

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ANDRÉ STANZANI FRANCA

IDENTIFICAÇÃO E MONITORAMENTO DE DORMENTES DE FERROVIAS
USANDO PROCESSAMENTO DE IMAGENS

ORIENTADORA: RAQUEL FRIZERA VASSALLO

VITÓRIA
2017

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ANDRÉ STANZANI FRANCA

IDENTIFICAÇÃO E MONITORAMENTO DE DORMENTES DE FERROVIAS
USANDO PROCESSAMENTO DE IMAGENS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito para obtenção do Grau de Mestre em Engenharia Elétrica.

Orientadora: Prof.^a Dr.^a Raquel Frizera Vassallo

VITÓRIA
2017

Dados Internacionais de Catalogação-na-publicação (CIP)
(Biblioteca Setorial Tecnológica,
Universidade Federal do Espírito Santo, ES, Brasil)

F814i Franca, André Stanzani, 1984-
Identificação e monitoramento de dormentes de ferrovias
usando processamento de imagens / André Stanzani Franca. –
2017.
127 f. : il.

Orientador: Raquel Frizera Vassallo.
Dissertação (Mestrado em Engenharia Elétrica) –
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Processamento de imagens. 2. Reconhecimento de
padrões. 3. Entropia. 4. Ferrovias. 5. Dormentes de ferrovias.
6. Haar, Transformadas de. I. Vassallo, Raquel Frizera. II.
Universidade Federal do Espírito Santo. Centro Tecnológico. III.
Título.

CDU: 621.3

Agradecimentos

As infindáveis madrugadas encharcadas em rock e blues, ideias e descobertas, tentativas e resultados subitamente terminaram. E como foram prósperas, joviais e satisfatórias esta temporada. Devo-as a minha cúmplice, Kelly A. Silveira. Lançar-me no desafio foi incentivo dela, de uma ideia que estava adormecida em mim. Contudo, como ela mesmo zela, conduzir e concluir é meu ofício. Claro que não só meu. Por vezes, também ouvi da preciosa professora Dr^a. Raquel Frizera Vassallo que era preciso convergir e definir. Companheira na ciência e na amizade desde a graduação, seus conselhos fizeram o seu primogênito ter o ritmo certo para vislumbrar essa caminhada. Recordo com animação as conversas, discussões e risos que compartilhei com os amigos e professores da pós-graduação e dos laboratórios. Em particular, agradeço a banca de avaliação da dissertação pela oportunidade e pelas discussões sobre o trabalho que durante alguns anos me tirou o sono. Sou grato também aos amigos do trabalho que incontestavelmente depositaram confiança, tempo e paciência no meu esforço e que nunca deixaram de crer que a labuta tem o seu valor. Enfim, reconheço a família Stanzani e a família Franca, minha maior torcida organizada, o perene apoio nessa jornada de conhecimento e desenvolvimento.

A tarefa não é tanto ver aquilo que ninguém viu,
mas pensar o que ninguém ainda pensou sobre aquilo que todo mundo vê
(Arthur Schopenhauer)

Resumo

A ferrovia é importante motor da economia mundial. Eficiente, segura e de grande capacidade e velocidade, esse meio de transporte de mais de 200 anos, ainda sofre com as dificuldades de manutenção, majoritariamente devido aos seus ativos de grande extensão, dispersão geográfica, quantidade e peso. Em vista disso, iniciativas em inspeção automática de ativos ferroviários vem se desenvolvendo. Em particular, a inspeção de dormentes ferroviários, que por vezes é feita manualmente, carece de desenvolvimento e consolidação. Esta dissertação apresenta um método para inventariar, identificar o tipo e defeitos em dormentes baseando-se em processamento de imagens, heurística e fusão de características de forma não-supervisionada. Utiliza-se transformada de Haar e imagens integrais, além de outras técnicas de processamento de imagens como detecção de bordas e cálculo de entropia acompanhadas de aspectos da própria topologia da ferrovia para alcançar os objetivos propostos. O desenvolvimento ocorreu sobre imagens reais, não classificadas previamente, do cotidiano ferroviário e que estavam sujeitas a diversos ruídos e variações de uma operação ferroviária autêntica. O método foi validado através de experimentos com um banco de imagens que possuem aproximadamente 33 mil dormentes. Os resultados alcançados são promissores, com acurácia de 97% na assertividade do tipo de dormente identificado e 93% na identificação de defeitos visíveis em dormentes.

Palavras-chave: Processamento de imagens. Reconhecimento de características. Transformada de Haar. Imagens integrais. Entropia. Ferrovia. Dormente.

Abstract

The railway is an important engine of the world economy. This means of transport more than 200 years old is efficient, safe and of great capacity and speed but still suffers from the difficulties of maintenance, mainly due to its assets of great extent, quantity, weight and geographic dispersion. In view of this, some initiatives in automatic inspection of railway assets have been developing. In particular, the inspection of railway sleepers (railway ties), which is sometimes done manually, needs development and consolidation. This dissertation presents a method for inventorying, identifying the type and some defects in sleepers based on image processing, heuristics and feature fusion in an unsupervised way. It uses Haar transform and integral images, as well as other image processing techniques such as edge detection and entropy computation along with aspects of railroad topology to achieve the proposed objectives. The algorithm was developed using real images of daily railway, previously unclassified, and that were subject to various noises and variations of a real railway operation. The method was validated through experiments with an image set that have approximately 33,000 sleepers. The results are promising and reach 97% accuracy in identifying the type of sleepers and reach 93% accuracy in identifying visible defects in sleepers.

Keywords: *Image processing. Features recognition. Haar transform. Integral images. Entropy. Railway. Railroad. Sleepers. Ties.*

Lista de figuras

Figura 1 – Matriz de modais de transporte comparada entre países de mesmo porte	15
Figura 2 – Ferrovias em países de mesmo porte	15
Figura 3 – Diagrama das ferrovias nos EUA e no Brasil no fim do século XVIII e atualmente	16
Figura 4 – Exemplos de material rodante	20
Figura 5 – Truque e rodeio ferroviário e o apoio nos trilhos	21
Figura 6 – Elementos da via permanente	21
Figura 7 – Diversos tipos de dormentes	23
Figura 8 – Várias representações de fixações	25
Figura 9 – Fixação do tipo Deenik	25
Figura 10 – Partes do trilho	26
Figura 11 – Aparelho de mudança de via (AMV)	26
Figura 12 – Carro controle e exemplos de medições	28
Figura 13 – Visão da câmera do carro controle	29
Figura 14 – Carro ultrassom	30
Figura 15 – Auto de linha e veículo rodoferroviário	31
Figura 16 – Exemplo de imagem utilizada para detecção de dormente de madeira	38
Figura 17 – Exemplo de imagem utilizada para detecção de dormente de aço	39
Figura 18 – Estrutura do algoritmo (diagrama)	42
Figura 19 – Tentativa de procurar os trilhos com filtro de borda (imagem original)	44
Figura 20 – Tentativa de procurar os trilhos com filtro de borda (filtro Gaussiano)	45
Figura 21 – Tentativa de procurar os trilhos com filtro de borda (filtro Bilateral)	46
Figura 22 – Tentativa de identificação da lateral do boleto do trilho	48
Figura 23 – Características do trilho e filtro de Haar peculiar	49
Figura 24 – Regiões de interesse	50
Figura 25 – Características da fixação e filtro de Haar peculiar	52
Figura 26 – Resultado do filtro de Haar de fixação sobre a imagem	53
Figura 27 – Identificação de textura usando Entropia	55
Figura 28 – Identificação de textura usando Sobel	56
Figura 29 – Exemplo da influência de um dormente descoberto na procura de outros dormentes e fusão de sensores	59
Figura 30 – Posição do dormente identificado	64
Figura 31 – Almofada isolante em detalhe	66
Figura 32 – Posição da almofada isolante entre o trilho e o dormente	67
Figura 33 – Almofada isolante não está presente em dormente de madeira	68
Figura 34 – Almofada presente em dormente de aço	68
Figura 35 – Segmentação de estrutura da almofada	69
Figura 36 – Aplicação dupla dos filtros cria artefatos	71
Figura 37 – Transformada de Hough sobre toda a almofada	72
Figura 38 – Transformada de Hough para borda vertical da almofada	73
Figura 39 – Transformada de Hough para uma borda inclinada da almofada	73
Figura 40 – Transformada de Hough sobre outra borda inclinada da almofada	73
Figura 41 – Transformada de Hough em imagem sem almofada	74

