$, fato que pode ser um limitador para regiões muito quentes (DJI, 2017). A câmera térmográfica Zenmuse XT possui resolução de 640x512 pixels, pesa 270 g, *Field of View* (FOV) de $32^{\circ}\times 26^{\circ}$, *Instantaneous Field of View* (IFOV) de 0,895 *mr*, tem taxa de frames de 9 Hz e possui microbolômetros VOx não arrefecidos sensíveis a faixa espectral de 7,5-13,5 μm (FLIR, 2016) que podem ser classificados como LWIR, sendo ideais para medir temperaturas de -20°C a 650°C .



Figura 24 – Drone Inspire I pronto para decolar com o TR-313K-31 ao fundo.

Os testes foram realizados de 01/08/2017 a 03/08/2017 no TMPM, de manhã de tarde e a noite em vários TCs diferentes para abranger a maior quantidade possível de situações. Na Figura 23, pode-se visualizar os locais em que foram realizados os testes com o RPA, foram coletadas 722 imagens e cada uma delas está representada por um ponto vermelho na imagem. As regiões do TMPM em que foram coletadas as imagens estão sinalizados pelos retângulos tracejados em amarelo. No primeiro dia 01/08/2017 os três horários foram contemplados com inspeções, logo pela manhã foram realizadas inspeções no TR-313K-31 que recebe material da RP-313K05. Esse TC possui grades de proteção em toda sua extensão e durante a inspeção estava operando sem carga. Na Figura 24 é possível ver o RPA antes da decolagem e o transportador TR-313K-31 ao fundo com as telas de proteção.

Uma das premissas definidas na subseção 4.3 foi a de se inspecionar os TCs sempre com carga, pois os defeitos ficam mais evidentes, e esse pode ser um dos motivos para não se ter encontrado nenhum rolo defeituoso no TR-313K31. Todavia, a análise das imagens coletadas trouxeram ótimos resultados, como a alta resolução das imagens a até 5 metros de distância do transportador e ainda a constatação de que as telas instaladas nos transportadores não afetam a medição de temperatura nos rolos atrás dela, ver Figura 25c. Na Figura 25a vê-se toda a extensão do TC que é necessário inspecionar e o RPA dentro da elipse tracejada em amarelo a aproximadamente 5 metros de distância da lateral do TR-313K31. Um ponto importante é o ângulo da câmera em relação ao TC, na Figura 25b não é possível visualizar os rolos centrais, pois o RPA estava voando muito alto e não conseguiu uma posição adequada para a filmagem. Já na Figura 25c pode-se ver os rolos centrais, mas o ângulo de filmagem ainda não é o ideal.

Dessa forma, além da distância especificada de até 5 m, o RPA precisa manter certa altura em relação ao solo para gerar imagens de qualidade para suportar o processamento de imagens futuro. Como a câmera tem um FOV vertical de 26° , a 5 metros de distância o campo de visão vertical será de 2,3 metros e deste modo a altura recomendada para o RPA é de 2 metros, conforme Figura 26. A linha de visão da câmera irá coincidir com a parte superior do rolo central, que também está posicionado a 2 metros do solo. É



(a) Visão da extensão do TC TR-313K31



(b) Imagem coletada com um ângulo impróprio



(c) Imagem coletada com um ângulo aceitável

Figura 25 – Coleta de imagens térmicas no TR-313K31: (a) O RPA dentro da elipse tracejada em amarelo voa a 5 metros de distância do TC. (b) Nesta imagem não é possível visualizar os rolos centrais, o RPA está voando muito alto. (c) Imagem térmica onde é possível visualizar os rolos centrais, nota-se também que a tela de proteção do TC não interfere na coleta dos dados de temperatura.

importante salientar que as medidas aqui apresentadas são do TR-313K-64 e outros TCs poderão apresentar medidas diferentes e nestes casos a linha de visão da câmera deve ser posicionada para coincidir com a parte superior do rolo central.

Nos voos realizados na tarde do dia 01/08/2017, foi também identificado que, além da altura e da distância do RPA com relação ao transportador, a inclinação e rotação da câmera pode dificultar a coleta de dados. No entanto, a câmera é montada em um gimbal com precisão angular de $\pm 0,03^\circ$ nos 3 eixos X, Y e Z. Precisão suficiente para garantir a qualidade das imagens, bastando realizar o correto alinhamento do campo de visão da câmera com o TC antes de se iniciar a coleta de dados. Na Figura 27, tem-se um exemplo de como o gimbal mantém a inclinação inicial durante uma sequência de imagens, mas infelizmente neste caso a configuração inicial não estava adequada e o erro se propagou por todas as imagens. Essa pequena inclinação não chega a ser uma barreira

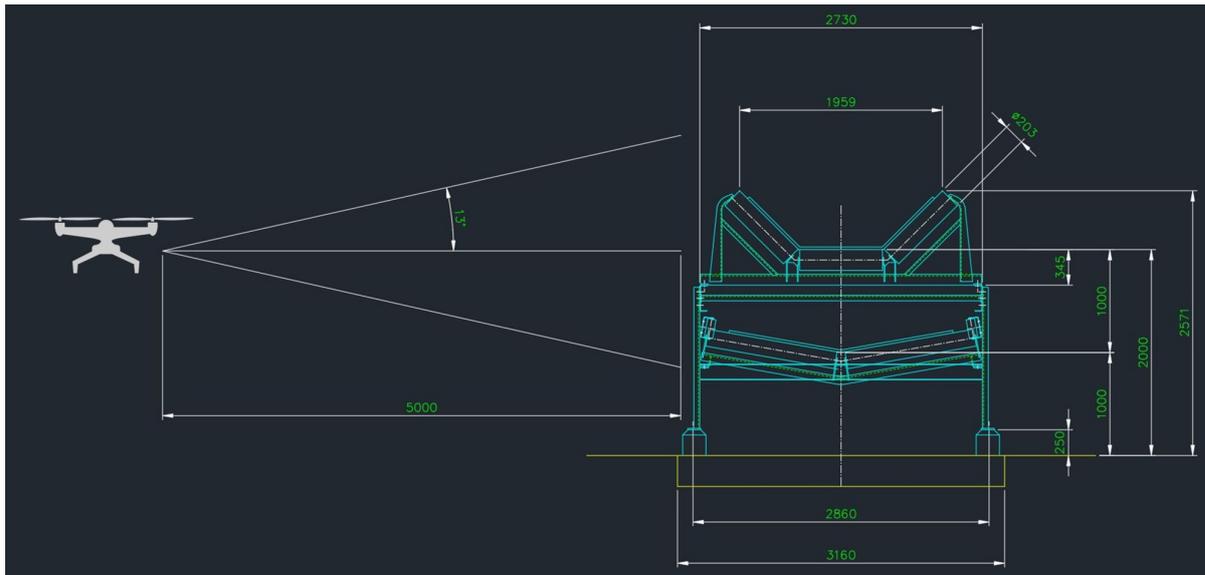


Figura 26 – Posição recomendada de voo para a captura de imagens de alta qualidade dos rolos. Fonte: Autor

para o processamento de imagens, mas com certeza adiciona uma parcela de erro.

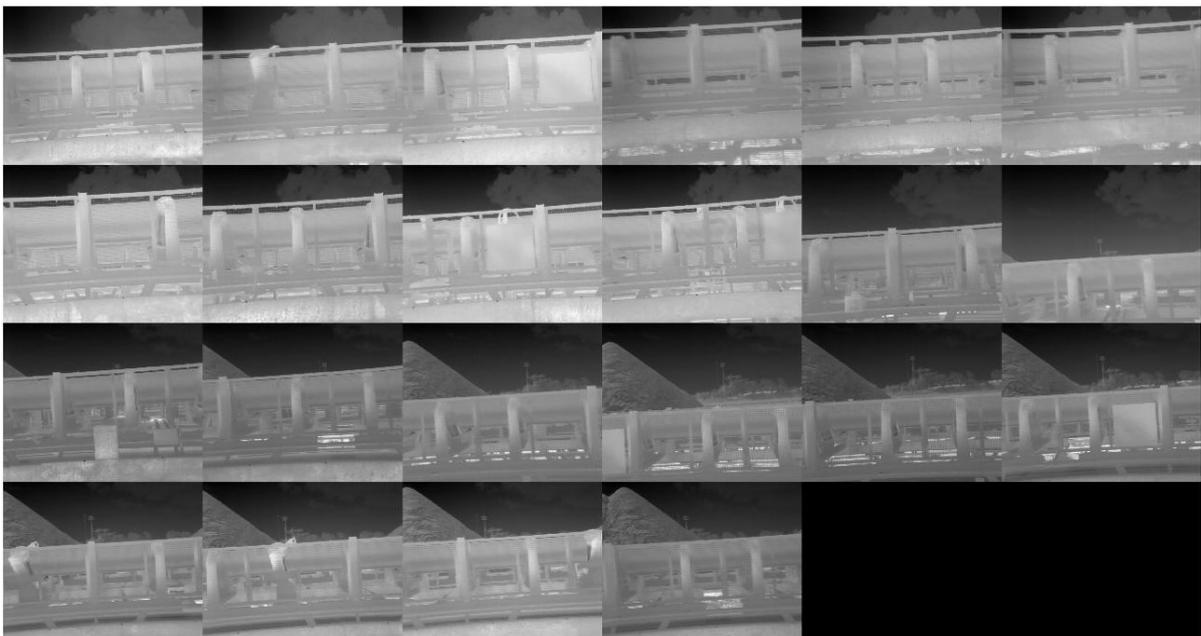


Figura 27 – Propagação do erro de configuração inicial na sequência de imagens. Fonte: Autor

Durante a noite do dia 01/08/2017 foram encontradas as primeiras falhas em rolos com o uso da câmera térmica embarcada no RPA, demonstrando a efetividade do método proposto. É importante evidenciar que só estavam disponíveis duas baterias, cada uma com autonomia de voo de aproximadamente 18 minutos. E desta forma durante os testes iniciais da manhã e tarde foram inspecionados parcialmente somente 3 transportadores e dois deles sem carga. O primeiro defeito foi encontrado no transportador TR-313K-84 que alimenta a EP-313K-06, e que no momento da inspeção operava com taxa aproximada

de 12.000 t/h. A distância, altura, inclinação, ângulo e parâmetros estavam ajustados conforme definições dessa secção e da secção 4.3.

Nos dias 02/08/2017 e 03/08/2017 novamente foram encontrados rolos defeituosos com a abordagem proposta, fortalecendo mais uma vez o método. Na Figura 28a pode ser visto o primeiro defeito encontrado, um rolo central travado em que o atrito com a correia gera o calor responsável pelo aumento de temperatura, já na Figura 28b foram encontrados dois rolos, um central e outro lateral com problemas no rolamento. Durante a manhã do dia 02/08 decidiu-se por realizar uma inspeção nos transportadores do píer que são de difícil acesso. Por exemplo, para acessar o rolo com defeito no rolamento, marcado na Figura 28c, o inspetor leva em média 15 minutos, pois ele deve subir vários lances de escada e fazer uma volta até o ponto de acesso, enquanto que o RPA atingiu o mesmo ponto em menos de 2 min. Durante a tarde do mesmo dia foi encontrado um rolo travado com aproximadamente 100 °C, ver Figura 28d. No último dia de testes 03/08/2017, que só foram realizados pela manhã, encontrou-se um rolo defeituoso mesmo com a proteção de tela instalada no transportador, Figura 28e, e também um outro rolo travado em um transportador aberto, ver Figura 28f.

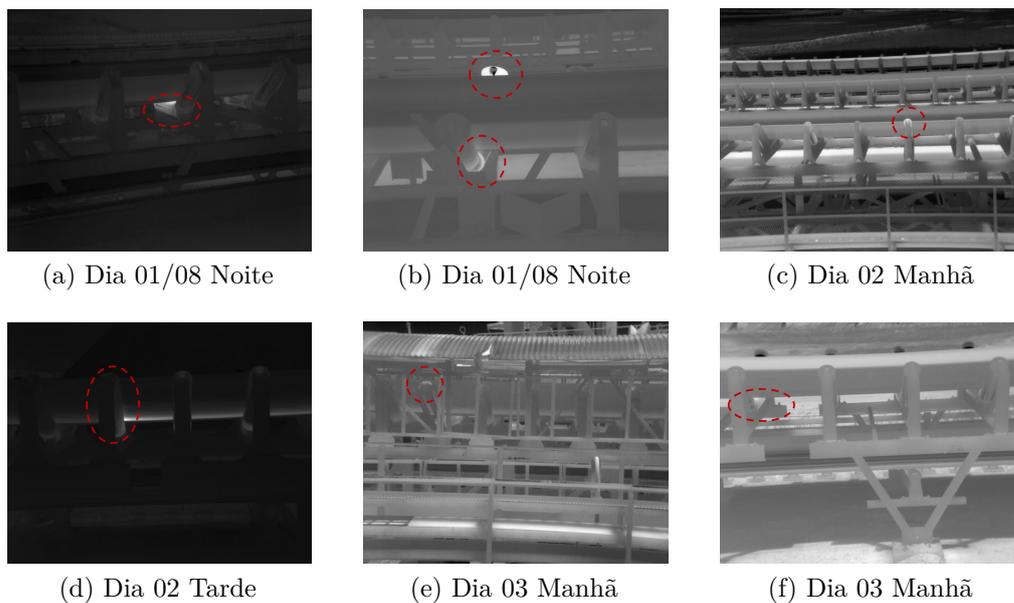


Figura 28 – Alguns rolos defeituosos encontrados com a abordagem proposta, eles estão destacados pelas elipses pontilhadas em vermelho: (a) Rolo travado encontrado no dia 01/08 a noite. (b) Rolamentos super-aquecidos encontrados na noite do dia 01/08. (c) Rolamento super-aquecido, manhã do dia 02/08. (d) Rolo travado encontrado na tarde do dia 02/08. (e) Rolamento super-aquecido encontrado na manhã do dia 03/08, note que a tela de proteção não impediu a localização do defeito. (f) Rolo travado encontrado na manhã do dia 03/08. Fonte: Autor.

Também foi repetido o teste de distância da câmera ao objeto realizado anteriormente com a câmera FLIR E60, mas desta vez com o uso da câmera embarcada no RPA.

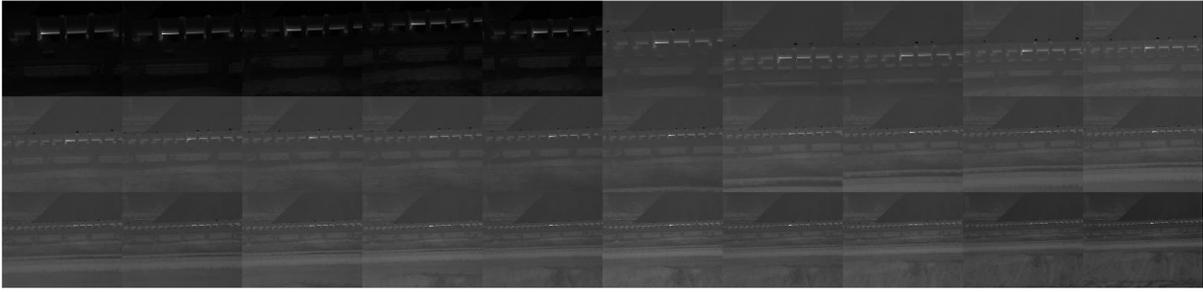


Figura 29 – Distância versus visualização de defeitos pelo inspetor. Fonte: Autor

A ideia era verificar até que ponto o inspetor poderia notar diferenças de temperatura na imagem pelo contraste e intensidade. A câmera converte os valores de temperatura capturados em uma imagem em escala de cinza, onde os valores mais elevados de temperatura são traduzidos com maior intensidade, ou seja, mais claros. Na Figura 29 a primeira imagem no canto superior esquerdo foi tirada a 3 metros de distância e o rolo com defeito é facilmente identificado. A distância foi gradualmente aumentada até chegar a 20 metros, imagem no canto inferior direito, ponto máximo em que ainda era possível identificar um defeito no transportador sem grandes dificuldades.

Essa segunda bateria de testes demonstrou a aplicabilidade da abordagem proposta para a identificação dos defeitos em rolos com a análise das imagens por uma pessoa qualificada. Um problema identificado foi na coleta das imagens durante o dia, pois muitas vezes o ponto indicado como o mais quente da imagem está no solo devido a refletância e também a absorção do calor do sol. Já para a inspeção no período noturno a aplicação dessa abordagem pode ser imediata com ganhos na qualidade e produtividade da inspeção.

4.3 Experimentos e Coleta de Dados

Após a definição do tipo de sensor, as coletas dos dados em campo foram realizadas de forma manual, com uma câmera E60 da FLIR para validar algumas premissas da termografia. Esses experimentos foram realizados antes de se prosseguir com os testes apresentados na Seção 4.2.

Testes com Câmera Térmica

Antes de se embarcar uma câmera térmica em um RPA, alguns parâmetros foram testados com uma câmera térmica tradicional de mão, para se obter um melhor controle das configurações do equipamento. Como discutido na Seção 2.3, muitos fatores afetam o resultado da IRT como a distância da câmera até o rolo, as condições de operação do TC no momento da medição e os parâmetros configurados na câmera.

Para avaliar a eficiência da IRT para rolos, uma série de testes com a câmera FLIR E60 foram realizados. Ela tem uma resolução de 320X240 pixels, sensibilidade de 50

mK , FOV (em português, Campo de Visão) de $25^\circ \times 19^\circ$, IFOV (em português, Resolução Espacial) de 1,36 mrad e uma frequência de até 60 Hz . Ela usa microbolômetros não resfriados sensíveis a comprimentos de onda entre 7,5-13 μm , classificando-se então como um dispositivo LWIR e é ideal para medir temperaturas entre $-20^\circ C$ e $650^\circ C$. Pode capturar duas imagens ao mesmo tempo, uma radiométrica e outra digital, possibilitando a fácil identificação do equipamento inspecionado pela simples sobreposição de imagens.

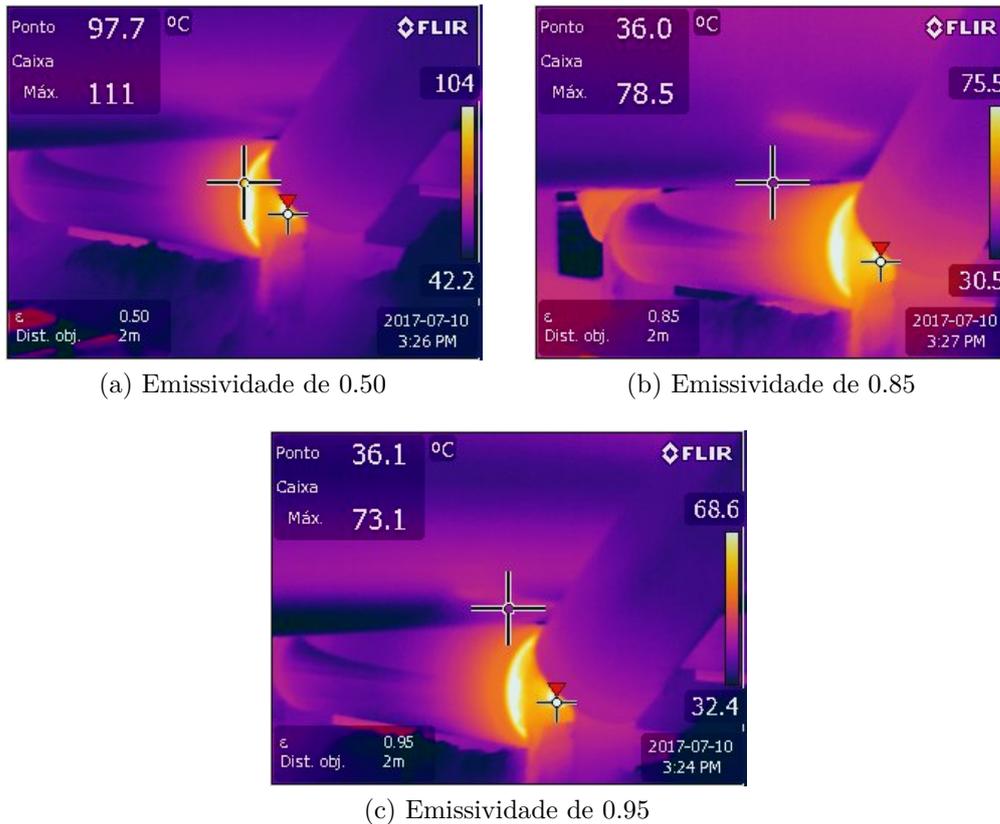
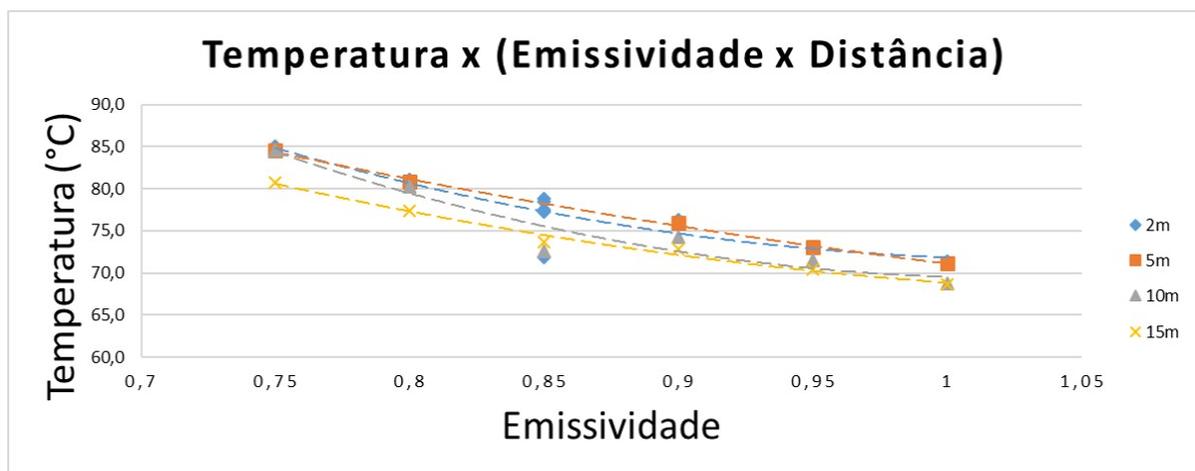


Figura 30 – Influência da emissividade na temperatura medida: (a) A temperatura máxima encontrada foi de $111^\circ C$ com a emissividade de 0,50. (b) Com a emissividade configurada para 0,85 a temperatura máxima foi de $78,5^\circ C$. (c) Máxima temperatura de $73,1^\circ C$ para uma emissividade de 0,95. Fonte: Autor, o horário da câmera foi configurado para -3 UTC.