Figura 42 – Transformada de Hough em imagem com visão da almofada oclusa....	74
Figura 43 – Gradiente sobre a almofada	75
Figura 44 – Exemplos de gradientes em almofadas com presença de brita	76
Figura 45 – Exemplo de gradiente de imagem com iluminação deficiente	77
Figura 46 – Exemplos de imagens sem almofada e o respectivo gradiente resultante	78
Figura 47 – Exemplo de identificação de imagem com almofada	79
Figura 48 – Exemplo de identificação de imagem sem almofada	79
Figura 49 – Identificação dos trilhos e dos ROIs	81
Figura 50 – Identificação da fixação	82
Figura 51 – Avaliação de texturas com Entropia e Sobel	83
Figura 52 – Fusão de características e escolha das posições dos dormentes	84
Figura 53 – Avaliação da textura para identificar o dormente de madeira, aço ou brita	84
Figura 54 – Identificação de almofadas.....	85
Figura 55 – Defeitos em dormentes de madeira.....	86
Figura 56 – Candidatos a defeitos.....	88
Figura 57 – Defeitos identificados nos dormentes de madeira	89
Figura 58 – Exemplos de defeitos em dormentes de madeira.....	90
Figura 59 – Defeito em dormente de aço	91
Figura 60 – Exemplos de dormentes com manchas de líquidos.....	92
Figura 61 – Exemplos de dormentes obstruídos parcialmente por brita	93
Figura 62 – Exemplos de dormentes com vegetação.....	93
Figura 63 – Exemplos de imagens dos dois conjuntos de dados	96
Figura 64 – Exemplos de erros de classificação do tipo de dormente no Conjunto 1	104
Figura 65 – Exemplos de erros de classificação do tipo de dormente no Conjunto 2	106
Figura 66 – Diagrama com a acurácia de cada etapa	112

Lista de tabelas

Tabela 1 – Referência percentual dos custos logísticos em relação ao PIB	12
Tabela 2 – Estruturas de custos logísticos	13
Tabela 3 – Principais produtos básicos de exportação (2016 e projeção 2017)	14
Tabela 4 – Vantagens e desvantagens dos diversos modais de transporte	17
Tabela 5 – Parâmetros comparados entre diversos modais	18
Tabela 6 – Características dos conjuntos de imagens	96
Tabela 7 – Estimativa do número de amostras	98
Tabela 8 – Características das amostras aleatórias	99
Tabela 9 – Matriz de confusão genérica.....	100
Tabela 10 – Matriz de confusão para o tipo de dormente para o Conjunto 1.....	102
Tabela 11 – Matriz de confusão para o tipo de dormente para o Conjunto 2.....	102
Tabela 12 – Desempenho do teste de tipo de dormente	103
Tabela 13 – Matriz de confusão para defeito em dormente para o Conjunto 1	107
Tabela 14 – Matriz de confusão para defeito em dormente para o Conjunto 2.....	107
Tabela 15 – Desempenho de detecção de defeitos em dormentes	108
Tabela 16 – Métricas de desempenho das versões finais dos algoritmos de identificação de defeitos em dormentes por ano de publicação	110
Tabela 17 – Tempo médio de processamento em segundos	114
Tabela 18 – Métricas de desempenho possíveis extraída de Yella, Gupta e Dougherty (2007)	124
Tabela 19 – Métricas de desempenho possíveis extraída de Yella et al. (2008)	125
Tabela 20 – Métricas de desempenho possíveis extraída de Yella, Ghiamati e Dougherty (2009) – 1º nível de classificação.....	126
Tabela 21 – Métricas de desempenho possíveis extraída de Yella, Ghiamati e Dougherty (2009) – 2º nível de classificação.....	126
Tabela 22 – Métricas de desempenho possíveis extraída de Yella, Rahman e Dougherty (2010)	127

Lista de abreviaturas

ABNT	Associação Brasileira de Normas Técnicas
AEB	Associação de Comércio Exterior do Brasil
AMV	Aparelho de mudança de via
ANTF	Associação Nacional dos Transportes Ferroviários
AREMA	<i>American Railway Engineering and Maintenance-of-Way Association</i>
DNIT	Departamento Nacional de Infraestrutura de Transportes
DWT	<i>Discrete wavelets transform</i>
FIESP	Federação das indústrias do estado de São Paulo
GMM	<i>Gaussian mixture models</i>
GPS	<i>Global Positioning System</i>
HOG	<i>Histogram of oriented gradients</i> , histograma de gradientes orientados
IMU	<i>Inertial measurement unit</i>
LQV	<i>Learning vector quantisation</i>
MDIC	Ministério da Indústria, Comércio Exterior e Serviços
MLP	<i>Multi-layer perceptron</i>
Mt	Milhões de toneladas
PDF	<i>Probability density function</i> , função de densidade de probabilidade
PIB	Produto interno bruto
<i>Pixel</i>	<i>Picture element</i> , menor elemento de uma imagem
RBFNN	<i>Radial basis function neural networks</i>
ROC	<i>Receiver operating characteristic</i>
ROI	<i>Region of Interest</i> , região de interesse
STFT	<i>Fourrier transform</i>
SVM	<i>Suport vector machine</i>
TKU	Tonelada-quilômetro útil

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Modais de transporte	11
1.2	Ferrovia	19
1.3	Inspeção da via permanente.....	27
1.3.1	<i>Inspeção automática de ferrovias</i>	<i>32</i>
1.4	Objetivo da Dissertação.....	36
2.	DESENVOLVIMENTO.....	38
2.1	Encontrando a posição dos dormentes.....	43
2.1.1	<i>Encontrando os trilhos na imagem.....</i>	<i>43</i>
2.1.2	<i>Determinando as ROIs</i>	<i>50</i>
2.1.3	<i>Encontrando as fixações</i>	<i>51</i>
2.1.4	<i>Procurando dormentes</i>	<i>54</i>
2.1.5	<i>Fundindo informações para definir a posição definitiva dos dormentes</i>	<i>56</i>
2.2	Definindo onde os dormentes estão aparentes.....	64
2.3	Determinando o tipo de dormente.....	65
2.3.1	<i>Procurando texturas nos dormentes visíveis</i>	<i>65</i>
2.3.2	<i>Procurando elementos de fixação característico de certos tipos de dormentes</i>	<i>66</i>
2.4	Avaliando a qualidade dos dormentes	85
3	DESEMPENHO E RESULTADOS.....	95
4	CONCLUSÃO.....	116
	REFERÊNCIAS	119
	APÊNDICE A – Métricas de desempenho na literatura	124

1 INTRODUÇÃO

As ferrovias são um importante componente da economia global e um meio de transporte economicamente e ambientalmente eficientes, seguro e regular. Para tal, sua segurança e eficiência estão intimamente relacionadas à disponibilidade e à confiabilidade de seus ativos, entre eles, os dormentes que sustentam os trilhos da via férrea. No entanto, a inspeção dos dormentes, na maioria das ferrovias, é executada pelo inspetor que frequentemente caminha sobre a ferrovia, observando os aspectos visuais dos dormentes. Esta não é uma forma eficiente para avaliar centenas de quilômetros de ferrovia, além de permitir que a subjetividade da percepção humana influencie na avaliação da condição real da ferrovia. Algumas soluções têm sido propostas em termos de automatização da inspeção de dormentes, ainda com lacunas em termos de assertividade. Esta dissertação trata de um método de inspeção automática de dormentes em ferrovias baseado em imagens, topologia dos elementos e heurísticas pré-definidas.

No entanto, para adequado entendimento, serão conceituadas as características das ferrovias diante dos demais modais de transportes, seus elementos e diversos métodos de inspeção.