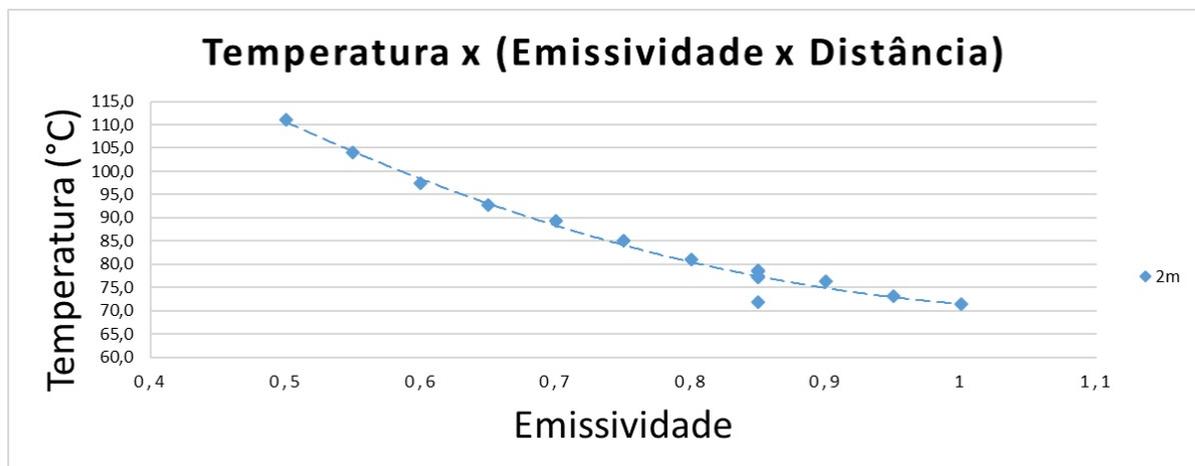
A temperatura medida pela câmera é função da radiação recebida em uma faixa específica de frequência, conforme a Equação 2.13. Os parâmetros ε e τ sofrem influência direta de alguns fatores externos como: Umidade relativa do ar, temperatura ambiente, distância do objeto, refletância e emissividade. E qualquer um deles se não for devidamente configurado pode levar a leituras incorretas de temperatura.

Na Figura 30, três diferentes imagens foram capturadas com a Flir E60, durante a operação normal do TC com taxa aproximada de 8000t/h. Geralmente, o espelho do rolamento e o eixo do rolo não tem pintura e pode-se usar a emissividade do material, aço oxidado, de $e = 0,85$ (Environmental Research Institute of Michigan. Infrared Information

and Analysis (IRIA) Center et al., 1978). Dessa forma, para a imagem da Figura 30b foi configurada uma emissividade de 0,85, que resultou em uma temperatura máxima medida de 78,5 °C na ponta do eixo, como pode ser verificado no canto superior esquerdo da Figura 30b. A emissividade foi então deliberadamente alterada para 0,5, com todos os demais parâmetros mantidos inalterados, incluindo a distância ao objeto e o ângulo da câmera. Essa alteração resultou em uma temperatura máxima de 111 °C no mesmo ponto, representando um erro de 41%, ver Figura 30a. A emissividade foi novamente alterada para 0,95 e a temperatura medida desta vez foi de 73.1 °C, com um erro de 6,8%, conforme Figura 30c.



(a) Emissividade x Distância



(b) Emissividade x Temperatura

Figura 31 – Comportamento da Temperatura x (Emissividade x Distância): (a) Foram configuradas várias distâncias e emissividades diferentes. (b) A distância foi mantida em 2m, e a emissividade foi alterada de 0,5 até 1. Fonte: Autor.

Os parâmetros de distância também foram configurados para diferentes valores, sem no entanto alterar a distância real da câmera ao objeto que foi mantida em 2 metros. Os valores de distância utilizados foram 2 m, 5 m, 10 m e 15 m, com a emissividade também alterada de 0,75 a 1, em passos de 0,5. Na Figura 31b nota-se a queda da temperatura

medida em uma curva levemente exponencial com o aumento da emissividade. Já na Figura 31a verifica-se que enquanto a temperatura medida cai exponencialmente com o aumento da emissividade, o aumento da distância apenas desloca a curva no eixo y. As curvas para 2 m e 5 m estão praticamente sobrepostas, demonstrando que essa pequena alteração na configuração não levou a grandes erros de medição.

Todas as medidas foram deliberadamente realizadas em campo, para simular um cenário real, onde não é possível ter-se o controle de todas as variáveis. E como esperado a emissividade se mostrou o parâmetro dominante. Os valores para a temperatura ambiente e a humidade relativa do ar foram ajustados somente uma vez. Com informações da estação 82280 do Instituto Nacional de Meteorologia (INMET), que fica posicionada na latitude $-2,53333333$, longitude $-44,21666667$ e altitude de 50,86 m. Os valores foram obtidos às 15 horas *Universal Time Coordinated* (UTC) -3, com $31,6\text{ }^{\circ}\text{C}$ para a temperatura ambiente e 70% para a humidade relativa do ar (INMET - Instituto Nacional de Meteorologia, 2017).

Pôde-se observar com estes experimentos, que mesmo sem o controle de todas as variáveis que influenciam a IRT pode-se obter resultados com erros toleráveis. Contanto que, o parâmetro da emissividade esteja corretamente configurado, em $e = 0,85$ para o caso dos rolos. Os demais parâmetros devem ser previamente configurados e, a não ser que as condições mudem de forma significativa, não será necessário interromper a coleta de dados para reconfigurar o equipamento. Por exemplo, se a distância do RPA até o TC mudar de 5 m para 6 m isso não acarretará um erro relevante no valor de temperatura medido.

Definição de Premissas Básicas

Na Seção 4.3, os dados empíricos demonstraram que a configuração da distância na câmera adiciona um erro aproximado de 5,8%, na temperatura medida, para um erro de 13 m na distância configurada. No entanto quando a distância real entre a câmera e o objeto muda, os valores medidos são fortemente influenciados. E dois fatores são os responsáveis: O primeiro deles é a influência da transmitância atmosférica que é o fator que a configuração de distância na câmera tenta ajustar e o segundo e mais importante é que áreas maiores serão representadas por um menor número de pixels, à medida que a distância aumenta. Ou seja, um aumento do menor tamanho de objeto que a câmera térmica pode efetivamente medir. O *Measurement Field of View* (MFOV) (em português, Campo de Visão Mensurável) é uma medida que informa qual o menor objeto detectável a uma certa distância.

A Figura 32 apresenta duas imagens capturadas com a câmera térmica a 11 m e a 3 m. As duas foram obtidas sobre as mesmas condições operacionais e em um intervalo menor que 2 min, com o parâmetro de distância configurado corretamente e emissividade de 0,85. Na primeira imagem 32a o valor obtido de temperatura foi de $47,9\text{ }^{\circ}\text{C}$, enquanto

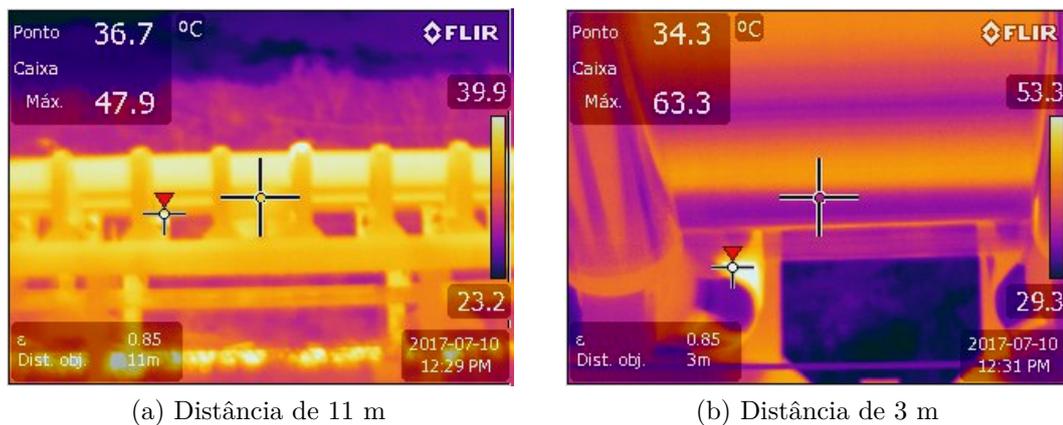


Figura 32 – A influência da distância na temperatura: **(a)** Foto tirada a 11 m de distância, resultando em um MFOV de 76,2 mm. **(b)** O mesmo rolo com a foto tirada a 3 m de distância, o MFOV calculado é de 20,8 mm. Fonte: Autor.

que na segunda foi de $63.3\text{ }^{\circ}\text{C}$. As duas imagens identificaram o mesmo ponto de máximo, mas com uma diferença de $15.4\text{ }^{\circ}\text{C}$ entre elas. Essa diferença pode ser explicada pelo MFOV, que a 3 m de distância tem o valor de 20,8 mm e a 11 m esse valor aumenta para 76,2 mm. Isso significa que a 11 m de distância o menor objeto que pode ser medido com precisão deve ter 76,2 mm de diâmetro.

Uma distância padrão deve ser adotada para inspecionar os rolos com IRT e evitar uma variação muito grande nas temperaturas medidas. O RPA também precisa voar a uma distância segura da estrutura e que permita o piloto reagir durante mudanças inesperadas na direção do vento. O valor definido foi de 5 m, no mínimo, pois atende os requisitos de segurança e desta distância uma câmera com resolução de 320×240 pixels e IFOV de 1,36 mrad, como a E60, tem um MFOV de 34,6 mm, que é suficiente para obter medições de temperaturas confiáveis. O rolo tem um diâmetro de 203 mm, conforme mostra Figura 49b.

Outro ponto importante é o estado do equipamento inspecionado, pois, conforme apresentado na Seção 2.2, o valor de temperatura do rolo aumenta na presença de um defeito, mas isso só ocorre se o TC estiver operando. E, se o TC estiver operando sem carga, o valor de temperatura será fortemente afetado para baixo. Pois os transportadores portuários operam com 8.000 t/h ou 16.000 t/h, e toda essa carga é suportada pelos rolos. E, desse modo, sua presença afeta principalmente os rolos defeituosos.

A Figura 33 contém o gráfico de taxa de operação de um TC das 10:59 h até 15:59 h. Nota-se que durante o intervalo avaliado a taxa de operação caiu várias vezes drasticamente e depois se recuperou. Durante o intervalo das 12:08 as 12:59, o TC operou com relativa estabilidade, com desvio padrão de 345,2 t/h que representa uma baixa taxa de variação para as operações com minério de ferro. Também houve intervalos de operação sem carga de até 20 minutos. Essas variações na taxa, principalmente quando o TC está

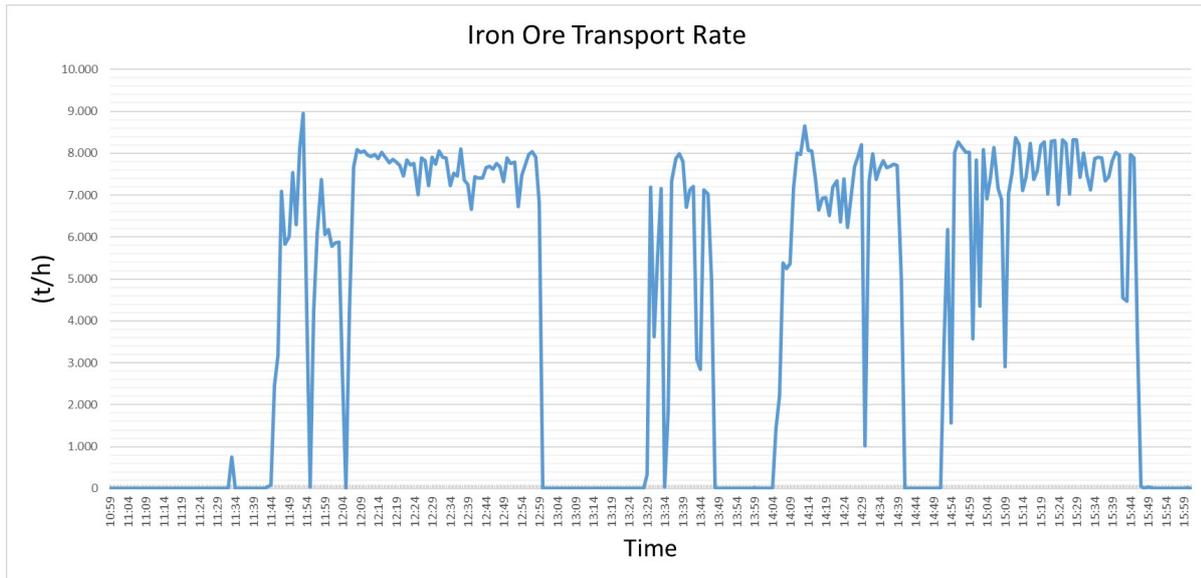


Figura 33 – Esse gráfico mostra como a taxa de operação de um TC pode cair instantaneamente e depois retornar aos seus valores originais. Fonte: Autor.

operando sem carga, pode levar a leituras incorretas de temperatura. E muitas vezes devido à altura ou inclinação do TC o inspetor não consegue verificar se o equipamento está operando com carga. A Tabela 6 abaixo resume os principais parâmetros a serem configurados.

Tabela 6 – Avaliação do Resultado do Algoritmo, Viola e Jones, no Banco de 50 Imagens de Teste

Parâmetro	Valor
Emissividade	0,85
Temperatura Ambiente	Conforme temperatura do dia
Altura do Voo	Aproximadamente 2 m, ajustar conforme altura do rolo central
Distância do TC	5 m +- 1 m
Estado do TC	Operando com carga
Velocidade do RPA	Até 9 m/s
Umidade	Conforme umidade do dia

4.4 Métodos de Processamento de Dados

O processamento dos dados começa com a aquisição de dados, onde os arquivos foram coletados em dois tipos de formato. O formato RJPG que além da representação em escala de cinza dos valores de temperatura coletados, também contém os dados radiométricos de cada pixel, que serão extraídos para a determinação de defeitos nos rolos. E o formato AVI, que consiste de um vídeo em escala de cinza que representa os valores de temperatura dos rolos, neste caso o arquivo não possui os dados radiométricos necessários à classificação dos defeitos mas podem ser utilizados para testar e treinar a identificação

das regiões dos rolos. Maiores detalhes sobre esse processamento será dado na Seção 5.1. E por fim, na etapa de reconhecimento de padrões, duas técnicas de identificação foram experimentadas para alcançar um melhor resultado. Todo o processamento de imagens foi realizado no Matlab com o auxílio do módulo de processamento de imagens e também com o uso de algumas funções do OpenCV.

5 Desenvolvimento e Resultados

O presente projeto foi desenvolvido em várias etapas, começando com o teste conceitual realizado com um RPA amador da DJI e uma câmera RGB, em seguida foi verificada a efetividade da câmera térmica embarcada em um drone e por fim o desenvolvimento dos algoritmos de identificação dos rolos e das falhas. A Figura 34 apresenta um resumo das três fases completadas.

	Fase 1	Fase 2	Fase 3
	VANT Tradicional	VANT + Câmera Térmica	Proc. de Sinais
Descrição	 <p>Uso de drones para captura de vídeos dos rolos (RGB).</p>	 <p>Adição de câmeras térmicas embarcadas no drone.</p>	 <p>Proc. de sinais para detecção automática de falhas, e localização do rolo defeituoso.</p>
Benefícios Adicionados	<ul style="list-style-type: none"> - Avaliação (humana) de defeitos na cobertura, travamentos, etc. 	<ul style="list-style-type: none"> - Avaliação (humana) de falhas nos rolamentos e demais defeitos hoje avaliados de forma sensitiva (trad.) - Diminuição do tempo de inspeção - Redução da exposição de riscos do inspetor 	<ul style="list-style-type: none"> - Identificação das regiões de interesse - Avaliação automática das condições de defeito - Localização do rolo defeituoso com o uso do GNSS ou DGNS

Figura 34 – Visão geral das fases do projeto com uma breve descrição e os principais benefícios de cada uma delas.

A efetividade das Fases 1 e 2 foram comprovadas conforme apresentado na Seção 4.2. Já o desenvolvimento e resultados obtidos com a Fase 3 do projeto serão apresentados na Seção 5.1 abaixo.

5.1 Desenvolvimento do Processamento dos Sinais

O uso do RPA com uma câmera térmica para inspeções dos rolos, principalmente a noite, trará ganhos imediatos de produtividade e precisão, no entanto a identificação das falhas irá continuar dependente da análise de uma pessoa qualificada e sujeita a erros humanos influenciados por fatores como: Cansaço, falta de atenção, erro de avaliação, negligência, e outros fatores psicológicos ou fisiológicos. Nesta seção será abordado o uso de técnicas de processamento de imagens para melhorar e automatizar o processo de identificação de falhas, e, desta forma, eliminar ou mitigar os erros humanos.

Os principais processos desta solução serão abordados nas seções a seguir: Na Seção 5.1, **Processamento Morfológico**, trabalhou-se no processamento a nível dos pixels para a identificação dos defeitos, já na Seção 5.1, **Detector Viola & Jones**, foi utilizado um algoritmo para detectar as regiões dos rolos nas imagens, e por último na Seção 5.1, **Detector ACF**, foi aprimorada a abordagem utilizada na Seção 5.1 para detectar as regiões dos rolos nas imagens.

Processamento Morfológico

As imagens apresentadas pelas câmeras térmicas, como por exemplo na Figura 28, são na verdade falsas imagens produzidas a partir dos dados de temperaturas coletados. Para melhorar a análise dos defeitos por humanos, as câmeras atuais transformam os dados de temperatura em uma imagem em escala de cinza. O primeiro passo então, para a identificação dos defeitos é obter novamente os dados de temperatura, que pode ser realizado com o uso do *Software Development Kit* (SDK) (em português, Kit de Desenvolvimento de Software) Atlas da Flir mais a toolbox de processamento de imagens do Matlab. Tome-se como exemplo a imagem da Figura 35a, o valor de temperatura de cada pixel pode ser extraído com o código C.1, do Apêndice C.

Na Figura 35b, é possível ver em detalhes o valor de temperatura contido em cada pixel, ou seja, tem-se agora uma matriz radiométrica com 604x512 valores de temperatura. A 5 metros de distância e com um FOV de 32°x26°, cada pixel terá uma área de 20,25 mm² e a área total da imagem será de 6,64 m².

Um meio simples de se identificar possíveis pontos defeituosos é de se estabelecer um limite de temperatura acima da qual a região pode conter um defeito. Foi então criada uma máscara e marcado como 1 os valores iguais ou maiores que 45 °C e 0 para o demais valores, resultando na Figura 35c. É também importante eliminar-se pequenas regiões que não representam falhas em rolos, ou mesmo representem erros de leitura em um dos sensores. E para isso, foi utilizada a técnica dos oito vizinhos conectados e de tamanho não menor que 19 pixels. Isto significa que só serão computadas regiões maiores que 19 pixels, onde cada pixel está conectado a outros 8 que também possuem temperatura maior

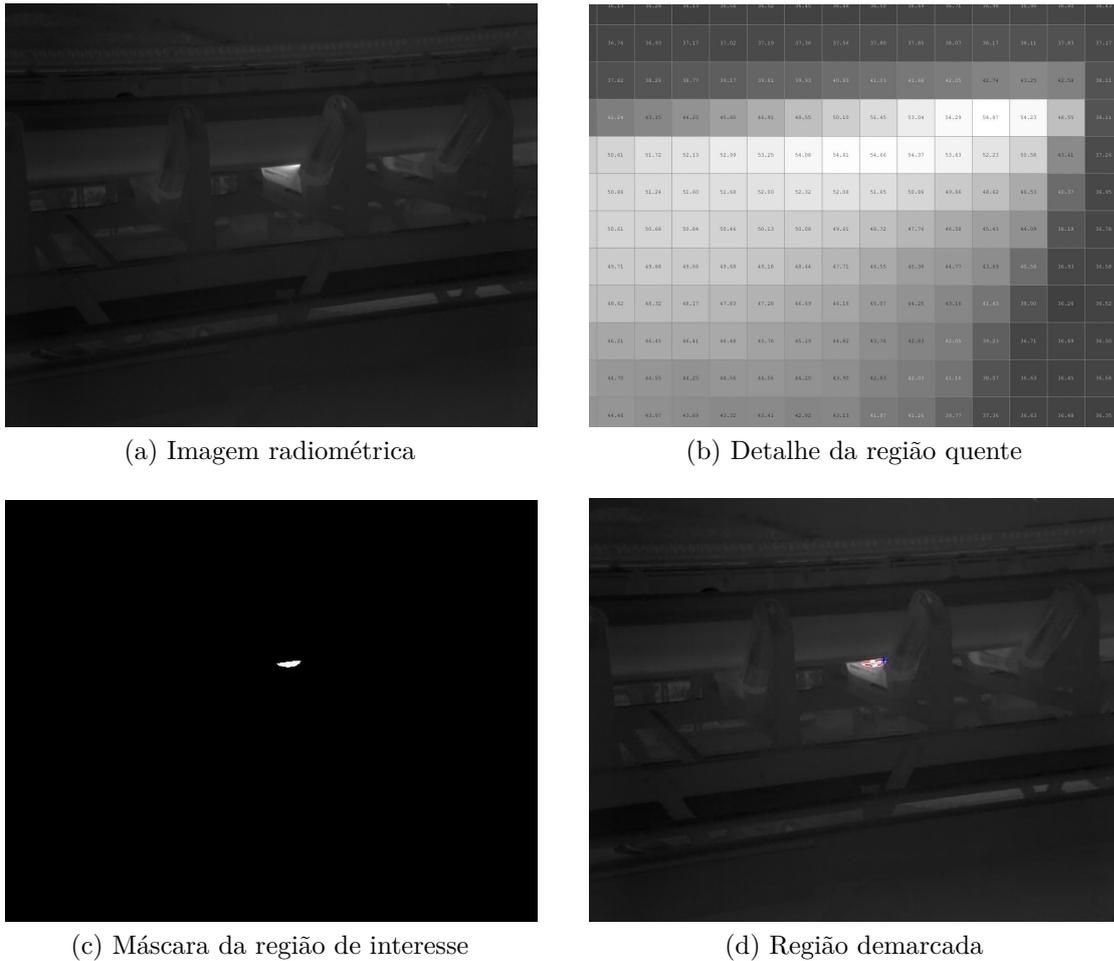


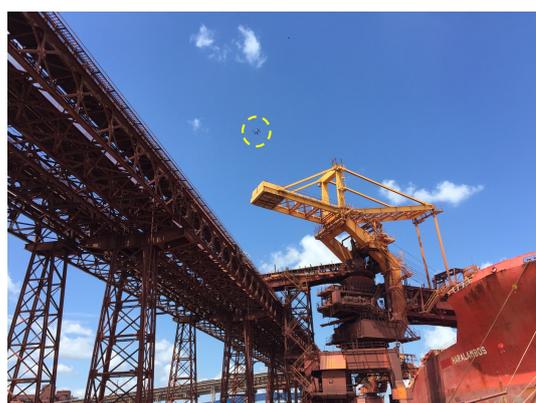
Figura 35 – Processamento morfológico: (a) Imagem radiométrica com a presença de um rolo defeituoso. (b) Detalhe da região sobreaquecida em que cada pixel contém o valor de temperatura. (c) Máscara da região de interesse, filtrada pela técnica dos 8 vizinhos conectados. (d) Região do rolo defeituoso demarcada. O asterisco azul mostra o ponto de máxima temperatura com $54\text{ }^{\circ}\text{C}$. Fonte: Autor.

ou igual a $45\text{ }^{\circ}\text{C}$. Esse limite mínimo foi estabelecido através de observações empíricas, e representa um área de $384,7\text{ mm}^2$ enquanto o rolo tem diâmetro de 203 mm e área de 32349 mm^2 . Essa tarefa pode facilmente ser executada no Matlab através do código C.2.

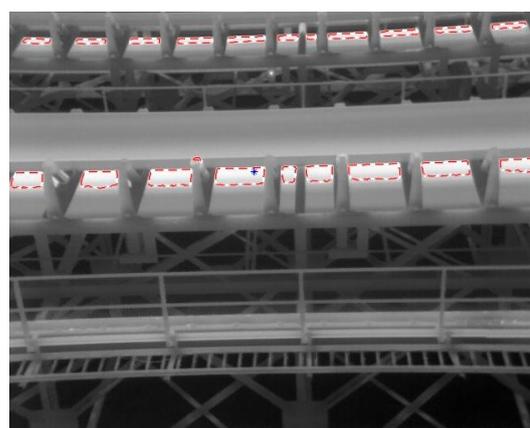
Finalmente as regiões encontradas podem ser plotadas na imagem original, facilitando a identificação dos defeitos pelo inspetor, ver Figura 35d, ou utilizadas como entradas para a identificação automática das falhas. O comando `bwboundaries` extrai as bordas das regiões de interesse que podem ser plotadas na imagem original com o código C.3.

Pode-se agora testar o processo morfológico aqui especificado em outra imagem coletada durante os testes no píer 03, ver Figura 36a. A imagem da Figura 36b foi processada com o processo morfológico descrito anteriormente e claramente demarcou

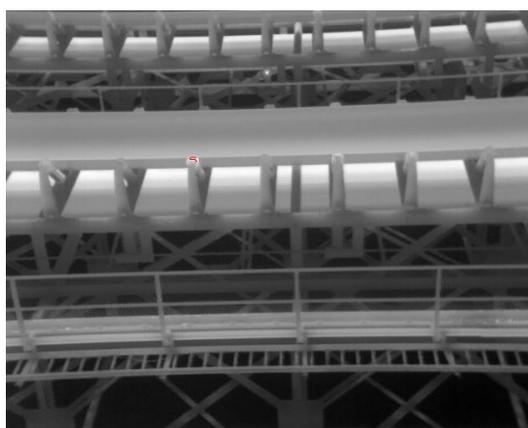
várias regiões que não são rolos. Isso ocorreu devido à refletância, já que as imagens foram coletadas durante o dia, a correia estava refletindo a luz solar e aparentando ter uma temperatura maior que a real. Foi então realizada uma melhoria no processamento morfológico para delimitar mais precisamente as regiões de interesse. Definindo-se agora além de um tamanho mínimo também um tamanho máximo para os objetos.



(a) Píer para carregamento de navios



(b) Regiões selecionadas incorretamente



(c) Algoritmo morfológico melhorado

Figura 36 – Processamento morfológico: (a) TCs do píer 03, o RPA está dentro da elipse tracejada em amarelo. (b) Regiões demarcadas erroneamente. (c) Melhora do algoritmo delimitando somente o rolo sobreaquecido. Fonte: Autor.

Na Figura 36c, pode-se ver o resultado onde somente o rolo sobreaquecido foi selecionado. Essa melhoria foi realizada através do código do Apêndice C.4, que obedece o limite mínimo de 19 pixels e estabelece um novo limite máximo de 3000 pixels. O valor superior foi definido através da observação de que não existiam ROIs maiores que 52x52, ou seja, 2704 pixels.

Apesar de simples e eficaz, para os casos aqui demonstrados, o processamento morfológico sozinho não poderia suportar uma automatização robusta para a identificação de defeitos. E deve ser utilizada em conjunto com outras técnicas para poder atingir os resultados esperados.

Detector Viola & Jones

O principal empecilho para usar somente o processo morfológico baseado em limiares, é a presença de regiões sobreaquecidas ou aparentemente aquecidas que não são do interesse da inspeção, que devem ser previamente excluídas antes do processamento morfológico. Uma maneira de eliminá-las e também mitigar o problema da refletância, como o da Figura 36b, é reconhecer previamente as regiões dos rolos. Depois de identificadas os processos morfológicos podem ser executados somente nessas áreas, e espera-se ótimos resultados já que os parâmetros para o reconhecimento dos rolos defeituosos são bem conhecidos. Qualquer outra interferência que apareça na imagem também será desconsiderada, posto que, somente a ROI será analisada.

Antes de prosseguir é importante revisitar algumas métricas que serão frequentemente utilizadas nesta seção e nas próximas:

Revocação - Mensura a quantidade de objetos relevantes que foram detectados. Ela é calculada como a razão entre o total de elementos relevantes detectados sobre o total de elementos relevantes;

Precisão - Mede o quanto assertivo é o algoritmo. É calculada como a razão entre o total de objetos relevantes detectados sobre o total de objetos detectados;

Falso Positivo - Ocorre quando é detectado um objeto erroneamente, por exemplo, um rolo é detectado onde não existe rolo;

Falso Negativo - Ocorre quando um objeto presente na imagem não é detectado. Por exemplo, a imagem contém 3 rolos rolos mas somente dois são detectados.

Como exemplificado na Seção 1.1 a não identificação de um rolo defeituoso pode trazer danos catastróficos para a empresa. E desta forma, a taxa de falsos negativos é crucial para a inspeção dos rolos, foi utilizada então, uma adaptação da abordagem proposta por Viola & Jones juntamente com o vetor de características HOG. O treinamento é simples mas muito eficiente em alcançar taxas de falsos negativos menores que 1% (VIOLA; JONES, 2001). E conforme explicado na Seção 3.2 o conceito consiste em usar uma série de classificadores fracos em cada estágio para formar um classificador forte no final do processo.

Na Figura 37a, são apresentadas as regiões selecionadas para o treinamento do detector. As localidades limitadas pelos retângulos em azul foram nomeadas como Rolos Laterais (RLEs), a intersecção do rolo lateral com o rolo central esquerdo, retângulo vermelho, foi nomeado como Rolo Esquerdo Central (REC) e a intersecção do rolo lateral com o rolo central direito foi nomeado como Rolo Direito Central (RDC), retângulo amarelo. A diferenciação entre RDC e REC foi realizada para diminuir o erro do detector devido a diferentes ângulos de visualização. Veja, por exemplo, a Figura 37b em que foi utilizado somente o detector do tipo REC, somente as intersecções esquerdas dos rolos

foram classificadas. Isso ocorre porque as características do tipo HOG são sensíveis a diferentes ângulos de visualização.

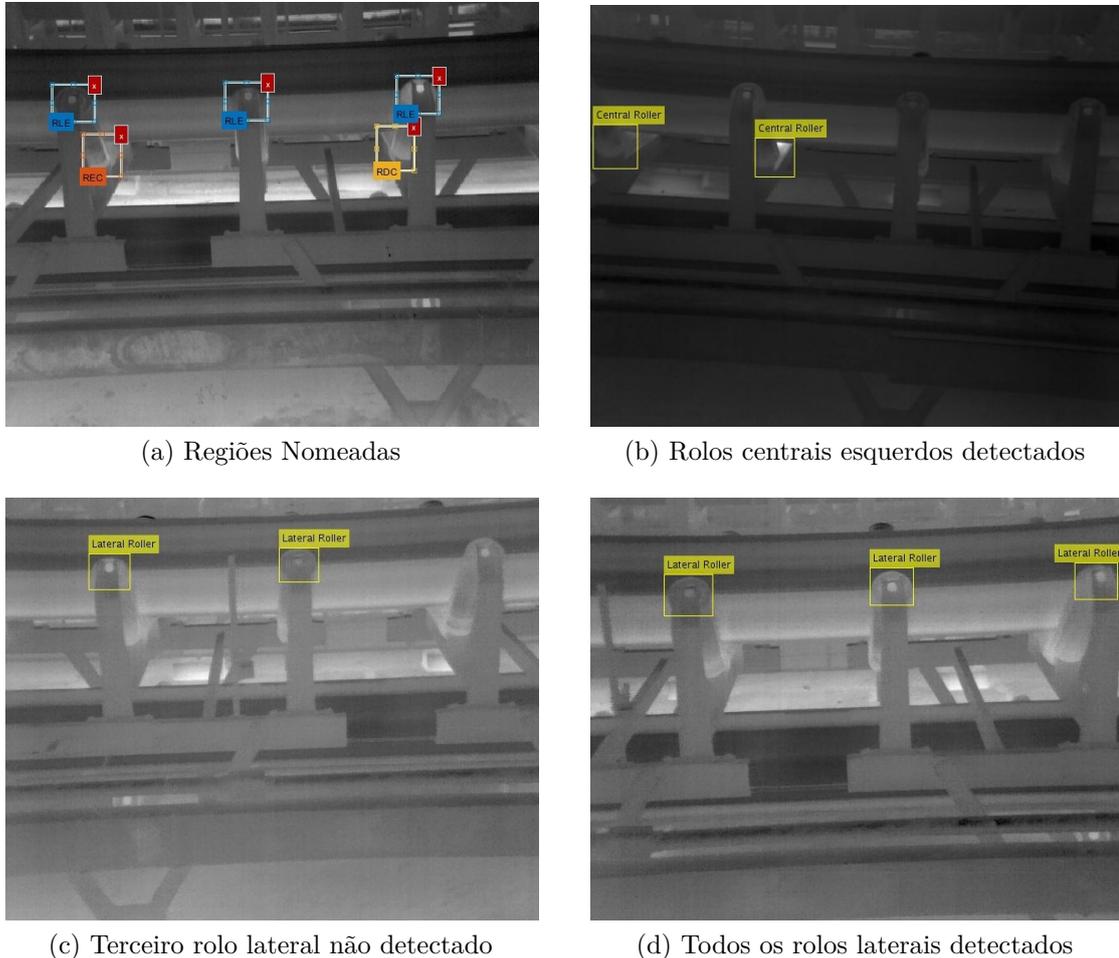


Figura 37 – Treinamento para o reconhecimento de objetos: (a) Diferentes regiões dos rolos nomeadas. (b) Rolos centrais esquerdos detectados. (c) O terceiro rolo lateral não foi encontrado pelo detector. (d) O terceiro rolo lateral que não foi encontrado na figura anterior 37c, e agora é o rolo central foi encontrado pelo detector. Fonte: Autor.

O treinamento para detectar as regiões de intersecção entre os rolos laterais e os centrais do lado esquerdo foi realizado através de 167 regiões positivas e 334 regiões negativas, retiradas de 116 imagens. Foram utilizadas duas vezes mais regiões negativas pois essa é uma maneira de aumentar a precisão do algoritmo durante o treinamento. Elas são retiradas automaticamente das imagens fornecidas como negativas, ou seja, sem a presença das ROIs e desta forma não requerem um esforço adicional com a demarcação de regiões. É importante que as imagens negativas sejam retiradas do plano de fundo das imagens que contém as regiões positivas para fortalecer o algoritmo com um ambiente real. Pode-se usar um algoritmo para auxiliar a detectar as regiões positivas antes do treinamento, mas no presente trabalho, todas as regiões positivas foram marcadas manualmente.

A delimitação das ROI é realizada por um vetor de 4 números, no formato $[x, y, largura, profundidade]$, onde os dois primeiros números dão a localização do ponto superior esquerdo do retângulo e os dois últimos a largura e profundidade, respectivamente. Esses dados foram então salvos em uma tabela chamada `Banco_de_Imagens_REC.mat`. Procedimento semelhante foi adotado para as demais ROIs. O algoritmo C.5 utilizado no Matlab pode ser conferido no Apêndice C. Nesta primeira parte, foram definidas as pastas contendo as imagens negativas e positivas e carregado esses dados para a área de trabalho do Matlab. Em sequência o código C.6 irá verificar os dados de entrada e através da função `trainCascadeObjectDetector` do Matlab repassar as entradas para a função `ocvTrainCascade` do OpenCV.

Foi utilizado uma taxa de 0,005 falsos positivos, 0,997 positivos verdadeiros e 4 estágios. Existe um trade-off entre *Overall False Positive Rate* (OFPR) (em português, Taxa Total de Falsos Positivos) $OFPR = fpr^s$, *Overall False Negative Rate* (OFNR) (em português, Taxa Total de Falsos Negativos) $OFNR = 1 - (1 - fnr)^s$ e o número de estágios s . Onde fpr é a taxa de falsos positivos por estágio e fnr é a taxa de falsos negativos por estágio. Portanto, quanto maior o número de estágios menor será a OFPR e maior a OFNR, e vice-versa. No treinamento foi utilizado uma fnr de 0,3% e apenas quatro estágios para manter uma OFNR baixa, teoricamente de apenas 1,2%. No entanto, durante os testes foi obtido uma OFNR de 11,67%, conforme Tabela 11. Felizmente a sequência de imagens coletadas, a 9Hz, oferece uma redundância espacial, já que cada rolo aparece no mínimo em 3 imagens seguidas. Consequentemente, quando leva-se em conta essa redundância a probabilidade de o rolo não ser detectado em nenhuma das 3 imagens é de apenas 0,15%. Por exemplo, na Figura 37c o terceiro rolo lateral não foi encontrado, mas na imagem subsequente, Figura 37d, todos os rolos foram encontrados inclusive o da imagem anterior. O banco de teste contém 50 imagens que não foram utilizadas no treinamento, mas estão devidamente demarcadas com todas as ROIs para calcular o resultado do algoritmo.

Tabela 7 – Avaliação do Resultado do Algoritmo, ACF, no Banco de 50 Imagens de Teste

Falso Positivo	Falso Negativo	Revocação	Precisão	Ground Truth	Verdadeiro Positivo
50	7	88%	51%	60	53

A Tabela 7 apresenta os resultados de Falso Positivo, Falso Negativo, Revocação, Precisão, *Ground Truth* e Verdadeiro Positivo do banco de imagens teste para cada uma das 50 imagens. O detector utilizado foi o do tipo REC e tabelas semelhantes podem ser montadas para os demais modelos. Um verdadeiro positivo é contado quando a região detectada sobrepõe no mínimo 50% da região do *ground truth*. Do total de 60 regiões demarcadas somente 7 não foram encontradas pelo algoritmo. Na Figura 38 foi plotado em 6 imagens as regiões detectadas, em amarelo, e as regiões do *ground truth* em ciano. Das

seis imagens apresentadas somente na do canto superior direito uma das regiões do *ground truth* não foi encontrada. Já na primeira imagem, na central inferior e na inferior direita foram encontradas regiões não pertencentes ao *ground truth*, ou seja falsos positivos.