1.1 Modais de transporte

O custo total de um produto ou serviço é formado pelo custo do produto (ou de produção) e do custo logístico. Este último corresponde ao custo de disponibilizar um bem ou informação em determinado local e condição. Uma pesquisa realizada pelo Banco Mundial relaciona o quanto os custos em logística corresponde percentualmente em relação ao Produto Interno Bruto (PIB) de vários países, conforme Tabela 1. De forma peculiar nota-se que, dos países pesquisados, os países da América do Sul e Central gastam mais em logística (acima de 18% do PIB) do que os demais países, independentes da sua extensão territorial ou dificuldades geográficas. Em particular, o Brasil gasta 20% do seu PIB em custos logísticos. Segundo a mesma pesquisa, do total de custos logísticos, 31,8% correspondem, em média, a custos de transporte, conforme a Tabela 2. Aproximadamente a mesma proporção corresponde a soma dos custos administrativos e de trâmites legais, 30,6%.

Tabela 1 – Referência percentual dos custos logísticos em relação ao PIB

País	Percentual do PIB
Peru	24,0
Argentina	21,0
Brasil	20,0
México	18,0
Irlanda	14,2
Singapura	13,9
Hong Kong	13,7
Alemanha	13,0
Taiwan	13,0
Dinamarca	12,8
Portugal	12,7
Canadá	12,0
Japão	11,3
Holanda	11,3
Itália	11,2
Reino Unido	10,6
Estado Unidos	10,5

Fonte: Banco Mundial (Guasch, 2002) apud Ministério dos Transportes (2012).

Tabela 2 – Estruturas de custos logísticos

Item	Percentual
Administração	20,5
Armazenagem	19,0
Estoque	18,7
Trâmites legais	10,0
Transporte	31,8
Total	100,0

Fonte: Banco Mundial (Guasch, 2002) apud Ministério dos Transportes (2012).

Na balança comercial do Brasil, os itens de soja em grãos e minério de ferro correspondem a cerca de 41% dos 91,5 Bilhões de reais em exportações brasileiras de produtos básicos (Tabela 3).

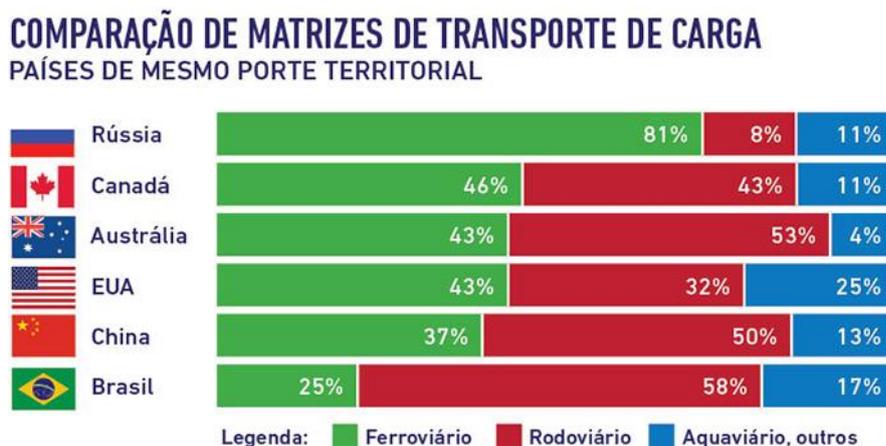
Tabela 3 – Principais produtos básicos de exportação (2016 e projeção 2017)

Produtos básicos	2017	2016	Participação
	US\$ Bilhões	US\$ Bilhões	em 2016
Soja em grão	57 Mt x \$380 = 21,660	19,098	24%
Minério de ferro	375 Mt x \$45 = 16,875	12,983	17%
Petróleo bruto	45 Mt x \$300 = 13,500	10,660	13%
Carne de frango	4,2 Mt x \$1.500 = 6,300	5,932	8%
Farelo de soja	14,8 Mt x \$350 = 5,180	5,151	7%
Café em grão	1,9 Mt x \$2.800 = 5,320	4,881	6%
Carne bovina	1,1 Mt x \$4.300 = 4,730	4,331	5%
Milho em grão	23 Mt x \$165 = 3,795	3,659	5%
Fumo em folhas	0,55 Mt x \$4.500 = 2,475	2,132	3%
Minério de cobre	1,1 Mt x \$1.800 = 1,980	1,820	2%
Carne suína	0,75 Mt x \$2.300 = 1,725	1,406	2%
Algodão em bruto	0,9 Mt x \$1.550 = 1,395	1,256	2%
Demais produtos	6,020	3,628	7%
Total	91,507	79,157	100%

Fonte: adaptado pelo autor. Valores das projeções de 2017 originalmente da Associação de Comércio Exterior do Brasil (2017) e valores executados em 2016 de Ministério da Indústria, Comércio Exterior e Serviços (2017).

Destes dois itens em particular, 40% da soja em grãos e 90% do minério de ferro são transportados por ferrovias, sem mencionar 55% das cargas de açúcar e 47% dos farelos, compondo 35% de todas as commodities agrícolas. Portanto as ferrovias representam papel importante no transporte de cargas para o Brasil. Correspondem a 25% da matriz de transporte do Brasil, atrás do modal rodoviário com 60% de participação em termos de TKU (tonelada-quilômetro transportada) (ANTF, 2016). Apesar disso, comparado a outras federações, conforme a Figura 1, o Brasil está aquém de países de mesma extensão territorial quanto ao uso das ferrovias.

Figura 1 – Matriz de modais de transporte comparada entre países de mesmo porte



Fonte: Plano Nacional de Logística e Transportes do Ministério dos Transportes (2014).

Fonte: Plano Nacional de Logística e Transporte do Ministério dos Transportes (2014) apud. ANTF (2016).

A potencialidade da implantação de ferrovias no Brasil pode ser identificada também através da densidade da malha ferroviária. Conforme a Figura 2, novamente o Brasil está bem aquém de outros países.

Figura 2 – Ferrovias em países de mesmo porte

DENSIDADE DAS MALHAS FERROVIÁRIAS

	Área (milhões km ²)	Ferrovias (mil km)	Ferrovias/Área (km/1.000 km ²)
EUA	9,83	224,79	22,9
Índia	3,29	68,53	20,8
China	9,60	191,27	19,9
África do Sul	1,22	20,99	17,2
Argentina	2,78	36,92	13,3
México	1,96	15,39	7,8
Canadá	9,98	77,93	7,8
Rússia	17,10	87,16	5,1
Austrália	7,74	36,97	4,8
Brasil	8,52	28,54	3,4

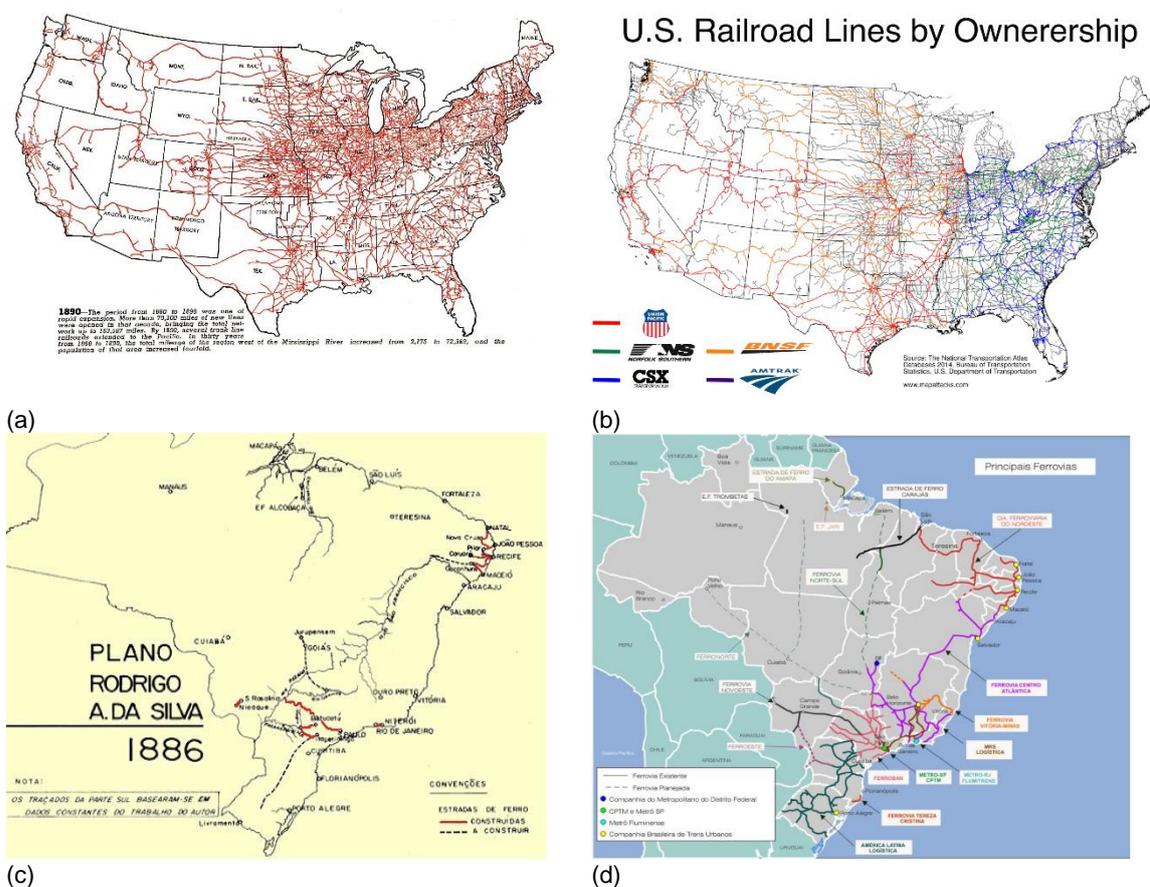
Fonte: Association of American Railroads (AAR), CIA World Factbook e ANTF.