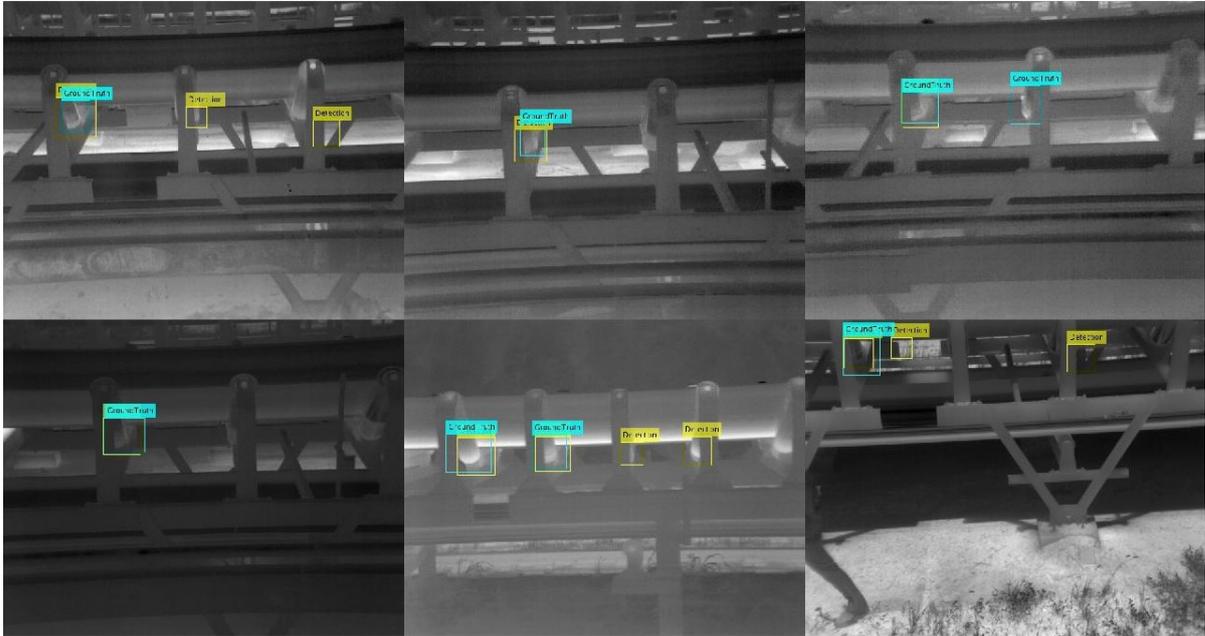
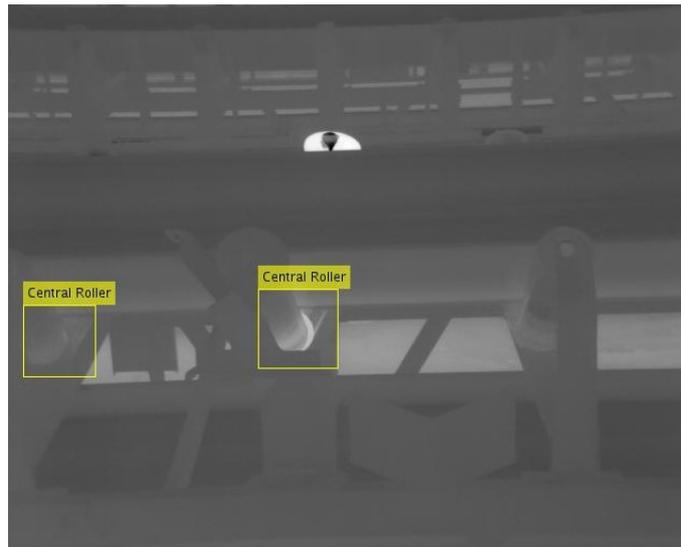


Figura 38 – Imagens com as regiões detectadas pelo algoritmo em amarelo e as regiões demarcadas como verdadeiras em ciano. Fonte: Autor

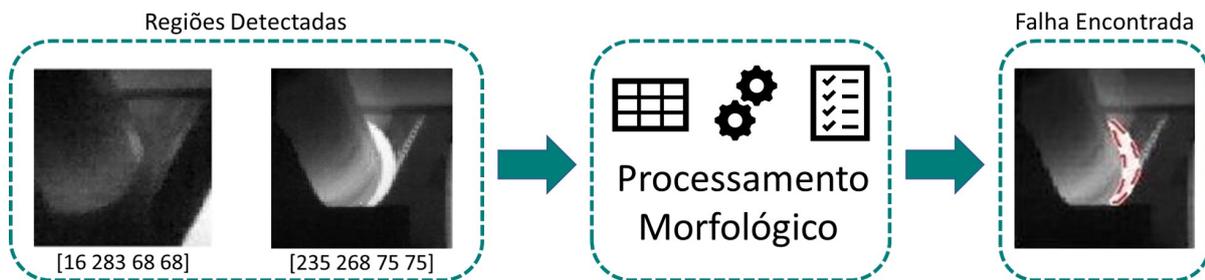
A OFPR calculado foi de 48,5%, o que também é explicado parcialmente pela pequena quantidade de estágios utilizados, uma vez que, a prioridade era a OFNR. No entanto, isso só representará um problema se a região erroneamente encontrada apresentar altos valores de temperatura, o que na maioria das vezes não acontece. Também é esperado que um banco maior de imagens nomeadas possa melhorar a OFPR sem impactar na OFNR.

Uma vez identificadas as ROIs aplica-se o processamento morfológico para identificar se a região possui um rolo defeituoso. A Figura 39 ilustra bem a abordagem proposta. Na imagem da Figura 39a, foi aplicado o detector do tipo REC, e, desta forma, só foram identificados os rolos centrais esquerdos. Note que, duas regiões foram identificadas a primeira delas com os rolos aparentemente normais e a segunda com um rolo sobreaquecido. Percebe-se também, que do outro lado da correia existe um rolo lateral sobreaquecido, mas como não foi aplicada na imagem um detector para essa região, ele se comporta como uma interferência indesejada. É um ótimo exemplo de como o algoritmo elimina pontos quentes indesejados ou pontos de alta refletância, simplesmente não lendo a temperatura nesses pontos. A Figura 39b apresenta o fluxo para a identificação dos defeitos, onde as regiões identificados são então submetidas ao processamento morfológico e somente as que atenderem aos requisitos estabelecidos é que serão identificadas como regiões defeituosas.

A abordagem proposta por Viola & Jones, apesar de antiga, continua apresentando



(a) Regiões identificadas na imagem



(b) Fluxo para a identificação de defeitos

Figura 39 – Identificação de falhas em rolos: (a) Detector do tipo REC aplicado à imagem. (b) Fluxo para a identificação de falhas em rolos. Fonte: Autor.

ótimos resultados e especificamente para esse caso dos rolos trouxe excelente taxa de falsos negativos. No entanto, a taxa de falsos positivos, apesar de ter seu impacto reduzido pelo processo morfológico, foi elevada e requer melhorias. Na próxima Seção será proposto um novo método que visa atender esses requerimentos.

Detector ACF

A abordagem ACF proposta por Dollár e Appel pode ser considerada uma evolução do método proposto por Viola & Jones. Apresentando melhores resultados tanto na OFNR quanto na OFPR. E conforme explicado na seção 3.4 o método utiliza inúmeros canais de características e uma árvore de decisão para formar um classificador robusto e rápido. Foi utilizado um banco de 116 imagens, com 644 regiões nomeadas da seguinte forma: 324 RLE, 167 REC e 153 RDC, conforme Figura 37a. Foi então realizado o treinamento de cada região individualmente conforme código do Apêndice C.8.

A função `trainACFObjectDetector` permite controlar vários aspectos do treinamento e entre eles o número de estágios. Que possui um trade-off da precisão com o tempo

de treinamento e processamento, como a velocidade do treinamento não é um problema extrapolou-se o número para 70 estágios para otimizar a precisão. Esta etapa foi repetida para cada uma das regiões de interesse. Uma vez criados os três detectores, partiu-se para a verificação do desempenho. Na comparação inicial com o método anterior os dois algoritmos obtiveram resultados equivalentes, conforme Tabela 8.

Tabela 8 – Avaliação do Resultado do Algoritmo, Viola e Jones, no Banco de 50 Imagens de Teste

Falso Positivo	Falso Negativo	Revocação	Precisão	Ground Truth	Verdadeiro Positivo
30	12	85%	63%	60	51

Entre as principais divergências, o ACF teve um total de falsos positivos 40% menor que o Viola & Jones, mas obteve um OFNR de 20% enquanto a abordagem anterior foi de apenas 11, 67%. A Tabela 12, disponível no Apêndice D, contém os resultados de cada imagem. Nota-se que na coluna de falsos negativos aparece algumas vezes o número -1, isso ocorre porque em algumas imagens todas as regiões do *ground truth* foram detectadas e algumas delas mais de uma vez. Esses valores não foram utilizados no somatório do total de falsos negativos.

Em função da proximidade dos resultados, em um banco de apenas 50 imagens, e como todas as outras 116 imagens disponíveis foram utilizadas no treinamento do detector, foi necessário obter novas imagens para o teste. Essa tarefa foi realizada com o código C.9, que extraiu um quadro a cada onze quadros de um vídeo de 38s com trinta quadros por segundo. Durante a extração de cada quadro foi aplicado os 3 detectores treinados, as regiões localizadas foram então utilizadas como facilitadoras na demarcação dos rolos. Ao todo 106 imagens foram nomeadas e cada uma delas foi manualmente verificada para conferir a correta demarcação dos rolos. Totalizando 548 regiões, onde 268 são do tipo RLE, 167 RDC e 113 REC. O banco de teste anterior foi proveniente de fotos tiradas a cada 1s enquanto o RPA se deslocava.

Tabela 9 – Avaliação do Resultado do Algoritmo, Viola e Jones, no Banco de 50 Imagens de Teste

Falso Positivo		Falso Negativo		Revocação		Precisão		Ground Truth		Verdadeiro Positivo	
VJ	ACF	VJ	ACF	VJ	ACF	VJ	ACF	VJ	ACF	VJ	ACF
75	65	37	10	67%	95%	50%	62%	113	113	76	107

A Tabela 9 apresenta o resultado da comparação entre os dois algoritmos. O ACF nesta nova confrontação teve um resultado superior ao Viola & Jones (VJ), o OFNR foi de 8, 85% e 32, 74% respectivamente. O número total de falsos positivos foi de 75 para o

VJ e de 65 para o ACF, já a quantidade de falsos negativos foi 37 e 10 respectivamente. Ficou evidente o melhor desempenho do ACF. O resultado para cada imagem pode ser encontrado na Tabela 13, disponível no Apêndice D

Também foram utilizadas duas métricas complementares, a taxa de falsos negativos versus falsos positivos, conforme proposto em (DOLLAR et al., 2012). E a curva de precisão versus revocação conforme definido em (HOIEM; CHODPATHUMWAN; DAI, 2012) e (EVERINGHAM et al.,), em que 50% de sobreposição entre a região detectada e a região esperada é considerado um verdadeiro positivo.

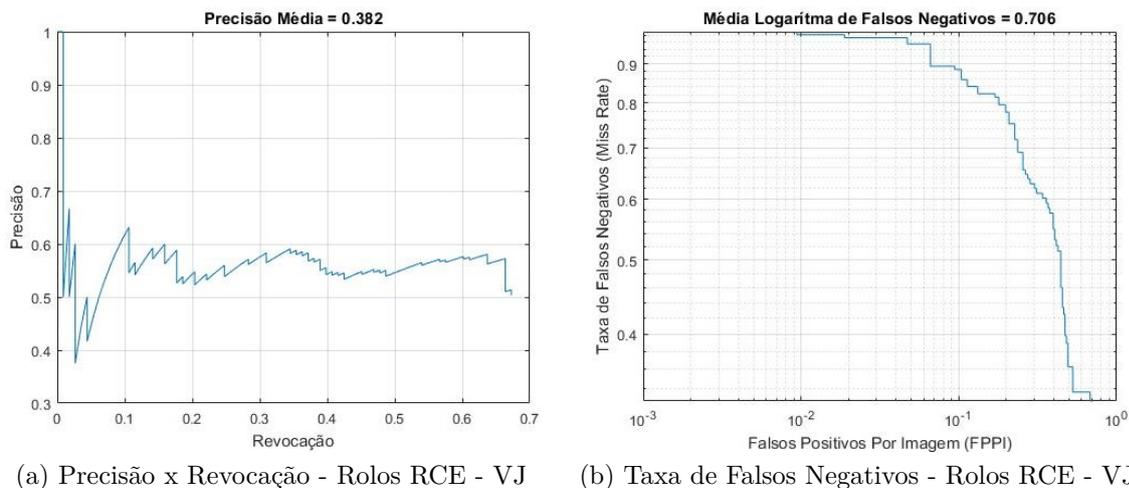


Figura 40 – Avaliação dos resultados do VJ: (a) Gráfico de precisão x revocação, com a precisão média indicada no título. (b) Gráfico da taxa de falsos negativos x falsos positivos. Fonte: Autor.

Para montar tais curvas é necessária a variação de um parâmetro que modifique os valores de falsos positivos e falsos negativos simultaneamente, ou uma terceira variável resultado que se relacione com as duas anteriores. Para o ACF essa variável é a confiança de cada detecção, no entanto o VJ não possui um modelo de cálculo definido para confiança. Observado-se o tamanho das regiões detectadas percebe-se que as que possuem áreas muito pequenas, geralmente são falsos positivos e desta forma devem possuir menor confiança. O valor para áreas dentro de uma mesma faixa são atribuídos através de uma distribuição gaussiana. Esse modelo mostrou-se aceitável e o resultado geral apresentado pelos gráficos é coerente com os resultados das tabelas de resultados.

Na Figura 40 estão plotados os dois gráficos mencionados. Na Figura 40a ver-se que a precisão e revocação mantêm determinada constância para o modelo de confiança adotado. E na Figura 40b verifica-se que somente para taxas próximas de 1 falso positivo por imagem são alcançados valores razoáveis de falsos negativos. Novamente em comparação com os mesmos tipos de gráficos para o ACF das Figuras 42a e 42b o resultado do VJ foi suplantado.

Cada um dos detectores ACF foi então avaliado nesse novo banco de imagens nomeadas através das duas métricas descritas anteriormente. O código C.10 para realizar cada uma dessas avaliações é descrito no Apêndice C.

A primeira região avaliada foi a RLE que apresentou uma precisão média de 0,909 e obteve uma precisão acima de 0,95 para uma revocação de até 0,85, conforme Figura 41a.

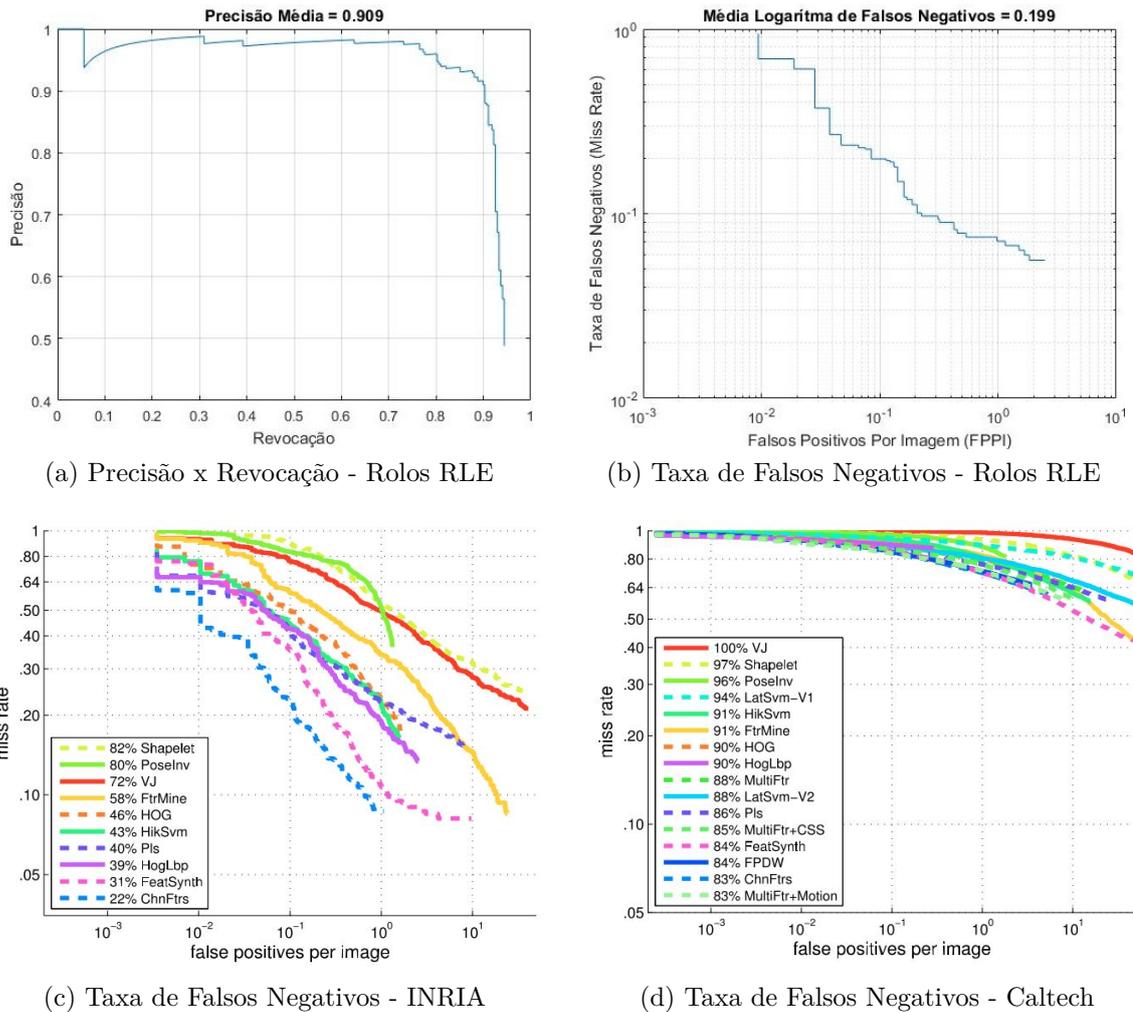
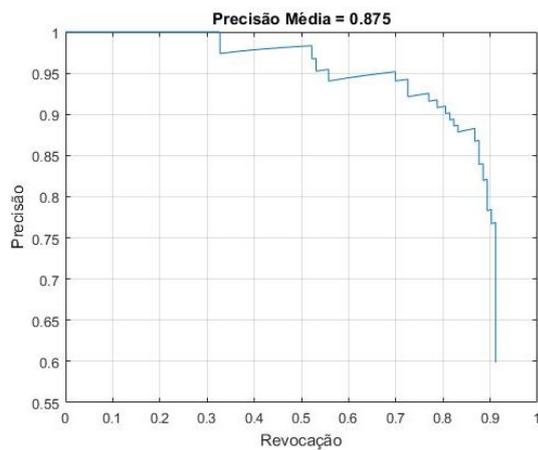


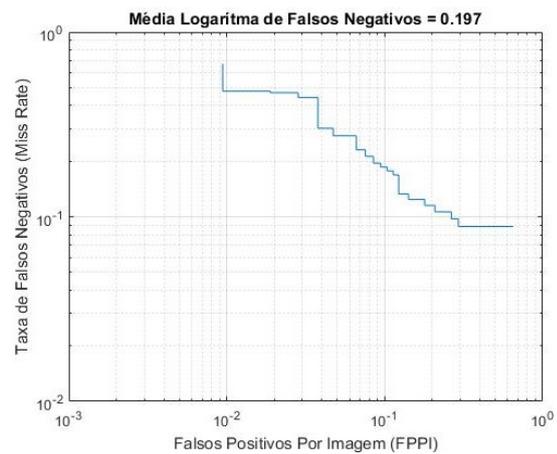
Figura 41 – Avaliação do detector RLE: (a) Gráfico de precisão x revocação, com a precisão média indicada no título. (b) Gráfico da taxa de falsos negativos x falsos positivos. (c) Avaliação de várias abordagens para a detecção de pedestres no banco de imagens INRIA. (d) Avaliação de várias abordagens para a detecção de pedestres no banco de imagens Caltech. Miss Rate é o mesmo que a taxa de falsos negativos Fonte: Autor (a) e (b). (DOLLAR et al., 2012) (c) e (d).