Fonte: ANTF (2016).

Visualmente é possível perceber a diferença entre as densidades das malhas ferroviárias. Conforme a Figura 3 (a) e (b), nota-se a densidade e penetração das ferrovias nos EUA, desde 1890, com 263 mil km, e em estágio atual (2014), com 398 mil km. A Figura 3 (c) e (d) apresenta um plano de 1886 para implantação de ferrovias

no Brasil, que contava à época com 7,5 mil km instalados e também a situação atual do Brasil com os atuais 29 mil km, fruto principalmente da iniciativa privada no início do século XX.

Figura 3 – Diagrama das ferrovias nos EUA e no Brasil no fim do século XVIII e atualmente



Situação das ferrovias americanas em (a) 1890 e em (b) 2014. (c) Plano de desenvolvimento de ferrovias brasileiras em 1886. As ferrovias existentes estão marcadas com linhas vermelhas e se encontram apenas em São Paulo, Rio de Janeiro e no litoral do Nordeste. (d) Situação atual das ferrovias brasileiras. Fonte: adaptado pelo autor.

Associação Nacional dos Transportes Ferroviários (ANTF) e outras entidades competentes estimam que as ferrovias possam responder por até 35% do modal utilizado no país (FIESP, 2016). Este anseio é desejável quando se compara as características de cada modal. Conforme a Tabela 4, as ferrovias são mais eficientes energeticamente, mais adequadas quanto a vencer longas distâncias, emitem menos gases poluentes e mais seguros que o transporte rodoviário. No entanto, não apresentam facilidades quanto ao transporte porta-a-porta (com entrega em diversos pontos e customizado) e possuem alto custo de investimento de implantação.

Tabela 4 – Vantagens e desvantagens dos diversos modais de transporte

Modal de transporte	Vantagem	Desvantagem
Rodoviário	<ul style="list-style-type: none"> - Entregas ágeis e rápidas para pequenas distâncias - Flexibilidade - Maior disponibilidade de vias para transitar - Entrega porta-a-porta 	<ul style="list-style-type: none"> - Capacidade de carga e volume menor por veículo - Alto custo de operação - Alto risco de roubo e acidentes - Vias com gargalo geram maior custo e tempo de entrega - O modal mais poluidor - Alto valor de frete
Aéreo	<ul style="list-style-type: none"> - Transporte de longas distâncias - Tempo de trânsito curto - Cargas de alto valor agregado e urgentes - Seguro de transporte baixo - Próximos a centro urbanos 	<ul style="list-style-type: none"> - Limite de volume e peso - Frete elevado - Dependente de terminais de acesso - Custo elevado de infraestrutura
Aquaviário	<ul style="list-style-type: none"> - Transporte de longas distâncias e grandes volumes - Mercadorias de baixo valor agregado - Transporte transoceânico - Frete de custo relativamente baixo 	<ul style="list-style-type: none"> - Depende de vias apropriadas - Gerenciamento complexo (muitos documentos) - Depende de terminais de acesso - Tempo de trânsito longo
Ferroviário	<ul style="list-style-type: none"> - Alta eficiência energética - Adequado a grandes distâncias de transporte e grandes volumes - Inexistência de pedágios - Baixíssimo nível de acidentes - Melhores condições de segurança da carga e contra roubos - Menor poluição do meio ambiente 	<ul style="list-style-type: none"> - Tráfego limitado aos trilhos - Sistemas de bitolas inconsistentes - Malha ferroviária insuficiente - Necessita de entrepostos especializados - Necessita de outros modais complementares

Fonte: adaptado pelo autor.

Seguramente há vantagens e desvantagens entre um modal e outro. A Tabela 4 apresenta essas características resumidas e bem conhecidas dos autores de

engenharia de transportes Ballou (1993), Bustamante (1998), Ribeiro e Ferreira (2002) e Caixeta-Filho e Martins (2007).

Um caso comparativo entre os modais diferentes é apresentado por Pereira (2009) conforme a Tabela 5.

Tabela 5 – Parâmetros comparados entre diversos modais

Parâmetros	Barco (Navegação interior)	Trem	Caminhão
Peso morto por tonelada de carga transportada	350 kg	800 kg	700 kg
Força de tração: 1 c.v. arrasta	4.000 kg	500 kg	150 kg
Energia: 1 kg de carvão mineral leva 1 tonelada por	40 km	20 km	6,5 km
Investimento para transportar 1000 toneladas, em milhões de DM (marcos alemães)	0,75	2,5	3,0
Equipamentos para transportar 1000 toneladas	1 empurrador e 1 balsa	1 locomotiva e 50 vagões	50 cavalos mecânicos e 50 reboques
Vida útil em anos de uso	50	30	10
Custo (R\$ por t por km) por tonelada por km transportado	0,009	0,016	0,056

Fonte: Pereira (2009)

Apesar da navegação alcançar ótimos níveis em termos de capacidade e custos, nem sempre é possível dispor de vias fluviais e geralmente estes caminhos são mais distantes e complexos, invariavelmente incorrendo em aumento de custos. Além disso, construir vias fluviais de forma não-natural raramente é economicamente viável. Canais fluviais são viáveis quando já existem vias naturais que apenas precisam ser ligadas por eclusas e outras obras limitadas.

Portanto quando se considera aspectos de capacidade, custos e emissão de poluentes, a ferrovia é uma boa opção. Cada vagão graneleiro de 100 toneladas substitui a movimentação de quase quatro caminhões, reduzindo a poluição e os

congestionamentos nas estradas e nos centros urbanos, além de dispor de menos mão de obra para movimentação da carga.

Nesse contexto, exposto a importância da ferrovia como um modal competitivo e com papel importante na economia nacional e mundial, essa dissertação propõe uma forma automática de inspecionar a ferrovia. Em particular a inspeção se dará sobre os dormentes, elementos de sustentação da ferrovia, em termos de quantidade, tipo e qualidade destes elementos na ferrovia e em ambiente real de operação ferroviária.

Entretanto, antes de se discutir sobre inspeção automática de ferrovias é importante conhecer alguns de seus elementos.

1.2 Ferrovia

Os elementos que compõem a ferrovia são locomotivas e vagões, que constituem o material rodante, o sistema de sinalização e a via permanente.

As locomotivas podem ser, comumente, diesel, diesel-elétrica ou elétricas. São elas que fornecem a tração para movimentar os vagões. Estes, por sua vez, são classificados de acordo com os seus propósitos ou formas. Os mais comuns são do tipo gôndola (para transporte de granéis sólidos com descarga pela abertura superior), *hopper* (para transporte de granéis sólidos com descarga por abertura inferior), plataforma (que portam os mais diversos materiais, inclusive containers), tanque (para volumes líquidos) e passageiro. Alguns destes estão representados na Figura 4.

Figura 4 – Exemplos de material rodante



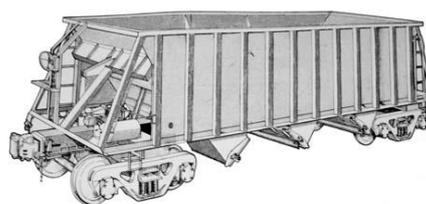
(a)



(b)



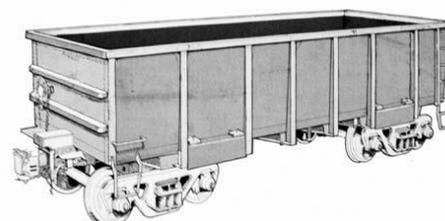
(c)



(d)



(e)

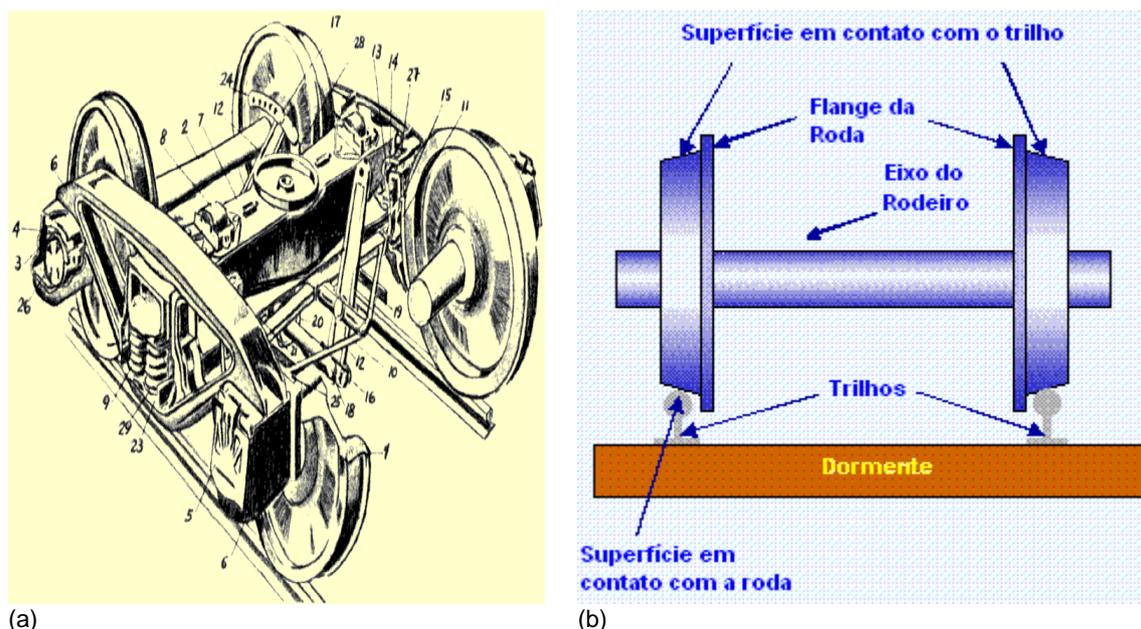


(f)

Exemplos de (a) Locomotiva, (b) Vagão plataforma, (c) e (d) Vagão Hopper, (e) e (f) Vagão gôndola.
Fonte: adaptado pelo autor.

O ponto de apoio do material rodante com a via permanente é através do rodeiro. O truque apoia-se nos rolamentos do rodeiro, que possui também um eixo e duas rodas. As rodas, por sua vez apoiam-se nos trilhos, com o seu friso tangenciando a lateral interna do boleto, conforme Figura 5.

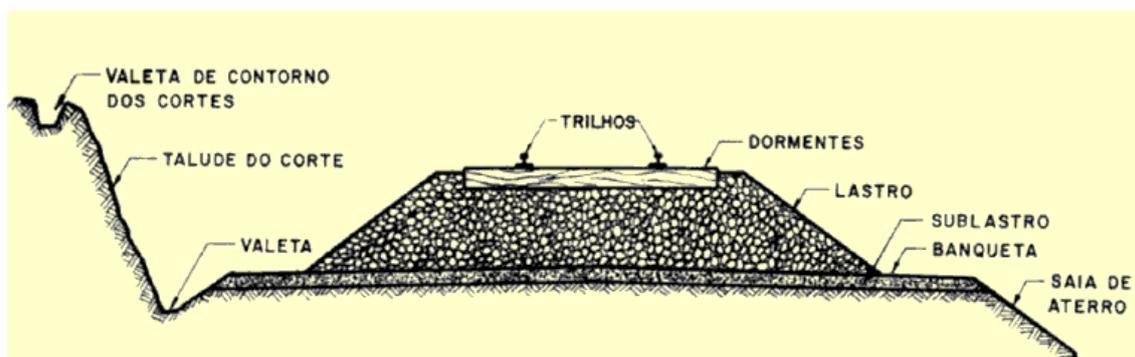
Figura 5 – Truque e rodeiro ferroviário e o apoio nos trilhos



(a) Esquemas de (a) truque e de (b) rodeiro e o ponto de contato com o trilho. Fonte: Monteiro (2010).

A via permanente é formada pelos elementos da superestrutura e da infraestrutura. A superestrutura é composta pelos trilhos, dormentes, elementos de fixação, lastro e sublastro e é responsável pelos impactos direto da carga. Por conseguinte, a infraestrutura é composta pelos demais itens da Via Permanente, a camada de terraplanagem, valetas de drenagem (sarjeta), talude de corte, saia de aterro, bueiros e obras de arte especiais (túneis e pontes) e suportam a superestrutura (BRINA, 1979) e (MONTEIRO, 2010). Os elementos da via permanente são ilustrados na Figura 6.

Figura 6 – Elementos da via permanente



Fonte Brina (1979).

O sublastro está compreendido entre o lastro e a infraestrutura e possui os objetivos de aumentar a capacidade de suporte da plataforma; evitar a penetração do lastro; aumentar a resistência do leito à erosão e à penetração de água; e permitir relativa elasticidade ao lastro. O sublastro é formado de material de solos encontrados na região e que possuam características específicas de plasticidade e elasticidade, mais barato e menos nobre que o lastro.

O lastro é formado geralmente por pedra britada (melhor opção), escória, cascalho, areia ou terra, que respondam por características particulares de peso específico, resistência, solubilidade, absorção e granulometria. Suas funções são distribuir convenientemente os esforços das cargas dos veículos sobre a plataforma; formar suporte elástico limitado, atenuando trepidações; suprimir irregularidades; impedir deslocamento dos dormentes; e facilitar a drenagem da superestrutura. Neste trabalho, será chamada de brita, a porção de lastro visível na superfície.

Os dormentes são os elementos responsáveis por receber e transmitir ao lastro os esforços das cargas, suportando os trilhos, permitindo sua fixação e mantendo invariável a distância entre eles (bitola). Para isso é preciso que suas dimensões forneçam apoio para que a taxa de trabalho do lastro não ultrapasse certos limites; que sua espessura lhe dê rigidez, entretanto com alguma elasticidade; que tenham durabilidade e resistência aos esforços; que permitam o nivelamento do lastro na sua base (não forme bolsões vazios); e que permitam fixação firme do trilho, mas sem rigidez.

Os materiais mais comuns de dormente são madeira, aço, concreto e compostos plásticos (Figura 7). Os dormentes de madeira reúnem quase todas as qualidades exigidas, mas a escassez de madeira nobre e a dificuldade de capacidade de fornecer dormentes de eucalipto de reflorestamento tem impulsionado a procura por novos materiais. Os dormentes de madeira possuem qualidades esperadas como flexibilidade, resistência a cargas, elasticidade, isolamento elétrico, permitem mudanças nos perfis de trilho e de fixação, reutilização e fácil manuseio. As desvantagens do seu uso é que são suscetíveis à queima e necessitam de tratamento anterior e sua vida útil é decrescente à medida que são utilizados dormentes de madeiras menos nobres.