Na Figura 41b ver-se que a média logarítmica de falsos negativos foi de apenas 0,199 ou de 19,9%. Para comparação da representatividade desse número pode-se verificar a Figura 41c em que o melhor resultado foi de 22%, ou a Figura 41d em que o melhor resultado foi de 83%. Essa confrontação de resultados demonstra a robustez do método

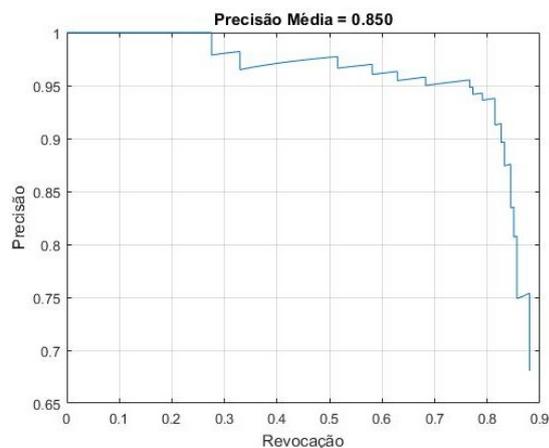
empregado, mas sem a pretensão de se declarar melhor de que qualquer um dos outros métodos. Pois as bases de imagens da INRIA e Caltech são muito maiores e complexas do que a base de imagens montada para os rolos. E a tarefa de detectar pedestres também oferece complexidades inexistentes na detecção de rolos. Aqui foi somente apresentada uma base de referência para dar uma ideia do resultado atingido e dos resultados obtidos pelos algoritmos, no estado da arte, para a detecção de pedestres. O algoritmo Viola & Jones é representado nas Figuras 41c e 41d pela linha vermelha e pela sigla VJ, e, apesar de ainda servir de referência, já foi ultrapassado pela maioria dos outros algoritmos. Já a abordagem ACF, representada pela linha tracejada em azul e pela sigla ChnFtrs, figura entre os melhores resultados para a detecção de pedestres. É importante a ressalva de que os excelentes resultados em uma determinada tarefa não garantem o mesmo desempenho em outra, no entanto o ACF se mostrou robusto na detecção de pedestres e também de rolos.



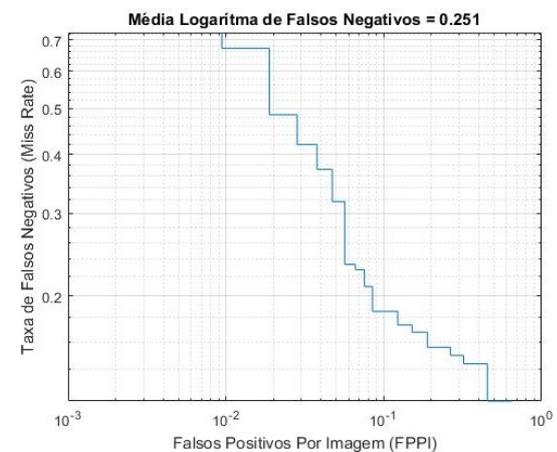
(a) Precisão x Revocação - Rolos REC



(b) Taxa de Falsos Negativos - Rolos REC



(c) Precisão x Revocação - Rolos RDC



(d) Taxa de Falsos Negativos - Rolos RDC

Figura 42 – Avaliação dos detectores REC e RDC: (a) e (c) Gráfico de precisão x revocação, com a precisão média indicada no título. (b) e (d) Gráfico da taxa de falsos negativos x falsos positivos. Fonte: Autor.

As Figuras 42a e 42c mostram que a precisão média foi de 0,875 para as imagens do tipo REC e de 0,850 para imagens do tipo RDC, valores muito próximos como esperado já que uma imagem é espelho da outra. Nos dois casos foram obtidas uma precisão de mais de 0,90 para revocação de até 0,80. Já nas figuras 42b e 42d são apresentadas as curvas de falsos negativos em razão da quantidade de falsos positivos para as imagens do tipo REC e RDC, respectivamente. Uma vez identificadas as regiões de interesse pode-se retomar o fluxo de detecção conforme apresentado na Figura 39.

6 Considerações Finais

6.1 Conclusão

A abordagem aqui proposta é composta por quatro pilares: A identificação das regiões de interesse, o processamento morfológico, dados radiométricos e a plataforma de deslocamento via RPA. Os quais formam um conjunto robusto para a identificação de defeitos em rolos, principalmente para o ambiente portuário apresentado. A falta de qualquer um dos pilares do processo proposto inviabiliza a solução. Por exemplo, sem o RPA seria muito custoso acessar os 200.000 rolos do TPM, sem os dados radiométricos, não é possível identificar os defeitos, sem a identificação das regiões dos rolos, as interferências como a refletância são elevadas e, por fim, sem o processamento morfológico, o número falsos positivos é demasiado elevado. A plataforma de transporte via RPA se mostrou extremamente eficiente com ganhos de produtividade estimados de até 93% no tempo de inspeção ¹. O algoritmo ACF para a detecção de rolos atingiu taxas de falsos negativos de até 5%, e com a redundância espacial de no mínimo 3 imagens esse número atinge o valor de apenas 0,0125%. O processamento morfológico por sua vez, juntamente com os limiares de temperatura se mostrou eficiente em eliminar os falsos positivos que mesmo com o uso do ACF permaneceu com taxas elevadas.

Foi utilizado um banco de dados pequeno para o treinamento, fato que influenciou no elevado número de falsos positivos. Pois do total de 722 imagens radiométricas coletadas somente 116 puderam ser aproveitadas para o treinamento, as demais estavam muito longe ou possuíam um ângulo de visão inadequado. Nesta situação foram extraídas 106 imagens adicionais de um vídeo para testar a precisão dos algoritmos utilizados. Os 106 quadros coletados não possuem informação radiométrica e não podem ser utilizados para o processamento morfológico. A coleta de novas imagens seguindo as premissas estabelecidas neste trabalho deverá fortalecer o algoritmo de detecção.

A principal contribuição do trabalho aqui apresentado será a redução das paradas indesejadas de produção por quebra de rolos, aproximadamente 30 por mês com 20 minutos de interrupção. Tanto pelo aumento da acurácia quanto da produtividade na inspeção dos TCs. À vista disso, a companhia VALE aprovou um investimento plurianual de 1,4 milhões de reais para a compra de equipamento, desenvolvimento das fases restantes do projeto e treinamento das equipes de inspetores.

Entre outras contribuições importantes, estão: A adaptação do algoritmo Viola &

¹ Suponha que um inspetor se desloca a 5 *km/h* e avalia o estado de um rolo em apenas 2s ele conseguiria então inspecionar um transportador de 1 *km* em 2 horas, no entanto um RPA voando a 14,4 *km/h* faz a mesma tarefa em apenas 8,4 minutos

Jones para reconhecimento de rolos, A adaptação do algoritmo ACF para reconhecimento de rolos, os processos morfológicos desenvolvidos, o algoritmo para a extração de temperatura, o banco de 222 imagens nomeadas com 1192 regiões, as premissas de voo para a correta aquisição das imagens, as premissas para a inspeção IRT dos TCs e uma pequena revisão bibliográfica sobre termografia, defeito em rolamentos, processamento de imagens e sensoriamento de rolos.

Por fim o autor considera que a proposta está pronta para entrar em operação, para determinados casos específicos, como a inspeção dos transportadores sem proteção lateral, e que as melhorias podem ser adicionadas ao projeto a medida que forem amadurecendo. Os dados a serem gerados durante as primeiras fases da operação irão servir de alavanca para se obter cada vez melhores resultados.

6.2 Trabalhos Futuros

Os resultados obtidos com o detector ACF mais, a matriz de temperatura da imagem e o processamento morfológico foram excelentes. Ainda assim, a proposta comporta inúmeras melhorias que irão tornar o processo ainda mais robusto e confiável, uma lista de algumas delas é apresentada a seguir. Inicialmente também estava previsto o desenvolvimento da identificação da localização rolos com o uso do *Differential Global Navigation Satellite System* (DGNSS) nesta primeira etapa, mas o atraso na entrega dos equipamentos não tornou isso possível.

Localização dos rolos com o uso de DGNSS. Para que o sistema possa se tornar inteiramente automático e independente da análise humana, a identificação da localização dos rolos deve ser realizada de maneira unívoca. O autor propõe realizar tal tarefa com o uso do DGNSS mais o processamento da posição do rolo na imagem. Ainda não foram realizados os primeiros testes pois os equipamentos só se tornaram disponíveis em 02/03/2018.

Aprimoramento da base de dados. Foi montada uma base de imagens para rolos em transportadores sem proteções laterais, logo, é necessário criar um banco de dados ainda maior para atender todas as situações possíveis de TCs na mineração.

Navegação Autônoma. O sistema atual depende da operação do RPA por um profissional capacitado, mas que pode cometer erros e violar as premissas estabelecidas em 4.2. O desenvolvimento de um sistema completamente autônomo que obedeça as regras estabelecidas pode tornar o método ainda mais confiável e produtivo.

Auto ajuste de parâmetros radiométricos. No modelo atual o parâmetros são configurados uma única vez para todo o voo. Pode-se conseguir maior precisão se os parâmetros puderem ser auto configuráveis durante o voo com a coleta de informações como temperatura e umidade ambiente.

Integração com o sistema. Conforme proposto em (NASCIMENTO et al., 2017) os dados coletados pelo RPA devem ser enviados automaticamente para o sistema informatizado de manutenção para capitalizar todos os ganhos propostos.

Predição de falhas. A identificação de falhas aqui proposta é baseada em limiares fixos de temperatura, um sistema ainda mais robusto pode ser desenvolvido com o uso estatístico da massa de dados coletados e comparação com os rolos vizinhos.

Aplicação para outros tipos de falhas. A abordagem aqui proposta pode ser aplicada para automatizar a identificação de outros tipos de defeitos, seguindo os passos aqui apresentados.

Aplicação de outros sensores. Para o caso da identificação de falhas em rolos os sensores térmicos se mostraram excelentes, mas outras aplicações podem requerer outros tipos de sensores que podem ser adaptados ao modelo aqui proposto.

A Funcionamento de um Transportador

O TR-313K-64 é um bom exemplo para descrever de maneira geral o funcionamento de um TC moderno com todos seus principais componentes envolvidos. Ver Figura 5, repetida aqui como Figura 43 por conveniência.

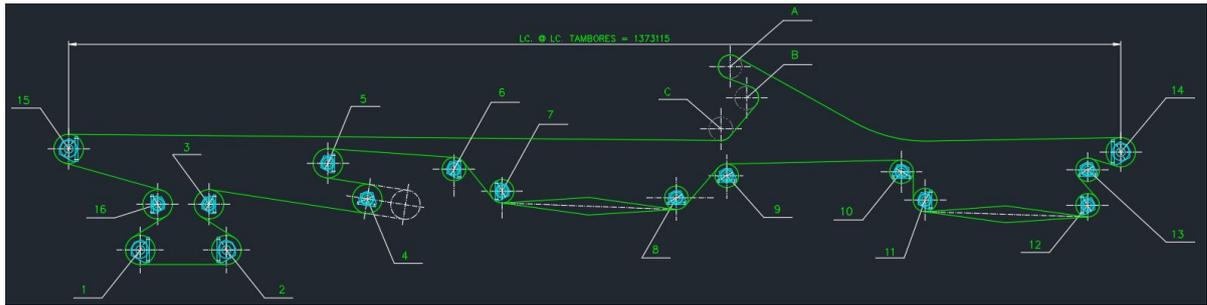


Figura 43 – Configuração do TR-313K-64 um transportador mais complexo com 19 tambores e 1,37 km de extensão. Fonte: Documentos de Engenharia Vale

Para que o TC possa se movimentar os acionamentos devem ser capazes de superar todas as forças contrárias ao movimento e que de maneira simplificada podem ser resumidas em: peso da correia, peso do material a ser transportado, momento de inercia de todos os componentes girantes como rolos e tambores e demais esforços resistentes. Outro fator importante é o atrito entre a correia e os tambores motrizes, tambores **1** e **2** da Figura 43, que devem ter um valor adequado para permitir a transmissão de movimento para a correia. Para atender esse requisito foram instalados os tambores de encosto **16** e **3**, que aumentam a tensão da correia na região dos tambores motrizes, ver Figura 43.

Na Figura 44 é possível visualizar os acionamentos de 1000 cv **A** e **B** ligados ao tambor motriz **1** e o acionamento **C** de 1500 cv ligado ao tambor motriz **2**, ver-se também a configuração do carro tensor **D** que contem o tambor **4** da Figura 43 e a torre do contra-peso **E** responsável por manter a tensão adequada na correia. Essa região apresentada na Figura 44 é chamada de cauda do transportador e usualmente é onde se encontra a maior variedade de componentes do TC como motores, redutores, acoplamentos, variadores hidráulicos, mancais, raspadores, sensores de rasgo da correia, sensores de desalinhamento, sensores de velocidade, encoders, painéis elétricos, células de carga e etc. Evidentemente, como exemplificado aqui, a complexidade do dimensionamento de um TC cresce bastante em função da aplicação e tamanho. No entanto, a inspeção dessa região, apresentada na Figura 44 que contém diversos equipamentos, é facilitada uma vez que todos esses componentes são instalados razoavelmente próximos uns dos outros, neste exemplo do TR-313K-64 essa região da cauda tem um comprimento aproximado de 52 metros.

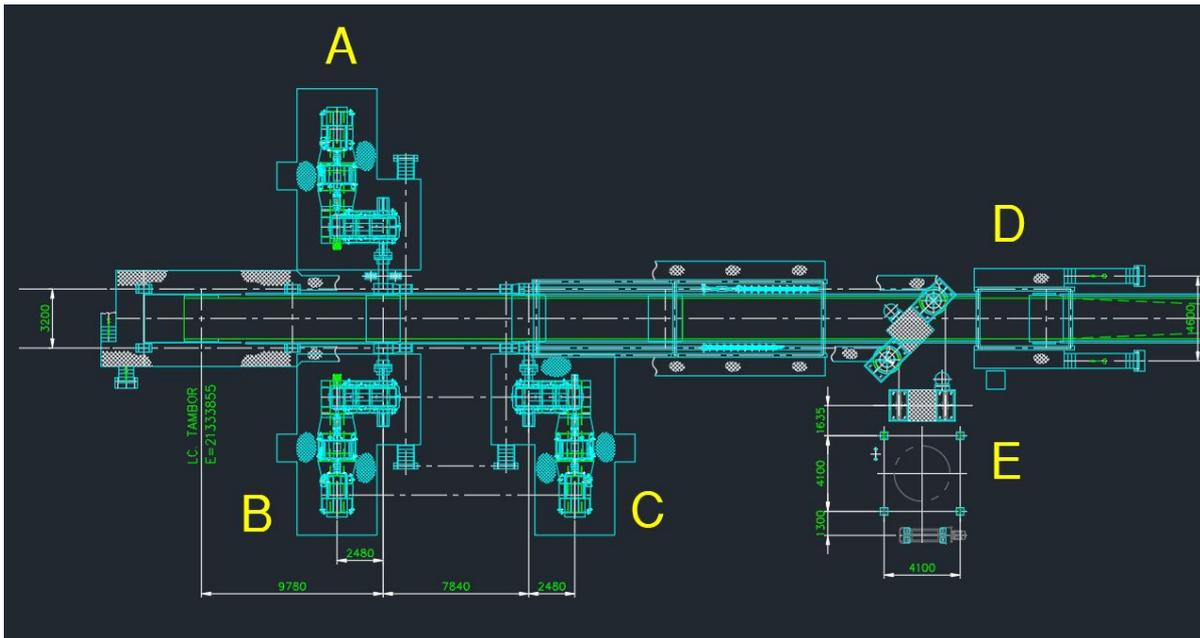


Figura 44 – Configuração da região do acionamento TR-313K-64. Esta região de apenas 52 metros contém a maior variedade de equipamentos instalados no transportador.
Fonte: Documentos de Engenharia Vale

Nos demais 1318 metros o TC é composto basicamente da sua estrutura metálica dos roletes para a sustentação da correia e de espaçados sensores de desalinhamento. A próxima seção irá detalhar a estrutura e funcionamento dos rolos e roletes.

A.1 Estrutura e Funcionamento dos Rolos e Roletes

Os rolos e roletes são os componentes mais abundantes de um TC e vários tipos e configurações são possíveis, mas todas elas têm a função principal de suportar e moldar a correia para a forma requerida em cada seção, além de diminuir a potência necessária para o transporte do material. Tomando novamente o TR-313K-64 como exemplo tem-se um total de 5367 rolos instalados em toda a sua extensão de 1,37 km. Sendo 4896 rolos de carga, 400 rolos de retorno em "V", 45 rolos de impacto, 20 rolos de retorno plano e 6 rolos guias. Cada um deles tem uma função específica e será melhor detalhada adiante.

É importante realizar a distinção entre rolos e roletes que muitas vezes causa confusão. Segundo a NBR 6177 (ABNT NBR 6177, 2016), o rolete é o conjunto de um ou mais rolos montados em um suporte com o intuito de guiar e sustentar a correia, e o rolo é o componente cilíndrico que gira sobre seu próprio eixo e sustenta a correia. Na Figura 45 estão destacados com clareza os rolos e roletes.

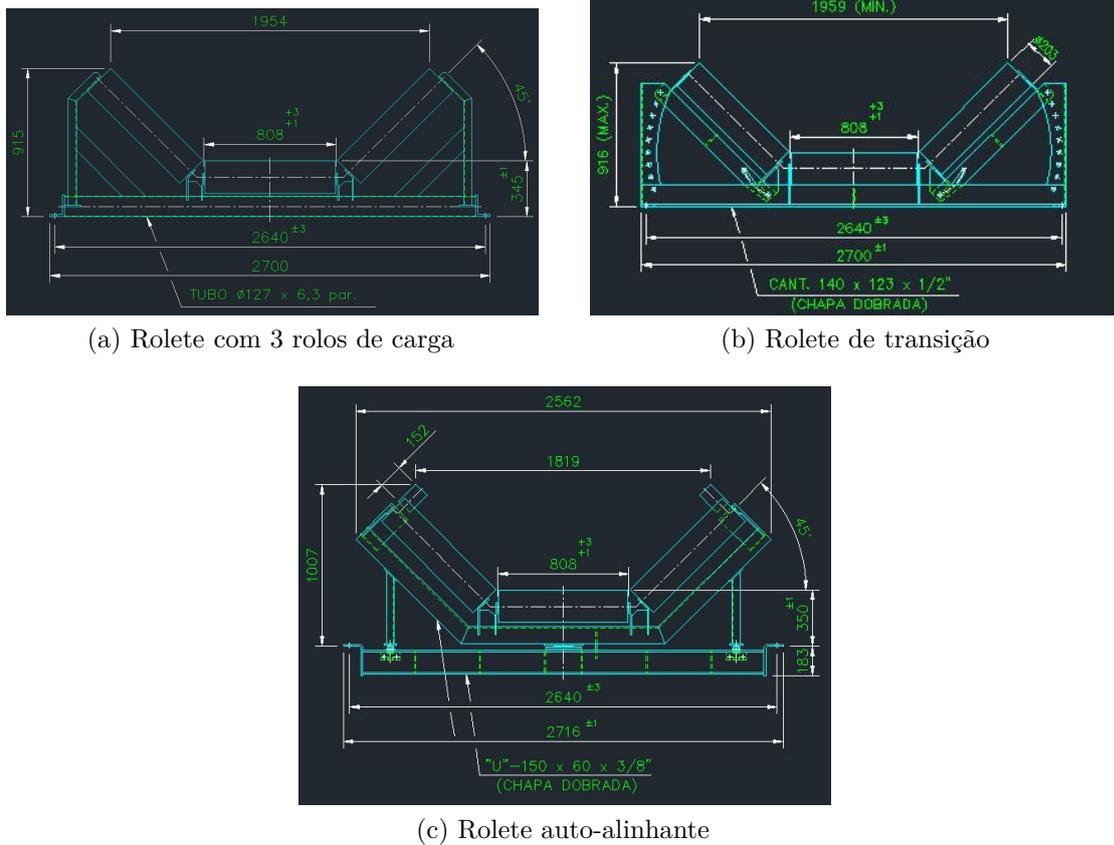
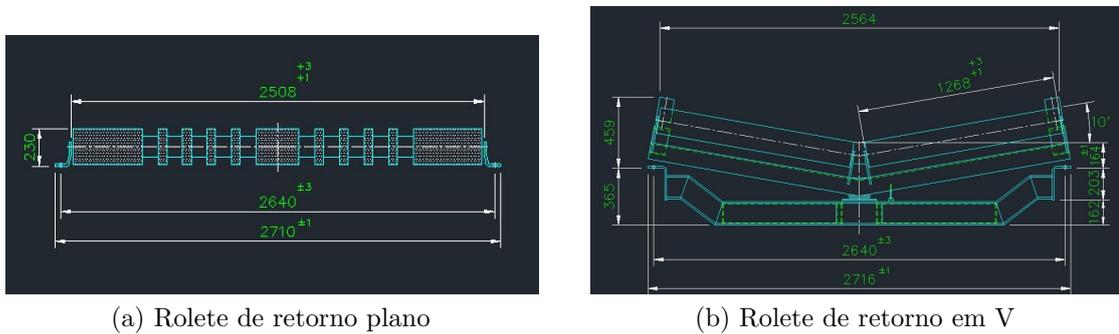


Figura 46 – Alguns tipos de roletes de carga: (a) Rolete de carga padrão com 3 rolos idênticos montados em linhas. (b) Roleta de transição que pode ter a inclinação dos rolos laterais ajustados para vários ângulos diferentes. (c) Rolete auto-alinhante com 3 rolos de carga e 2 guias, sua função é corrigir pequenos desalinhamentos. Fonte: Documentos de Engenharia Vale.

Roletes de Retorno

Os roletes de retorno oferecem suporte para a correia em todo o seu caminho de volta após o descarregamento do material transportado. O espaçamento entre eles varia de 2 m a 3 m e é calculado para que a correia não ceda de forma excessiva, não desalinhe e não entre em contato com a estrutura do transportador. Dois tipos de montagem são amplamente utilizadas no primeiro caso, ver Figura 47a, a correia é suportada por somente um rolo horizontal. Já no segundo caso a estrutura é montada em formato de "V" com o uso de dois rolos em linha, conforme Figura 47b, esse tipo de configuração reduz a energia requerida pelo acionamento e melhora o alinhamento da correia (SWINDERMAN et al., 2009). Durante o projeto é importante que seja considerado o material que fica agregado na superfície de carga da correia, pois muitas vezes esse material é extremamente abrasivo e desgasta prematuramente a carcaça do rolo de retorno. Para superar esse problema alguns rolos de retorno, chamados de autolimpantes, possuem anéis de borracha cobrindo o cilindro metálico como mostra a Figura 47a. Não se deve confundir o rolo de retorno autolimpante, que tem a função de evitar o desgaste do rolo, com os limpadores que fazem

a limpeza da correia pelo retorno.



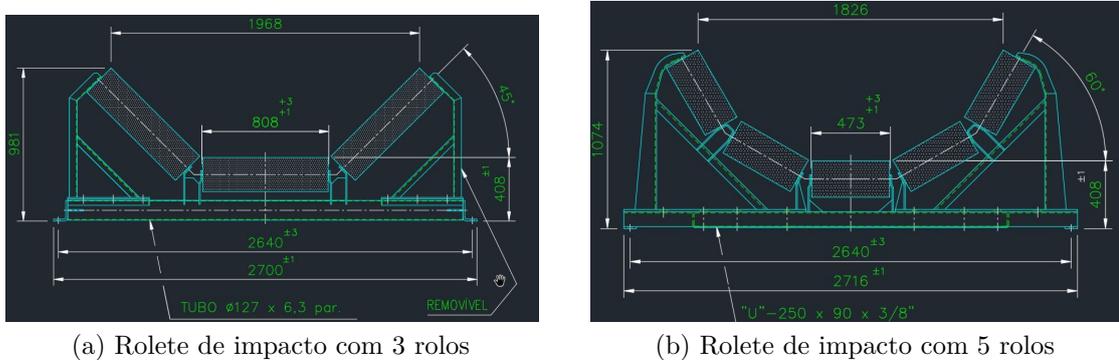
(a) Rolete de retorno plano

(b) Rolete de retorno em V

Figura 47 – Alguns tipos de roletes de retorno: **(a)** Rolete de retorno plano, neste exemplo o rolo de retorno possui anéis de borracha. **(b)** Rolete de retorno em V, que além da função de suporte também melhora o alinhamento da correia. Fonte: Documentos de Engenharia Vale.

Roletes de Impacto

Os roletes de impacto são empregados nas regiões de carregamento da correia, onde o impacto proveniente da queda do material sobre a correia poderia gerar sérios danos se não houvesse o amortecimento necessário.



(a) Rolete de impacto com 3 rolos

(b) Rolete de impacto com 5 rolos

Figura 48 – Alguns tipos de roletes de impacto: **(a)** Rolete de impacto com 3 rolos coberto com borracha, neste exemplo a lateral do suporte é removível para facilitar a troca dos rolos. **(b)** Rolete de impacto com 5 rolos cobertos com borracha. Fonte: Documentos de Engenharia Vale.

Na Figura 48a tem-se 3 rolos cobertos com anéis de borracha vulcanizada na carcaça cilíndrica de metal. Os rolos são montados em linhas, e os roletes possuem um espaçamento de apenas 0,3 m entre eles para suportar o impacto do material. Para chutes muito altos, pode-se usar a configuração apresentada na Figura 48b que possui 5 rolos de impacto montados em linha, diminuindo o esforço por eixo em cada rolo e aumentando a vida útil. Na Figura 48a também é possível ver que a lateral do suporte é removível para facilitar a troca dos rolos de impacto que têm um ciclo de vida útil menor que os cargas,

devido as condições severas de operação, e também são mais difíceis de trocar já que estão espaçados de apenas 0,3 m.

Estrutura dos Rolos

Segundo a Norma (ABNT NBR 6678, 2017) o rolo é constituído por um tubo de aço, com espessura e diâmetro adequados ao uso previsto e projetado nas suas extremidades para obter a máxima precisão de montagem. Ela também especifica que as sedes dos rolamentos devem ser resistentes e rígidas, projetadas em conformidade com a carga máxima para os diversos tipos de rolos. Um outro fator importante é o ângulo entre o rolamento e o eixo, causado pela deflexão do próprio eixo sob carga. O projeto da sede do rolamento, apesar de seguir características específicas de cada fabricante, deve ser projetada para reduzir o ângulo entre rolamento e eixo. Por último a norma recomenda que o diâmetro interno do alojamento dos rolamentos para todas as séries seja calibrado ou usinado, e os limites de tolerância deste diâmetro devem estar de acordo com a norma (ABNT NBR 6158, 1995), classe M7.

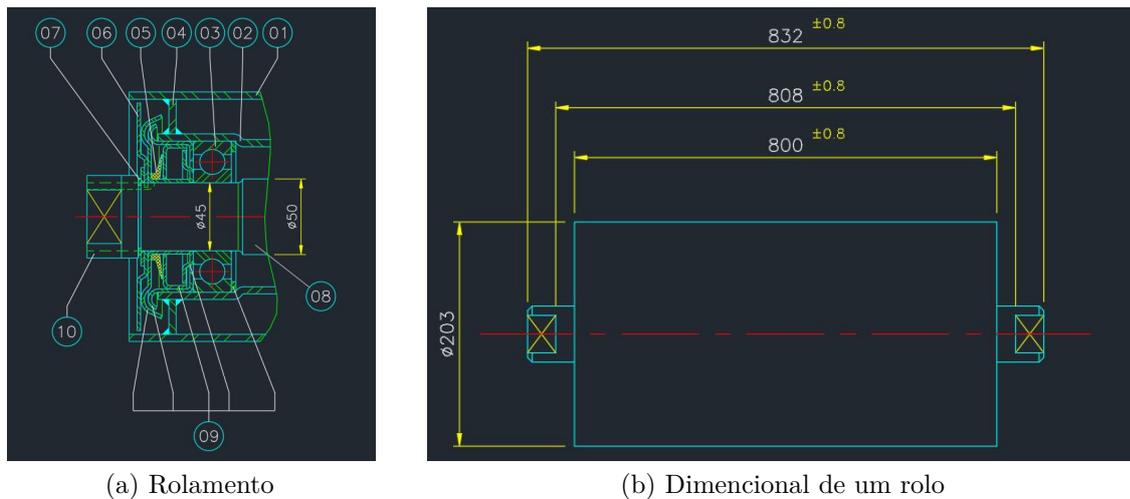


Figura 49 – Detalhes de um rolo de carga: (a) Detalhes do rolamento de um rolo de carga, a Tabela 10 descreve cada numero indicado. (b) Dimensional de um rolo de carga comum.

A Figura 49a apresenta o desenho detalhado da especificação de um rolo de carga com cada um dos seus componentes numerados de 1 a 10, ver Tabela 10. Já a Figura 49b apresenta o dimensional do mesmo rolo, que neste caso foi especificado para uma correia de 2200mm de largura com capacidade nominal de 16.000t/h. A capacidade TC e a largura da correia, no entanto, não são os únicos parâmetros a serem considerados para a especificação de um rolo, e várias outras informações devem ser consultada, como: velocidade da correia, peso da correia por metro linear, característica do material que está sendo transportado, condições ambientais, condições de operação, condições de manutenção, espaçamento dos roletes, tipo do rolete e temperatura de trabalho. Deve-se ainda considerar a condição mais

crítica de operação da correia, como capacidade maior que 100%, intempéries atmosféricas, impactos na zona de carregamento e desalinhamento.

Tabela 10 – Exemplo de Especificação para um Rolo de Carga

Ref.	Descrição	Especificação	Qtd.	Material/Fabricante
01	Tubo Externo	$\phi 8'' \times 4,75$	01	Aço ABNT 1020
02	Tubo Interno C.R.	$\phi 4'' \times 4,75$	01	Aço ABNT 1020
03	Rolamento	6309 ZZ C3	02	SKF/NSK/FAG
04	Flange	$\phi 45/\phi 8''$	02	Aço ABNT 1020
05	Retentor	$\phi 45$	02	Borracha Nitrílica
06	Blanck	$\phi 45/\phi 8''$	02	Aço ABNT 1010
07	Anel Elástico	Tipo "E" 45	02	Aço
08	Eixo	$\phi 50/45$	01	Aço ABNT 1020
09	Conjunto de Vedação	$\phi 45$ M1	02	C. Desenho F.
10	Adaptador	$\phi 50/42$	02	Aço

Na Tabela 10 tem-se um exemplo de especificação para um rolo de carga, os principais itens serão melhor detalhados abaixo:

Tubo Externo, é o elemento que dá forma ao rolo e entra em contato com a correia.

Neste exemplo a especificação solicita a fabricação do mesmo em aço ABNT 1020 e com um diâmetro de $\phi 8$ ou 203 *mm*.

Tubo Interno, é o elemento que forma a sede do rolamento, também especificado em aço ABNT 1020.

Rolamento é o componente mais importante do rolo e o qual permite que ele gire a altas velocidades, suportando uma carga elevada e com um desgaste mínimo. Neste exemplo o rolamento especificado foi rígido com uma carreira de esferas.

Eixo, é o responsável por sustentar o rolo e deve ser dimensionado obedecendo aos critérios de deflexão máxima dos rolamentos. Fabricado em aço ABNT 1020.

Conjunto de Vedação, são os componentes responsáveis por manter os lubrificantes dentro do rolamento e impedir que os contaminantes entrem.

Os rolamentos devem ser criteriosamente selecionados e existe uma série de aspectos que irá influenciar na correta seleção, a começar pelo comportamento dinâmico da aplicação que engloba fatores como: carga movimentada, espaço disponível, desalinhamento, velocidade, temperatura operacional, níveis de vibração, tipo de lubrificante e níveis de contaminação. Após a caracterização de todos esses fatores, parte-se para a definição dos tipos de rolamentos que podem ser classificados, em função do tipo de copo rolante usado na sua construção (DUBBEL et al., 1994). Existem três tipos principais de copos rolantes, os rolamentos esféricos, os rolamentos com rolos e os combinados, ver Figura 50.

Os rolamentos com esferas 50a dependendo do tipo de montagem do rolamento podem oferecer resistência axial ou radial. Já os rolamentos com rolos 50b tipicamente oferecem resistência radial e em comparação com os rolamentos esféricos de mesmo tamanho

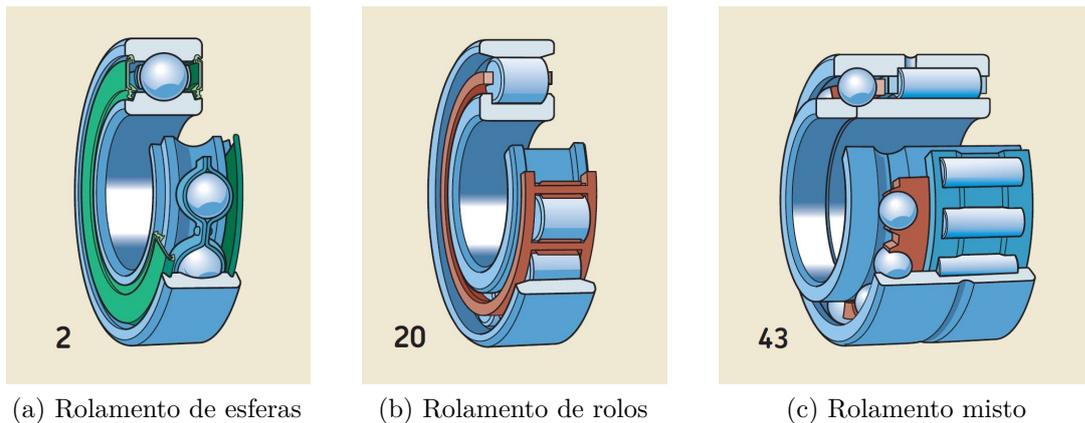


Figura 50 – Tipos de copos rolantes: **(a)** Montagem típica de um rolamento de esferas para esforços radiais. **(b)** Rolamento de rolos para cargas radiais. **(c)** Rolamento de carreira dupla combinado com rolos e esferas, oferece resistência axial e radial. Todas as figuras foram retiradas do catálogo geral de rolamentos da (SKF, 2015). A numeração 2, 20 e 43 foi mantida para facilitar a identificação das figuras no catálogo.

têm maior capacidade (SKF, 2008), mas dependendo da montagem podem oferecer certa resistência axial. E por último os rolamentos combinados 50c que podem possuir duas ou mais carreiras com esferas e rolos em cada uma delas, somando os atributos dos dois corpos rolantes. Para os rolos de carga dos transportadores de correia são especificados rolamentos radiais de esferas com uma carreira, os demais rolos do TC usam a especificação do rolo de carga que é a situação mais crítica.

Não é possível medir de forma exata o tempo de vida de um rolamento individualmente, mesmo com o conhecimento de todas as condições operacionais, pois esse tempo tem uma grande variação entre os rolamentos. No entanto pode-se estima-lo estatisticamente através de testes com vários rolamentos do mesmo tipo e sobre as mesmas condições. Usa-se o conceito de vida útil estimada L_{10} , que corresponde a vida útil em milhões de revoluções que 90% dos rolamentos de mesmo tipo irão alcançar, ou seja, 10% irão falhar prematuramente. As Equações A.1 e A.2 abaixo retiradas de (ABNT NBR ISO 281, 2010) definem L_{10} em 10^6 revoluções para cargas radiais e axiais.

$$L_{10} = \left(\frac{C_r}{P_r}\right)^p \quad \text{para cargas radiais} \quad (\text{A.1})$$

$$L_{10} = \left(\frac{C_a}{P_a}\right)^p \quad \text{para cargas axiais} \quad (\text{A.2})$$

O expoente p tem o valor 3 para rolamentos de esferas e de 10/3 para rolamento de rolos. O coeficiente C_r é a capacidade de carga dinâmica radial básica, e C_a é a capacidade de carga dinâmica axial básica, ambos em Newton para 10^6 revoluções. O coeficiente P_r é a carga dinâmica radial básica, e P_a é a carga dinâmica axial básica, ambos também em

Newton para 10^6 revoluções. Outros fatores como o tipo do material usado no rolamento, a contaminação do lubrificante e a temperatura de operação influenciam fortemente na vida útil do rolamento e tem-se então a Equação A.3.

$$L_m = a_1 a_2 f_1 L_{10} \quad (\text{A.3})$$

Onde L_m é a vida útil estimada modificada pelos fatores a_1 , a_2 e f_1 . O fator a_1 está relacionado ao tipo de material usado, a_2 tem relação com a contaminação do lubrificante e f_1 é modificado de acordo com a temperatura de operação do rolamento, todos os três fatores variam de 0 a 1.

B Visão Humana

Um entendimento básico de como os humanos adquirem e avaliam as imagens é de grande valia, pois muitas técnicas recentes são desenvolvidas em cima desses princípios. A título de exemplo, o sistema visual humano pode facilmente reconhecer objetos através da orientação ou escala dos padrões mesmo que eles possuam a mesma média em escala de cinza do ambiente. Para executar a mesma tarefa com o processamento digital de imagens usa-se operadores para determinar a orientação e escala dos padrões e assim adquirir as características da imagem (JÄHNE, 2005). O olho humano possui diversos tecidos especializados que trabalham em conjunto para a aquisição das imagens. Na Figura 51 tem-se um corte transversal simplificado do olho humano.

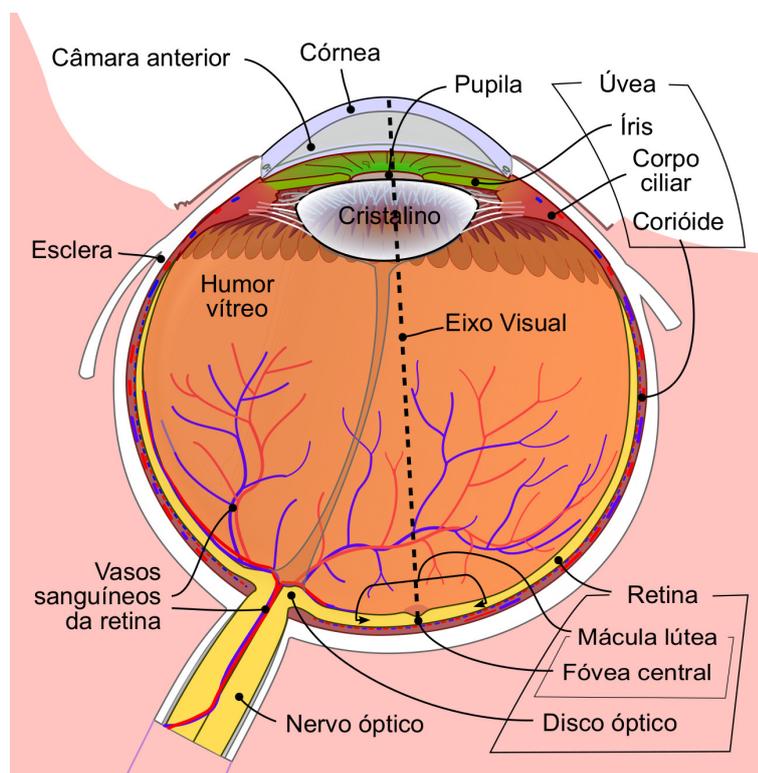


Figura 51 – Corte transversal simplificado do olho humano. Fonte: Figura foi adaptada de (COMMONS, 2016b).

O olho é uma esfera com aproximadamente 20mm coberto pela **córnea** externamente e pela **esclera** internamente. Após a esclera tem-se a **coriódio** que é responsável pela nutrição do olho por meio de sua vasta rede de vasos sanguíneos. A **íris** e o **corpo ciliar** ficam na extremidade da coriódio e são responsáveis por controlar a quantidade de luz que entra no olho, através da contração da íris. O **crystalino** localizado logo após a íris e suspenso por fibras ligadas ao corpo ciliar permite a passagem de 92% da luz visível, no entanto ele absorve grande parte do espectro IR o que em excesso pode gerar dano a

suas estruturas.

A **retina** é a camada mais interna do olho e responsável pela aquisição de imagens, por intermédio de duas classes de sensores discretos: os **cones** e os **bastonetes**. Cada olho possui aproximadamente até 7 milhões de cones e 150 milhões de bastonetes. A **fóvea** localizada na região central da retina, concentra boa parte dos cones que são capazes de distinguir pequenos detalhes, e dessa forma os músculos que controlam o olho, o direcionam para que o **eixo visual** incida na fóvea. Os bastonetes estão distribuídos por toda a retina e são sensíveis a baixos níveis de iluminação, mas por outro lado eles discernem menos detalhes do que os cones. Eles são responsáveis pela visão escotópica ou visão de luz escura, enquanto que os cones são responsáveis pela visão fotópica ou visão de luz clara. Quando leva-se em conta apenas os cones, as câmeras digitais mais modernas possuem quantidade de sensores equiparáveis (GONZALEZ; WOODS, 2010). Porém quando trata-se do processamento das imagens o homem continua superando a máquina em vários aspectos.