Figura 7 – Diversos tipos de dormentes



Dormentes da esquerda para a direita: madeira, concreto, aço e plástico. Fonte: VALE (2011).

Os dormentes de aço são chapas metálicas com secção em forma de “U” invertido e com artifícios geométricos nas extremidades (Figura 7). Possuem vida útil elevada; são leves; necessitam de menos lastro; fornecem maior estabilidade lateral da via; e permitem recuperação após algum dano. Suas desvantagens é que são barulhentos ao tráfego; condutores de eletricidade (problemas para os circuitos de sinalização através do trilho); possibilidade de corrosão; fixação complicada e com necessidade de reaperto; e alto custo de aquisição.

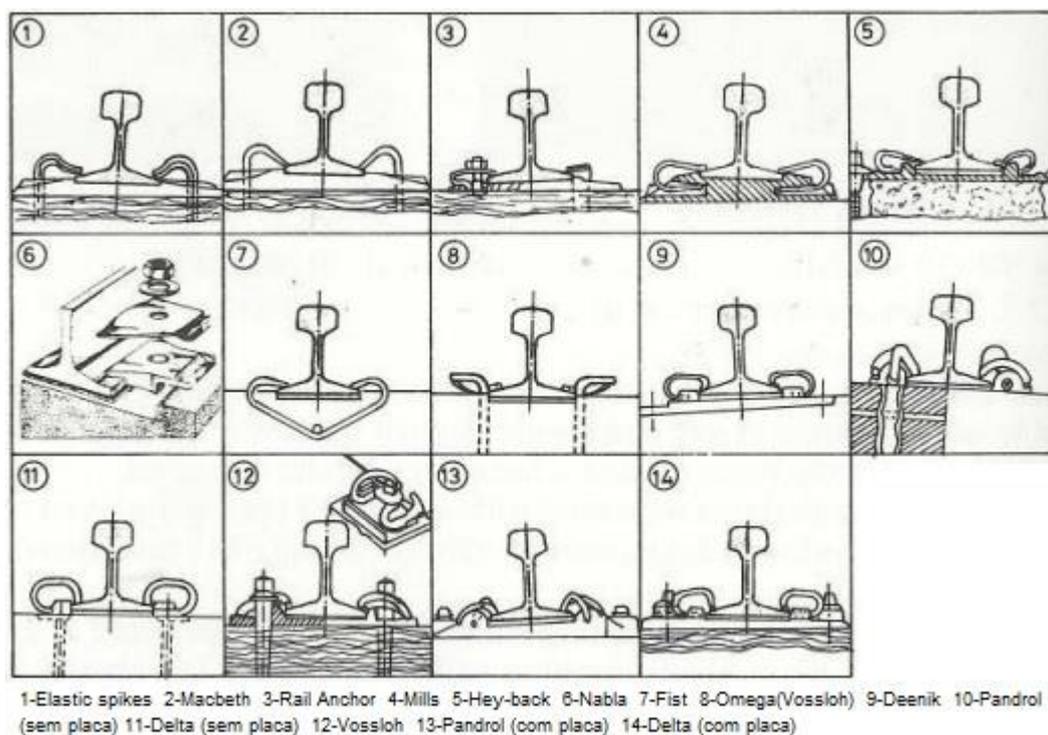
Os dormentes de concreto são uma alternativa aos dormentes de aço para vias de alto tráfego e demais problemas relatados, e também para a substituição de dormentes de madeira. São geralmente em formato trapezoidal (para melhor distribuição dos esforços). Podem ser monoblocos (uma única peça de concreto e aço protendido) ou bi-blocos (duas peças de concreto e aço protendido nas extremidades unidas por uma barra metálica). Possuem a vantagem de vida útil elevada; grande estabilidade da via; insensível a fogo e fungos; facilidade de controle (inclusive variação mínima da bitola) e inspeção; e menor taxa de aplicação por extensão ao longo da ferrovia. No entanto, há também desvantagens: dificuldade de manuseio devido ao peso; maior possibilidade de quebra (diferente da madeira e do aço em que as trincas evoluem lentamente, no concreto as trincas evoluem muito rápido); alto custo inicial; necessita de maior volume de lastro; exige maior cuidado com o lastro para evitar falta de apoio e conseqüente quebra do dormente; e exige maior cuidado com a socaria, pois é mais sensível a impactos mecânicos.

Por fim os dormentes de plástico são uma solução sustentavelmente correta. São feitos de material plástico descartável - um compósito de matriz polimérica dispersado com fibras de vidro - de modo a possuir as características desejadas para os dormentes. As vantagens são vida útil calculada de mais de 50 anos; material leve; suporte de grandes cargas; não racha e não trinca; eletricamente não condutivo; impermeável à água e agentes biológicos; resistente a óleo diesel, óleo mineral e graxa; absorve vibrações. No entanto ainda carece de estudos e testes detalhados das comprovações das vantagens e viabilidade técnica.

Os dormentes podem ser considerados inaptos quando não mais apresentam o suporte necessário à via, principalmente suporte lateral, permitindo a abertura de bitola. Essa inaptidão pode ocorrer devido a acidentes ferroviários. No caso de um descarrilamento, os dormentes de madeira e de plástico podem atuar absorvendo parte do impacto do material rodante, preservando-o (MONTEIRO, 2010). Os dormentes de concreto e de aço tendem a danificar mais o material rodante devido a sua característica de rigidez e, no caso do dormente de aço, propensão a criar superfícies altamente cortantes ou talhantes. Os dormentes podem ser considerados inaptos caso o desgaste mecânico for alto (nos dormentes de madeira, principalmente próximos aos *tirefonds* (tirefão) e parafusos que atravessam os dormentes de madeira) ou na presença de ataque de fungos e insetos e incêndios (BRINA, 1979). Na totalidade desses casos os defeitos podem ser visíveis na superfície exposta dos dormentes, serem internos ou estarem escondido pelo lastro.

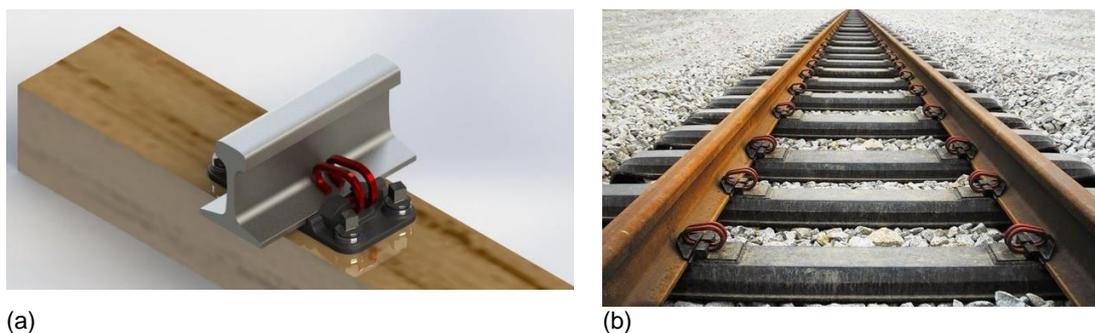
Os elementos de fixação atuam entre os trilhos e os dormentes, fixando-os uns aos outros. Os mais variados elementos de fixação podem ser utilizados, entre elásticos ou rígidos. Pregos e *tirefonds* são elementos rígidos que transferem quase todos os esforços dos trilhos para os dormentes e são aplicados furando os dormentes de madeira. Fixações elásticas, como grampos, absorvem parte dos esforços, transferindo apenas parte para os dormentes. Podem ainda ser empregadas placas de fixação e almofadas (*pads*) que possuem as funções de suportar as fixações rígidas ou elásticas ou de isolar eletricamente e mecanicamente o trilho do dormente (Figura 9 (b)). A Figura 8 apresenta alguns desses elementos de fixação. A Figura 9 (a) apresenta a fixação Deenik, sendo esta a fixação mais comum das imagens utilizadas neste trabalho.