C Códigos para o Matlab

Neste Anexo estão contidos os principais códigos utilizados no processamento de imagens para a detecção de rolos e extração de temperatura.

Listing C.1 – Extraí os valores de temperatura de cada pixel da imagem.

```
1 %% Usa o SDK da FLIR para transformar cada pixel da imagem no seu ...
   valor de temperatura
2
3 % Abre o SDK Atlas da FLIR
4 atPath = getenv('FLIR_Atlas_MATLAB');
5 atImage = strcat(atPath, 'Flir.Atlas.Image.dll');
6 asmInfo = NET.addAssembly(atImage);
7
8 % Abre a imagem desejada
9 FileName='C:\MATLAB\DJI_0204.jpg'; % Local de arquivamento da imagem
10 file = Flir.Atlas.Image.ThermalImageFile(FileName);
11 seq = file.ThermalSequencePlayer();
12
13 % Adquire os valores dos pixels
14 img = seq.ThermalImage.ImageProcessing.GetPixelsArray;
15 im = double(img);
16 [linhas, colunas]=size(im);
17
18 % A Adquire os valores de temperatura da imagem
19 imT=zeros(linhas,colunas);
20 for i=1:1:linhas
21
22     for j=1:1:colunas
23         imT(i,j)=seq.ThermalImage.GetValueFromSignal(im(i,j));
24     end
25 end
26
27 % Máximo valor de temperatura da imagem
28 max=seq.ThermalImage.GetValueFromSignal(seq.ThermalImage.MaxSignalValue);
29 % Mínimo valor de temperatura da imagem
30 min=seq.ThermalImage.GetValueFromSignal(seq.ThermalImage.MinSignalValue);
31 [row,col] = find(imT(:,:)==max)
```

Listing C.2 – Remove objetos menores que 19 pixels.

```
1 %% – Realiza a segmentação da imagem
```

```

2
3 %Threshold da imagem – Valores maiores que 45 C podem apresentar ...
   problemas.
4 imgThresh = imT > 45;
5
6 % Remove todos os pequenos objetos conectados (8 vizinhos), que são ...
   menores que 19 pixels.
7 imgFilled = bwareaopen(imgThresh, 19, 8);

```

Listing C.3 – Imprime a demarcação das regiões encontradas.

```

1 %% Plota as regiões de interesse
2
3 % Bordas das regiões de interesse
4 imB = bwboundaries(imgFilled, 'noholes');
5
6 % Plota a imagem
7 imshow(imT, []);
8 hold on
9 visboundaries(imB, 'Color', 'r', 'LineStyle', '- -', 'LineWidth', 1)
10 plot(col, row, 'b*') % Marca a região mais quente
11 impixelinfo ;
12 hold off

```

Listing C.4 – Cria limites superior e inferior no tamanho dos pixels.

```

1 %% Elimina as partes maiores ou menores que um certo limite
2 %
3 CC = bwconncomp(imgThresh, 8); % Determina os componentes conectados
4 S = regionprops(CC, 'Area'); % Calcula a área de cada componente
5 L = labelmatrix(CC); % Nomeia as áreas
6 L1 = ismember(L, find([S.Area] <= 3000 )); % Limite superior da área
7 L2 = ismember(L, find([S.Area] >= 19 )); % Limite inferior da área
8 imgFilled= and(L1,L2); % Novas áreas delimitadas

```

Listing C.5 – Define banco de dados para treinamento.

```

1 %% Treinamento para encontrar a interseção dos rolos centrais ...
   esquerdos com os rolos laterais
2 % Carregue o bando de dados 'Banco_de_Images_REC.mat'.
3 % O banco contem 3 tabelas: uma com todas as imagens, outra com o ...
   banco para treinamento e a última para teste dos resultados.
4 % As imagens foram colhidas com o uso do drone Inspire I, com uma ...
   câmera térmica, nos dias 01, 02 e 03 de agosto.

```

```

5 % Dia 01 de agosto a noite.
6 % Dia 02 de agosto a tarde.
7 % Dia 03 de agosto pela manhã.
8 % O local dos teste foi no Porto da Vale no terminal marítimo de ...
   Ponta da Madeira.
9 %% Carregando o banco de imagens.
10 % Define as imagens positivas e negativas para o treinamento.
11
12 load('Banco_de_Imagens_REC.mat');
13
14 % Adiciona o diretório das imagens no caminho do Matlab.
15 imDir = fullfile('C:\MATLAB\Drone SLZ\Banco de Treinamento');
16 addpath(imDir);
17 % Especifica o diretório das imagens negativas.
18 negativeFolder = fullfile('C:\MATLAB\Drone SLZ\Background');
19
20 % Cria um banco de imagens negativas.
21 negativeImages = imageDatastore(negativeFolder);
22 % Resgata as regiões positivas delimitadas anteriormente.
23 positiveInstances= Banco_de_Treinamento(:,1:2);

```

Listing C.6 – Treina o algoritmo Viola e Jones.

```

1 %% Realiza o treinamento
2 % Treina um detector chamado 'XXXXXXXXX.xml'
3 % Parâmetros possíveis:
4 % 'FalseAlarmRate' – Taxa de falsos positivos aceita – 0.5 (default) ...
   – [0–1]
5 % 'TruePositiveRate' – Taxa mínima de verdadeiros positivos – 0.995 ...
   (default) – [0–1]
6 % 'NegativeSamplesFactor' – [Fator de amostras negativas] x [Número ...
   de amostras positivas por estágio]
7 % 'FeatureType' – Tipo de característica –
8   %'HOG' (default) – Melhor para objetos;
9   %'LBP' – Melhor para feições humanas;
10  %'Haar' – Melhor para feições humanas, mais demorado;
11 % 'NumCascadeStages' – 20 (default) – Número de estágios, números ...
   inteiros;
12 % 'ObjectTrainingSize' – 'Auto' (default) – tamanho do objeto para ...
   treinamento;
13
14 % Observação: Esse comando pode demorar vários minutos para terminar ...
   a execução.
15 trainCascadeObjectDetector('XXXXXXXXX.xml',positiveInstances, ...
16 negativeFolder,'NegativeSamplesFactor',2,'FalseAlarmRate', 0.005, ...
17 'TruePositiveRate',0.997,'NumCascadeStages',4);

```

O código C.7 gera o detector e imprimir as regiões detectadas na imagem.

Listing C.7 – Usa o detector treinado.

```

1 %% Cria um detector com o arquivo gerado no passo anterior
2 %Parâmetros possíveis
3 % 'MinSize' – [height width] – Tamanho do menor objeto detectável;
4 % 'MaxSize' – [height width] – Tamanho do maior objeto detectável;
5 % 'ScaleFactor' – números maiores que 1.0001 – escala para a ...
   detecção multi-escala;
6 % 'MergeDetections' – scalar integer – Limiar de detecção para ...
   regiões sobrepostas;
7 % 'UseROI' – Usa regiões de interesse pré-definidas;
8
9 detector = vision.CascadeObjectDetector('XXXXXXXXX.xml');
10 detector.MergeThreshold=2;
11
12 %% Ler uma imagem para teste.
13 img = imread('C:\MATLAB\Drone SLZ\Banco de Teste\DJI_0258.jpg');
14 % Usa o detector.
15 bbox = step(detector,img);
16 % Insere as regiões detectadas na imagem.
17 detectedImg = insertObjectAnnotation(img,'rectangle',bbox,'Central ...
   Roller');
18 % Mostra a imagem detectada.
19 figure; imshow(detectedImg);impixelinfo ;

```

Listing C.8 – Treinamento para o detector ACF.

```

1 %% Treina um detector ACF.
2 % Carrega a tabela de figuras nomeadas.
3 load('Table_Without_Null_2017_10_26.mat')
4
5 % Seleciona as colunas desejadas da tabela de regiões nomeadas.
6 Rollers = Without_Null(:, [1 2]);
7
8 % Treina o detector ACF.
9 acfDetector = trainACFObjectDetector(Rollers, 'NumStages', 70, ...
   'Verbose', true, 'NegativeSamplesFactor', 12);

```

Listing C.9 – Extração de um quadro a cada onze quadros de um vídeo.

```

1 %% Retira quadros de um vídeo
2
3 % Carrega o vídeo e coleta informações do mesmo.

```

```

4 RollersVideo = VideoReader('DJI_0285.mp4')
5 get(RollersVideo)
6
7 %% Usa os três detectores previamente treinados.
8 % Carrega os detectores
9 load('C:\Matlab\Drone SLZ\ACF_Roller_Lateral_150S.mat');
10 Detector01=acfDetector;
11 clear acfDetector;
12 load('C:\Matlab\Drone SLZ\ACF_Roller_RDC_Detector_70S.mat');
13 Detector02=acfDetector;
14 clear acfDetector;
15 load('C:\Matlab\Drone SLZ\ACF_Roller_REC_Detector_70S.mat');
16 Detector03=acfDetector;
17 clear acfDetector;
18 % Realiza a extração de um quadro
19 nframes = RollersVideo.NumberOfFrames;
20 I = read(RollersVideo, 1);
21 % Opcional para salvar o vídeo posteriormente
22 Rollers_Detected = zeros([size(I,1) size(I,2) 3 nframes], class(I));
23 % Cria um vetor estruturado para guardar os resultados
24 numframes=105;
25 results(numframes) = struct('imageFilename', [], 'RLE', [], 'REC', ...
    [], 'RDC', []);
26 % Aplica os Detectores
27 j=1;
28 for k = 1 :+11: nframes
29     singleFrame = read(RollersVideo, k);
30     % Aplica o Detector01
31     [bboxes1,scores1] = ...
        detect(Detector01,singleFrame,'SelectStrongest',true,'MinSize',[35 ...
        35]);
32     % Aplica o Detector02
33     [bboxes2,scores2] = ...
        detect(Detector02,singleFrame,'SelectStrongest',true,'MinSize',[35 ...
        35]);
34     % Aplica o Detector01
35     [bboxes3,scores3] = ...
        detect(Detector03,singleFrame,'SelectStrongest',true,'MinSize',[35 ...
        35]);
36
37     Local=sprintf('C:\\MATLAB\\Drone SLZ\\Recuperar Imagens ...
        Video\\Frames Capturados\\DJI_0285_F%03d.jpg',k);
38
39     results(j).imageFilename = Local;
40     results(j).RLE = bboxes1;
41     results(j).REC = bboxes2;
42     results(j).RDC = bboxes3;

```

```

43     % Opcional para salvar o vídeo
44     Rollers_Detected(:, :, :, k) = singleFrame;
45     j=j+1;
46 end
47
48 results_Table = struct2table(results);
49
50 %% Salva o Banco de Imagens
51
52 for k = 1 :+11: nframes
53     singleFrame = read(RollersVideo, k);
54     nome = sprintf('C:\\Matlab\\Drone SLZ\\Recuperar Imagens ...
                    Video\\Frames Capturados\\DJI_0285_F%03d.jpg', k);
55     imwrite(singleFrame, nome);
56 end

```

Listing C.10 – Avalia os detectores.

```

1 %% Faz uma avaliação geral do detector utilizado
2 % Avalia a Precisão e Revocação de detector já treinado.
3 % Calcula a taxa de Falsos Negativos x Falsos Positivos de um ...
   detector ACF
4
5 % Carrega a tabela das regiões demarcadas
6 load('Bancoteste_acada10frames_inteiras.mat')
7
8 % Seleciona o ground truth (regiões verdadeiras) dos rolos. São as ...
   regiões
9 % demarcada que sabe-se da existência de rolos.
10 Rollers =Bancoteste_acada10frames_inteiras(:, [1 2]);
11
12 %% Aplica o Detector a todas as imagens e guarda os resultados
13
14 % Cria um vetor estruturado para guardar os resultados
15 numImages = height(Rollers);
16 results(numImages) = struct('Boxes', [], 'Scores', []);
17
18 % Carrega o detector escolhido para a área de trabalho
19 load('ACF_Roller_Lateral_150S.mat');
20 detector=acfDetector;
21
22 % Aplica o detector a todas as imagens do banco de dados.
23 for i = 1 : numImages
24     I = imread(char(Rollers.imageFilename(i)));
25     [bboxes, scores] = detect(detector, ...
                               I, 'NumScaleLevels', 24, 'MinSize', [32 27]);

```

```
26     results(i).Boxes = bboxes;
27     results(i).Scores = scores;
28
29     for j = 1:length(scores)
30         annotation = sprintf('Confidence = %.1f', scores(j));
31         I = insertObjectAnnotation(I, 'rectangle', bboxes(j, :), annotation);
32     end
33     %figure, imshow(I);
34 end
35
36 results_Table = struct2table(results);
37
38 %% Avalia o resultado do detector x o ground truth
39
40 % Calcula o resultado
41 [ap, recall, precision] = ...
    evaluateDetectionPrecision(results_Table, Rollers(:, 2));
42 [am, fppi, missRate] = ...
    evaluateDetectionMissRate(results_Table, Rollers(:, 2));
43
44 % Plota o resultado Taxa de Falsos Negativos / Taxa de Falsos Positivos
45 % por Imagem (FPPI)
46 figure
47 loglog(fppi, missRate);
48 grid on
49 title(sprintf('Média Logarítma de Falsos Negativos = %.3f', am))
50 xlabel('Falsos Positivos Por Imagem (FPPI)')
51 ylabel('Taxa de Falsos Negativos (Miss Rate)')
52
53 % Plota a Precisão x Revocação
54 figure
55 plot(recall, precision)
56 grid on
57 title(sprintf('Precisão Média = %.3f', ap))
58 xlabel('Revocação')
59 ylabel('Precisão')
```

D Tabelas

A Tabela 11 apresenta os resultados de Falso Positivo, Falso Negativo, Revocação, Precisão, *Ground Truth* e Verdadeiro Positivo do banco de imagens teste para cada uma das 50 imagens.

A Tabela 12 apresenta os resultados de Falso Positivo, Falso Negativo, Revocação, Precisão, *Ground Truth* e Verdadeiro Positivo do banco de imagens teste para cada uma das 50 imagens. Foi testado o algoritmo ACF de detecção de regiões do tipo REC.

As Tabelas 13 e 14 apresentam os resultados de Falso Positivo, Falso Negativo, Revocação, Precisão, *Ground Truth* e Verdadeiro Positivo do banco de imagens teste para cada uma das 106 imagens. Foram testados os algoritmos Viola e & Jones e ACF de detecção de regiões do tipo REC.

Tabela 11 – Avaliação do Resultado do Algoritmo, Viola e Jones, no Banco de 50 Imagens de Teste

ID Imagem	Falso Positivo	Falso Negativo	Revocação	Precisão	Ground Truth	Verdadeiro Positivo
1	2	0	100%	33%	1	1
2	0	0	100%	100%	1	1
3	0	2	0%	0%	2	0
4	1	1	0%	0%	1	0
5	2	0	100%	33%	1	1
6	2	1	0%	0%	1	0
7	0	0	100%	100%	1	1
8	0	0	100%	100%	1	1
9	0	0	100%	100%	1	1
10	0	0	100%	100%	1	1
11	0	1	50%	100%	2	1
12	0	0	100%	100%	1	1
13	0	0	100%	100%	1	1
14	0	0	100%	100%	1	1
15	1	0	100%	50%	1	1
16	0	0	100%	100%	1	1
17	0	0	100%	100%	1	1
18	1	0	100%	50%	1	1
19	1	0	100%	50%	1	1
20	2	0	100%	33%	1	1
21	2	0	100%	50%	2	2
22	2	0	100%	60%	3	3
23	3	0	100%	40%	2	2
24	2	0	100%	50%	2	2
25	0	0	100%	100%	2	2
26	0	0	100%	100%	1	1
27	0	0	100%	100%	1	1
28	0	0	100%	100%	1	1
29	1	0	100%	50%	1	1
30	0	0	100%	100%	2	2
31	0	0	100%	100%	1	1
32	0	0	100%	100%	1	1
33	1	0	100%	50%	1	1
34	1	0	100%	67%	2	2
35	0	0	100%	100%	1	1
36	1	0	100%	50%	1	1
37	1	0	100%	50%	1	1
38	1	0	100%	50%	1	1
39	2	0	100%	33%	1	1
40	1	0	100%	50%	1	1
41	2	0	100%	33%	1	1
42	3	0	100%	25%	1	1
43	0	0	100%	100%	1	1
44	0	0	100%	100%	1	1
45	1	0	100%	50%	1	1
46	4	1	0%	0%	1	0
47	5	1	0%	0%	1	0
48	2	0	100%	33%	1	1
49	2	0	100%	33%	1	1
50	1	0	100%	50%	1	1
Totais	50	7	88%	51%	60	53

Tabela 12 – Avaliação do Resultado do Algoritmo, ACF, no Banco de 50 Imagens de Teste. Regiões do Tipo REC.

ID Imagem	Falso Positivo	Falso Negativo	Revocação	Precisão	Ground Truth	Verdadeiro Positivo
1	0	0	100%	100%	1	1
2	1	0	100%	50%	1	1
3	0	1	50%	100%	2	1
4	1	1	0%	0%	1	0
5	0	0	100%	100%	1	1
6	0	0	100%	100%	1	1
7	0	0	100%	100%	1	1
8	0	0	100%	100%	1	1
9	0	0	100%	100%	1	1
10	0	0	100%	100%	1	1
11	0	1	50%	100%	2	1
12	1	0	100%	50%	1	1
13	0	0	100%	100%	1	1
14	0	0	100%	100%	1	1
15	0	0	100%	100%	1	1
16	0	0	100%	100%	1	1
17	0	0	100%	100%	1	1
18	0	0	100%	100%	1	1
19	0	0	100%	100%	1	1
20	0	0	100%	100%	1	1
21	1	-1	150%	75%	2	3
22	3	1	67%	40%	3	2
23	4	1	50%	20%	2	1
24	2	0	100%	50%	2	2
25	0	0	100%	100%	2	2
26	0	0	100%	100%	1	1
27	3	0	100%	25%	1	1
28	2	0	100%	33%	1	1
29	1	-1	200%	67%	1	2
30	2	-1	150%	60%	2	3
31	0	0	100%	100%	1	1
32	0	0	100%	100%	1	1
33	0	1	0%	NaN	1	0
34	0	1	50%	100%	2	1
35	0	0	100%	100%	1	1
36	0	0	100%	100%	1	1
37	0	0	100%	100%	1	1
38	0	0	100%	100%	1	1
39	0	1	0%	NaN	1	0
40	0	0	100%	100%	1	1
41	0	0	100%	100%	1	1
42	0	0	100%	100%	1	1
43	0	0	100%	100%	1	1
44	2	1	0%	0%	1	0
45	1	1	0%	0%	1	0
46	3	1	0%	0%	1	0
47	2	1	0%	0%	1	0
48	0	0	100%	100%	1	1
49	1	0	100%	50%	1	1
50	0	0	100%	100%	1	1
Totais	30	12	85%	63%	60	51

Tabela 13 – Avaliação do Resultado dos Algoritmos ACF e Viola e & Jones, no Banco de 106 Imagens de Teste. Regiões do Tipo REC.