Figura 8 – Várias representações de fixações



Fonte: Profillidis (2000)

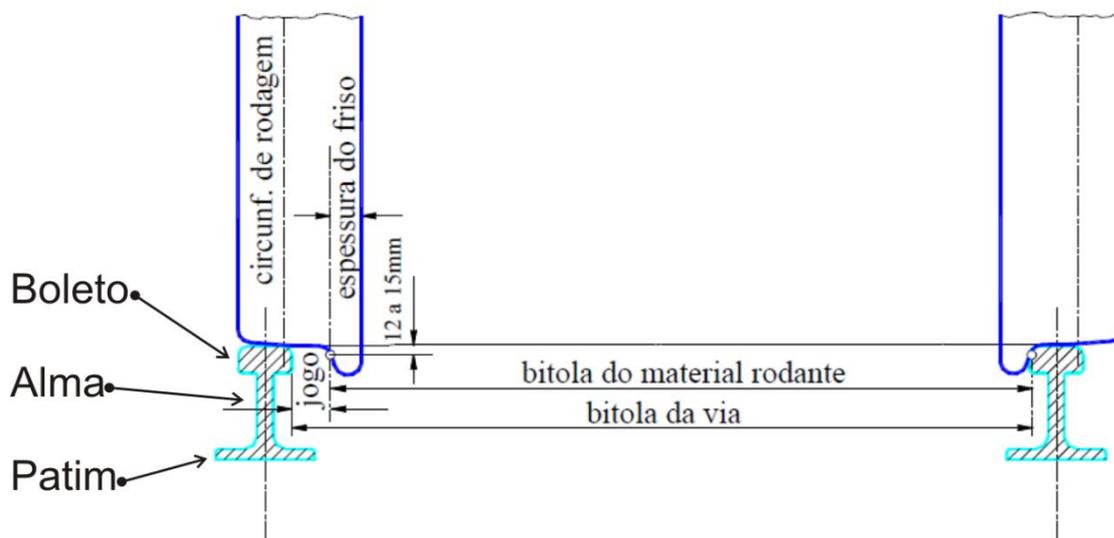
Figura 9 – Fixação do tipo Deenik



(a) Fixação do tipo Deenik (a) destacada em vermelho. Em preto, placa de apoio entre o dormente e o trilho. Em (b), almofada isolante entre o dormente de aço e o trilho, isolando eletricamente os elementos. Fonte: adaptado pelo autor.

Um tipo de trilho muito empregado em ferrovia é o Vignole que possui formato específico e três partes nomeadas: boleto (o material acumulado na parte superior do trilho), alma (parte central e alongada) e o patim (a base trapezoidal que se assenta diretamente sobre o dormente ou sob a placa de apoio). A distância entre as faces internas nos boletos dos dois trilhos é a medida de bitola, conforme Figura 10.

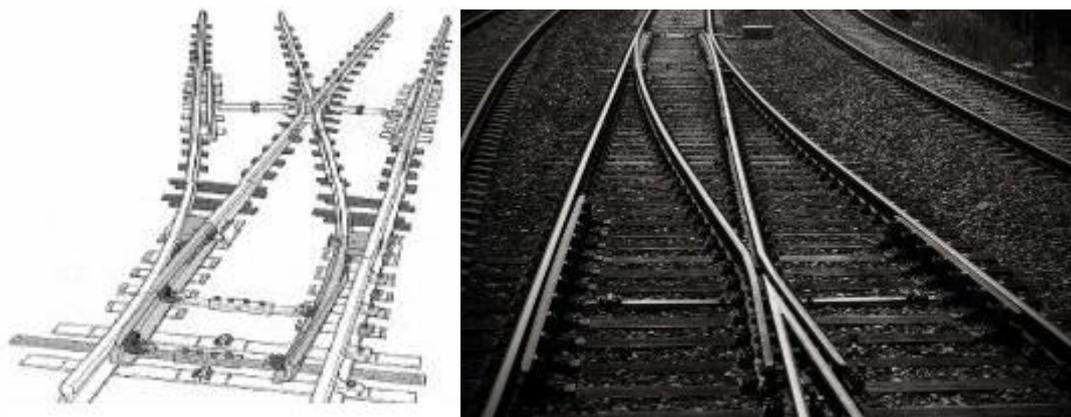
Figura 10 – Partes do trilho



As diferentes partes do trilho: boleto, alma e patim. A bitola da via, ou simplesmente bitola, é a medida entre as faces internas do boleto. A diferença entre bitola da via e a bitola do material rodante é a folga que permite os vagões e locomotivas circularem livremente e circunscreverem as curvas sobre a via. Fonte: ALL (2009).

O aparelho de mudança de via (AMV) é um conjunto de peças adjacentes a duas vias férreas que permite a mudança de uma via para outra (Figura 11). É composto de agulhas, contra-agulhas, chave-maromba ou máquina de chave, jacaré, calços, coxins, contra-trilhos e dormentes especiais. Quando a via é sinalizada, o AMV é operado pela máquina de chave, que remotamente é acionada para movimentar as agulhas e permitir a mudança de vias, fazer retornos, cruzar por linhas, enfim, todas as ações que o AMV permite.

Figura 11 – Aparelho de mudança de via (AMV)



Fonte: VALE (2011).

Nesta seção foram apresentadas alguns dos elementos que compõem a ferrovia. Para mantê-los em condições de utilização, várias técnicas de inspeção são aplicadas. Entretanto poucas delas são realizadas de forma automática. Mesmo nos casos em que a aquisição de dados para inspeção seja automática, normalmente a análise e classificação é feita manualmente por operários especializados. Assim é possível priorizar os trechos da ferrovia que sofrerão manutenção.

A próxima seção traz um compêndio de diferentes métodos e atividades de inspeção de ferrovias.