ID Image	Falso Positivo		Falso Negativo		Revocação		Precisão		Ground Truth		Verdadeiro Positivo	
	Detec.	VJ	ACF	VJ	ACF	VJ	ACF	VJ	ACF	VJ	ACF	VJ
1	1	1	0	0	100%	100%	67%	67%	2	2	2	2
2	1	0	0	0	100%	100%	67%	100%	2	2	2	2
3	0	1	0	0	100%	100%	100%	67%	2	2	2	2
4	1	1	0	0	100%	100%	67%	67%	2	2	2	2
5	2	4	0	0	100%	100%	50%	33%	2	2	2	2
6	1	0	1	0	50%	100%	50%	100%	2	2	1	2
7	0	1	0	0	100%	100%	100%	50%	1	1	1	1
8	0	2	0	0	100%	100%	100%	33%	1	1	1	1
9	1	0	0	0	100%	100%	50%	100%	1	1	1	1
10	0	0	1	0	50%	100%	100%	100%	2	2	1	2
11	1	4	0	0	100%	100%	50%	20%	1	1	1	1
12	2	2	1	0	0%	100%	0%	33%	1	1	0	1
13	0	0	0	0	100%	100%	100%	100%	1	1	1	1
14	0	1	0	0	100%	100%	100%	50%	1	1	1	1
15	1	0	0	-1	100%	200%	50%	100%	1	1	1	2
16	0	0	1	0	50%	100%	100%	100%	2	2	1	2
17	1	1	0	0	100%	100%	50%	50%	1	1	1	1
18	0	0	0	0	100%	100%	100%	100%	1	1	1	1
19	0	0	0	0	100%	100%	100%	100%	1	1	1	1
20	1	0	1	0	50%	100%	50%	100%	2	2	1	2
21	1	0	0	0	100%	100%	50%	100%	1	1	1	1
22	0	0	0	0	100%	100%	100%	100%	2	2	2	2
23	0	1	0	0	100%	100%	100%	50%	1	1	1	1
24	0	1	0	1	100%	50%	100%	50%	2	2	2	1
25	0	1	0	0	100%	100%	100%	50%	1	1	1	1
26	1	0	0	0	100%	100%	50%	100%	1	1	1	1
27	0	1	0	1	100%	50%	100%	50%	2	2	2	1
28	0	0	0	0	100%	100%	100%	100%	2	2	2	2
29	0	0	1	0	50%	100%	100%	100%	2	2	1	2
30	0	0	0	-1	100%	200%	100%	100%	1	1	1	2
31	1	0	0	0	100%	100%	50%	100%	1	1	1	1
32	1	0	0	0	100%	100%	50%	100%	1	1	1	1
33	0	1	1	1	50%	50%	100%	50%	2	2	1	1
34	1	0	0	0	100%	100%	50%	100%	1	1	1	1
35	0	1	2	1	0%	50%	NaN	50%	2	2	0	1
36	1	0	0	0	100%	100%	50%	100%	1	1	1	1
37	0	1	0	0	100%	100%	100%	50%	1	1	1	1
38	2	1	0	0	100%	100%	33%	50%	1	1	1	1
39	1	0	0	0	100%	100%	50%	100%	1	1	1	1
40	2	0	1	0	0%	100%	0%	100%	1	1	0	1
41	0	0	1	0	0%	100%	NaN	100%	1	1	0	1
42	0	0	1	0	0%	100%	NaN	100%	1	1	0	1
43	0	0	2	0	0%	100%	NaN	100%	2	2	0	2
44	0	1	0	0	100%	100%	100%	50%	1	1	1	1
45	1	1	0	0	100%	100%	50%	50%	1	1	1	1
46	0	2	1	1	50%	50%	100%	33%	2	2	1	1
47	2	1	1	0	50%	100%	33%	67%	2	2	1	2
48	0	0	0	0	100%	100%	100%	100%	2	2	2	2
49	0	2	0	-1	100%	150%	100%	60%	2	2	2	3
50	0	0	1	0	50%	100%	100%	100%	2	2	1	2

Referências

ABNT NBR 6158. *Sistema de tolerâncias e ajustes*. Rio de Janeiro: ABNT - Associação Brasileira de Normas Técnicas, 1995. 79 p.

ABNT NBR 6177. *Transportadores contínuos - Transportadores de correia - Terminologia*. [S.l.]: ABNT - Associação Brasileira de Normas Técnicas, 2016. 45 p.

ABNT NBR 6678. *Transportadores contínuos - Transportadores de correias - Roletes - Projeto, seleção e padronização*. Rio de Janeiro: ABNT - Associação Brasileira de Normas Técnicas, 2017. 81 p. Disponível em: <<https://www.abntcolecao.com.br>>.

ABNT NBR ISO 281. *Mancais de rolamentos — Capacidade de carga dinâmica e vida útil estimada*. Rio de Janeiro: ABNT - Associação Brasileira de Normas Técnicas, 2010. 54 p.

AI, X.; HANNON, W. M.; KOTZALAS, M. N. Rolling bearing lubrication. In: _____. *Encyclopedia of Tribology*. Boston, MA: Springer US, 2013. p. 2856–2863. ISBN 978-0-387-92897-5. Disponível em: <https://doi.org/10.1007/978-0-387-92897-5_345>.

BAGAVATHIAPPAN, S. et al. Infrared thermography for condition monitoring – A review. *Infrared Physics & Technology*, v. 60, p. 35–55, 2013. ISSN 13504495.

CANIOU, J. *Passive Infrared Detection: Theory and Applications*. Springer US, 2013. ISBN 9781475761405. Disponível em: <<https://rd.springer.com/book/10.1007/978-1-4757-6140-5>>.

CHANDEL, A. K.; PATEL, R. K. Bearing Fault Classification Based on Wavelet Transform and Artificial Neural Network. *IETE Journal of Research*, v. 59, n. February 2015, p. 219–225, 2013. ISSN 03772063.

COMMONS, W. *File:Electromagnetic-Spectrum.svg — Wikimedia Commons, the free media repository*. 2016. [Online; accessed 21-December-2017]. Disponível em: <<https://commons.wikimedia.org/w/index.php?title=File:Electromagnetic-Spectrum.svg&oldid=196988180>>.

COMMONS, W. *File:Schematic diagram of the human eye pt.svg — Wikimedia Commons, the free media repository*. 2016. [Online; accessed 16-January-2018]. Disponível em: <https://commons.wikimedia.org/w/index.php?title=File:Schematic_diagram_of_the_human_eye_pt.svg&oldid=199811234>.

COMMONS, W. *File:Electromagnetic-Spectrum-Pt.svg — Wikimedia Commons, the free media repository*. 2017. [Online; accessed 21-December-2017]. Disponível em: <<https://commons.wikimedia.org/w/index.php?title=File:Electromagnetic-Spectrum-Pt.svg&oldid=273309991>>.

Conveyor Equipment Manufacturers Association. *Belt Conveyors for Bulk Materials*. 7th. ed. 5672 Strand Ct., Ste. 2, Naples, FL: Conveyor Equipment Manufacturers Association, 2014. 829 p. ISBN 978-1-891171.44.4.

DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: *Proceedings - 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005*. IEEE, 2005. I, p. 886–893. ISBN 0769523722. ISSN 1063-6919. Disponível em: <<http://ieeexplore.ieee.org/document/1467360/>>.

DAS, A. *Guide to Signals and Patterns in Image Processing: Foundations, Methods and Applications*. Springer, 2015. ISBN 3319141716. Disponível em: <<http://www.springer.com/la/book/9783319141718>>.

DE, S. et al. Image segmentation: A review. In: _____. *Hybrid Soft Computing for Multilevel Image and Data Segmentation*. Cham: Springer International Publishing, 2016. p. 29–40. ISBN 978-3-319-47524-0. Disponível em: <https://doi.org/10.1007/978-3-319-47524-0_2>.

DEMANT, C.; GARNICA, C.; STREICHER-ABEL, B. Overview: Object features. In: _____. *Industrial Image Processing: Visual Quality Control in Manufacturing*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 303–318. ISBN 978-3-642-33905-9. Disponível em: <https://doi.org/10.1007/978-3-642-33905-9_10>.

DJI. *Manual do usuário PHANTOM 3 Advanced*. DJI, 2015. 59 p. Disponível em: <<http://www.dji.com/product/phantom-3>>.

DJI. *User Manual Inspire 1*. 2017. 64 p. Disponível em: <<http://www.dji.com/product/inspire-1>>.

DOLLÁR, P. et al. Fast Feature Pyramids for Object Detection. *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE*, v. 36, n. 8, p. 1–14, 2014.

DOLLAR, P. et al. Pedestrian detection: An evaluation of the state of the art. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 34, n. 4, p. 743–761, 2012. ISSN 01628828.

DUBBEL, H. et al. *Dubbel*. Springer-Verlag London, 1994. ISBN 978-1-4471-3566-1. Disponível em: <<https://doi.org/10.1007/978-1-4471-3566-1>>.

DUFOUR, É. *Principles of Infrared Spectroscopy*. 1. ed. Elsevier Inc., 2009. #volume#. 1–27 p. ISSN #issn#. ISBN 9780123741363. Disponível em: <<http://dx.doi.org/10.1016/B978-0-12-374136-3.00001-8>>.

ENDRES, I.; HOIEM, D. Category-independent object proposals with diverse ranking. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 36, n. 2, p. 222–234, 2014. ISSN 01628828.

Environmental Research Institute of Michigan. Infrared Information and Analysis (IRIA) Center et al. *The Infrared Handbook*. The Office, 1978. Disponível em: <<https://books.google.com.br/books?id=xf1RAAAAMAAJ>>.

EVERINGHAM, M. et al. *The PASCAL Visual Object Classes Challenge 2007 (VOC2007) Results*. [Http://www.pascal-network.org/challenges/VOC/voc2007/workshop/index.html](http://www.pascal-network.org/challenges/VOC/voc2007/workshop/index.html).

FLIR. *User Manual Zenmuse XT*. 2016. 19 p. Disponível em: <<http://www.dji.com/product/zenmuse-xt>>.

Flir System. *Flir E60 User Manual*. Wilsonville: Flir Systems Inc., 2013. 74 p. Disponível em: <<http://www.flir.com>>.

FREUND, Y.; SCHAPIRE, R. E. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, v. 55, n. 1, p. 119 – 139, 1997. ISSN 0022-0000. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S002200009791504X>>.

GAUSSORGUES, G.; CHOMET, S. *Infrared Thermography (Microwave and RF Techniques and Applications)*. Springer, 1994. ISBN 978-94-011-0711-2. Disponível em: <<https://rd.springer.com/book/10.1007/978-94-011-0711-2#about>>.

GONZALEZ, R. C.; WOODS, R. E. *Processamento Digital de Imagens (3 Ed.)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2010. ISBN 978-85-7605-401-6.

HALLIDAY, D.; RESNICK, R.; WALKER, J. *Fundamentos de física: volume 4 : óptica e física moderna*. LTC, 2009. ISBN 9788521616085. Disponível em: <<https://books.google.com.br/books?id=6cd6PgAACAAJ>>.

HANNON, W. M.; HOUPERT, L. Rolling bearing heat transfer and temperature. In: _____. *Encyclopedia of Tribology*. Boston, MA: Springer US, 2013. p. 2831–2839. ISBN 978-0-387-92897-5. Disponível em: <https://doi.org/10.1007/978-0-387-92897-5_370>.

HARZALLAH, H.; SCHMID, C.; GRENOBLE, I. Combining efficient object localization and image classification. 2009.

HE, M.; HE, D. Deep Learning Based Approach for Bearing Fault Diagnosis. *IEEE TRANSACTIONS ON INDUSTRY APPLICATIONS*, v. 53, n. 3, p. 1–13, 2013.

HOIEM, D.; CHODPATHUMWAN, Y.; DAI, Q. Diagnosing error in object detectors. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, v. 7574 LNCS, n. PART 3, p. 340–353, 2012. ISSN 03029743.

HUDA, A. S. et al. A new thermographic NDT for condition monitoring of electrical components using ANN with confidence level analysis. *ISA Transactions*, Elsevier, v. 53, n. 3, p. 717–724, 2014. ISSN 00190578. Disponível em: <<http://dx.doi.org/10.1016/j.isatra.2014.02.003>>.

Infraspection Institute. Standard for Infrared Inspection of Electrical Systems & Rotating Equipment. p. 1–18, 2008. Disponível em: <www.infraspection.com>.

INMET - Instituto Nacional de Meteorologia. *BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa*. 2017. Disponível em: <<http://www.inmet.gov.br>>.

JÄHNE, B. *Digital Image Processing*. [s.n.], 2005. 607 p. ISSN 00135127. ISBN 9783540240358. Disponível em: <<http://www.imagingbook.com/>>.

JAIN, S.; LAXMI, V. Color image segmentation techniques: A survey. In: NATH, V. (Ed.). *Proceedings of the International Conference on Microelectronics, Computing & Communication Systems*. Singapore: Springer Singapore, 2018. p. 189–197. ISBN 978-981-10-5565-2.

- JANSSENS, O. et al. Thermal image based fault diagnosis for rotating machinery. *Infrared Physics & Technology*, v. 73, p. 78–87, 2015. ISSN 13504495. Disponível em: <<http://www.sciencedirect.com.ez28.periodicos.capes.gov.br/science/article/pii/S1350449515002297>>.
- LI, H.; NGAN, K. N. Image/video segmentation: Current status, trends, and challenges. In: _____. *Video Segmentation and Its Applications*. New York, NY: Springer New York, 2011. p. 1–23. ISBN 978-1-4419-9482-0. Disponível em: <https://doi.org/10.1007/978-1-4419-9482-0_1>.
- LIU, Z. et al. Integrated imaging and vision techniques for industrial inspection: Advances and applications. *Integrated Imaging and Vision Techniques for Industrial Inspection: Advances and Applications*, p. 1–536, 2015. ISSN 09328092.
- MALDAGUE, X. *Nondestructive evaluation of materials by infrared thermography*. Springer-Verlag, 1993. ISBN 978-1-4471-1995-1. Disponível em: <<https://doi.org/10.1007/978-1-4471-1995-1>>.
- MALDAGUE, X. *Theory and practice of infrared technology for nondestructive testing*. Wiley, 2001. (Wiley series in microwave and optical engineering). ISBN 9780471181903. Disponível em: <<https://books.google.com.br/books?id=ts9RAAAAMAAJ>>.
- MATHWORKS. *Practical Introduction to Time-Frequency Analysis*. 2015. Disponível em: <<https://www.mathworks.com/help/signal/examples/practical-introduction-to-time-frequency-analysis.html?requestedDomain=www.mathworks.com>>.
- MILAN, A. et al. MOT16: A Benchmark for Multi-Object Tracking. mar 2016. Disponível em: <<http://arxiv.org/abs/1603.00831>>.
- MIN-CUTS, C. P.; MEMBER, S.; SMINCHISESCU, C. CPMC : Automatic Object Segmentation Using. v. 34, n. 7, p. 1312–1328, 2012.
- MODEST, M. *Radiative Heat Transfer*. Elsevier Science, 2013. ISBN 9780123869906. Disponível em: <<https://www.sciencedirect.com/science/book/9780123869449>>.
- MODEST, M. F. Chapter 3 - radiative properties of real surfaces. In: MODEST, M. F. (Ed.). *Radiative Heat Transfer (Third Edition)*. Third edition. Boston: Academic Press, 2013. p. 61 – 128. ISBN 978-0-12-386944-9. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780123869449500030>>.
- NASCIMENTO, R. et al. An Integrated Inspection System for Belt Conveyor Rollers - Advancing in an Enterprise Architecture. In: *Proceedings of the 19th International Conference on Enterprise Information Systems - Volume 2: ICEIS*,. Porto, Portugal: [s.n.], 2017. v. 2, p. 190–200. ISBN 978-989-758-248-6.
- PAPAGEORGIOU, C. P.; OREN, M.; POGGIO, T. A general framework for object detection. In: *Sixth International Conference on Computer Vision (IEEE Cat. No.98CH36271)*. [S.l.: s.n.], 1998. p. 555–562.
- PLATANIOTIS, K. N.; VENETSANOPOULOS, A. N. Color image segmentation. In: _____. *Color Image Processing and Applications*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2000. p. 237–277. ISBN 978-3-662-04186-4. Disponível em: <https://doi.org/10.1007/978-3-662-04186-4_6>.

RAI, A.; UPADHYAY, S. H. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings. *Tribology International*, Elsevier, v. 96, p. 289–306, 2016. ISSN 0301679X. Disponível em: <<http://dx.doi.org/10.1016/j.triboint.2015.12.037>>.

RANDALL, R. B.; ANTONI, J. Rolling element bearing diagnostics-A tutorial. *Mechanical Systems and Signal Processing*, v. 25, n. 2, p. 485–520, 2011. ISSN 08883270.

REZAEI, A. et al. A comparison study between acoustic sensors for bearing fault detection under different speed and load using a variety of signal processing techniques. *Tribology Transactions*, v. 54, n. 2, p. 179–186, 2011. ISSN 10402004.

SENNI, L. et al. On-line automatic detection of foreign bodies in biscuits by infrared thermography and image processing. *Journal of Food Engineering*, Elsevier Ltd, v. 128, p. 146–156, 2014. ISSN 02608774. Disponível em: <<http://dx.doi.org/10.1016/j.jfoodeng.2013.12.016>>.

SHIROISHI, J. et al. Bearing condition diagnostics via vibration and acoustic emission measurements. *Mechanical Systems and Signal Processing*, v. 11, n. 5, p. 693–705, 1997. ISSN 08883270.

SKF. *Rolamentos de rolos cilíndricos de fila simples*. São Paulo: Grupo SKF, 2008. 2 p. Disponível em: <skf.com>.

SKF. *Catálogo Geral de Rolamentos*. São Paulo: Grupo SKF, 2015. 1382 p. Disponível em: <skf.com>.

SUNDARARAJAN, D. *Digital Image Processing: A Signal Processing and Algorithmic Approach*. Singapore: Springer Singapore, 2017. 468 p. ISBN 978-981-10-6112-7.

SWINDERMAN, R. T. et al. *Foundations - Guia Prático para um Controle mais Limpo, Seguro e Produtivo de Pó e Material a Granel*. 4. ed. [S.l.]: Martin Engineering Ltda., 2009. 562 p. ISBN 978-0-9717121-1-9.

TONDON, N.; CHOUDHURY, A. A review of vibration and acoustics measurement methods for the detection of defects in rolling element bearing. *Tribology International*, v. 32, n. 8, p. 469–480, 1999. ISSN 0301679X.

UIJLINGS, J. R. et al. Selective search for object recognition. *International Journal of Computer Vision*, v. 104, n. 2, p. 154–171, 2013. ISSN 09205691.

U.S. Geological Survey. *Mineral Commodity Summaries*. U.S. Geological Survey, 2017. 90-91 p. Disponível em: <<https://doi.org/10.3133/70180197>>.

USAMENTIAGA, R. et al. Infrared Thermography for Temperature Measurement and Non-Destructive Testing. *Sensors*, v. 14, n. 7, 2014. ISSN 1424-8220.

VIOLA, P.; JONES, M. Rapid object detection using a boosted cascade of simple features. In: *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*. [s.n.], 2001. v. 1, p. I–511–I–518. ISBN 0-7695-1272-0. ISSN 1063-6919. Disponível em: <<http://ieeexplore.ieee.org/document/990517/>>.

- WATANABE, T.; ITO, S.; YOKOI, K. Co-occurrence Histograms of Oriented Gradients for Pedestrian Detection. In: *Advances in Image and Video Technology. PSIVT 2009*. Springer, Berlin, Heidelberg, 2009. v. 2, p. 37–47. Disponível em: <http://ieeexplore.ieee.org/xpls/abs/_all.jsp?arnumber=1467360http://link.springer.com/10.1007/978-3-540-92957->.
- WOODCOCK, C.; MASON, J. *Bulk Solids Handling: An Introduction to the Practice and Technology*. Glasgow Caledonian University, UK: Springer, Blackie Academic & Professional, 2011. ISBN 978-94-009-2635-6.
- WYSOCLCI, A.; FEEST, B. Bearing failure: Causes and cures. *EC and M: Electrical Construction and Maintenance*, v. 96, n. 2, p. 52–X6, 1997. ISSN 00134260. Disponível em: <<http://www.ecmweb.com/>>.
- Xiao-ping Jiang; Guan-qiang Cao. Belt conveyor roller fault audio detection based on the wavelet neural network. In: *2015 11th International Conference on Natural Computation (ICNC)*. [S.l.]: IEEE, 2015. p. 954–958. ISBN 978-1-4673-7679-2.
- XIE, G. S. et al. SDE: A Novel Selective, Discriminative and Equalizing Feature Representation for Visual Recognition. *International Journal of Computer Vision*, Springer US, v. 124, n. 2, p. 145–168, 2017. ISSN 15731405.
- YOUNUS, A. M.; YANG, B.-S. Intelligent fault diagnosis of rotating machinery using infrared thermal image. *Expert Systems with Applications*, v. 39, n. 2, p. 2082–2091, 2012. ISSN 09574174. Disponível em: <<http://www.sciencedirect-com.ez28.periodicos.capes.gov.br/science/article/pii/S0957417411011158>>.
- ZOU, H.; HUANG, F. A novel intelligent fault diagnosis method for electrical equipment using infrared thermography. *Infrared Physics Technology*, Pergamon, v. 73, p. 29–35, nov 2015. ISSN 1350-4495. Disponível em: <<https://www.sciencedirect.com>>.