1.3 Inspeção da via permanente

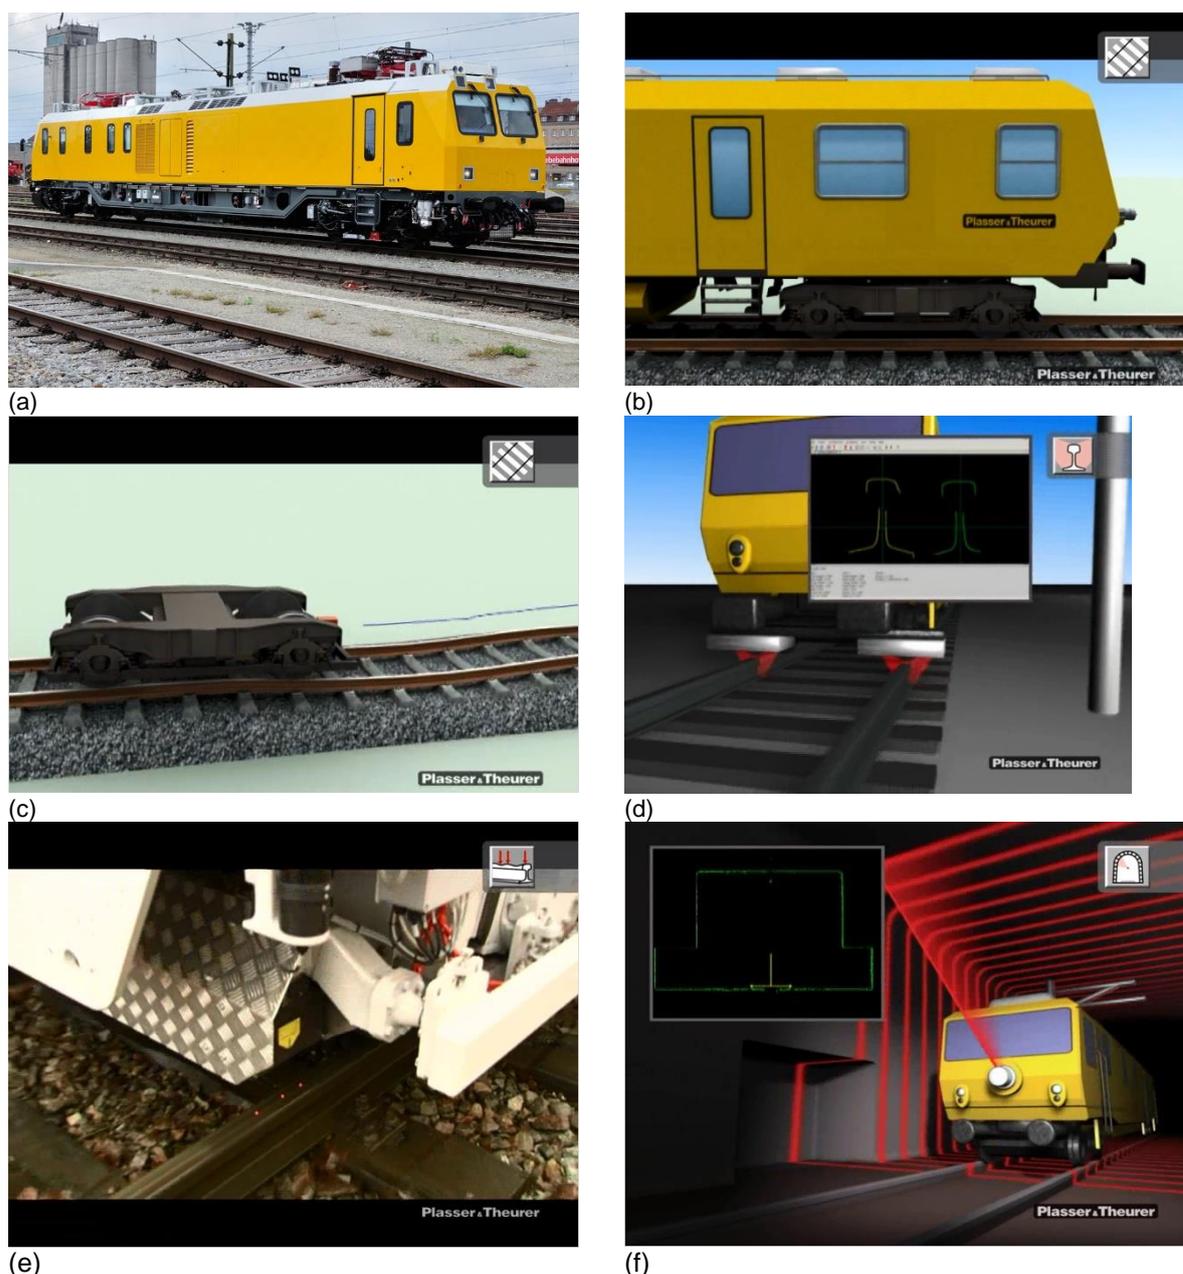
A condição dos elementos da via permanente pode causar restrições ou mesmo impedir uso de um trecho da ferrovia. Os motivos para tal podem ser inúmeros, como trilhos fraturados e tensionados, condições do lastro (limpeza e altura), condições dos dormentes (principalmente as condições físicas e o espaçamento) e o estado dos elementos de fixação (Soares, 2006).

As atividades de inspeção da via permanente competem ao inspetor de via permanente e têm como objetivo direcionar e priorizar as ações de gerenciamento de manutenção. As inspeções podem ser realizadas utilizando equipamentos apropriados como Carro Controle, Carro de Ultrassom, Auto de linha, Veículo rodoferroviário ou mesmo a pé, percorrendo trechos da via. E podem ser automáticas, semiautomáticas ou manuais. Quando as inspeções são realizadas manualmente diversos elementos da via são avaliados: trilhos (Inspeção visual), dormentes, lastro, AMVs e conjunto de fixação (VALE, 2011) em uma caminhada a pé acompanhando a ferrovia munido de algumas ferramentas a mão. Para avaliar o dormente, por exemplo, além da avaliação visual a procura de fraturas, quebras, ataques biológicos nos dormentes, o inspetor pode bater no dormente de madeira com o cabo de uma picareta de soca para ouvir o barulho que o dormente emite e avaliar o seu estado interno. Por outro lado, quando realizadas de forma automática ou semiautomática apenas aspectos específicos são avaliados, a depender dos sensores embarcados nos equipamentos. Algumas inspeções e equipamentos são apresentados a seguir.

O Carro controle é um veículo ferroviário, conforme a Figura 12, capaz de se auto propelir pela ferrovia tomando uma série de medidas. O Carro Controle possui, em geral, GPS para identificação das coordenadas geográficas do trecho, unidades

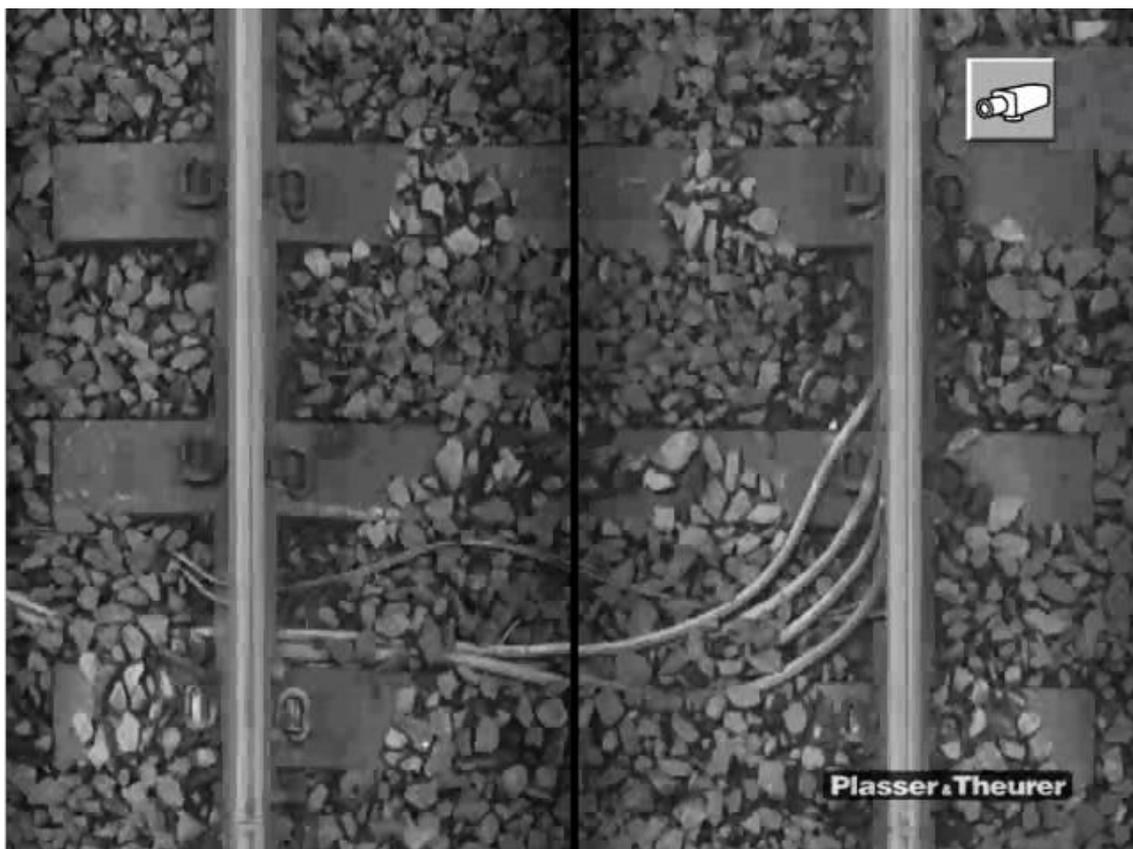
de medidas inerciais (IMU), sensores lasers e *encoders* para avaliação dinâmica da geometria da via e sob efeito de carga (bitola, superelevação, alinhamento, empeno, nivelamento, etc.), sensores de lasers para medição do perfil e desgaste dos trilhos e de corrugação (abaulamento e cavas) no topo do trilho, sistemas de câmeras para avaliar ausência ou problemas em fixações ou outros elementos da via (Figura 13), e sensores laser para avaliar gabarito da via, túneis, pontes e quantidade de lastro.

Figura 12 – Carro controle e exemplos de medições



(a) Exemplo de carro controle. (b) Medição de geometria da via (bitola, superelevação, inclinação). (c) Os sensores de geometria da via ficam instalados no truque do veículo. (d) Medição do perfil do trilho com laser (e) A corrugação é medida por três emissores de lasers alinhados no topo do trilho (f) Medição de gabarito de túnel com laser rotativo. Fonte: Auer (2013).

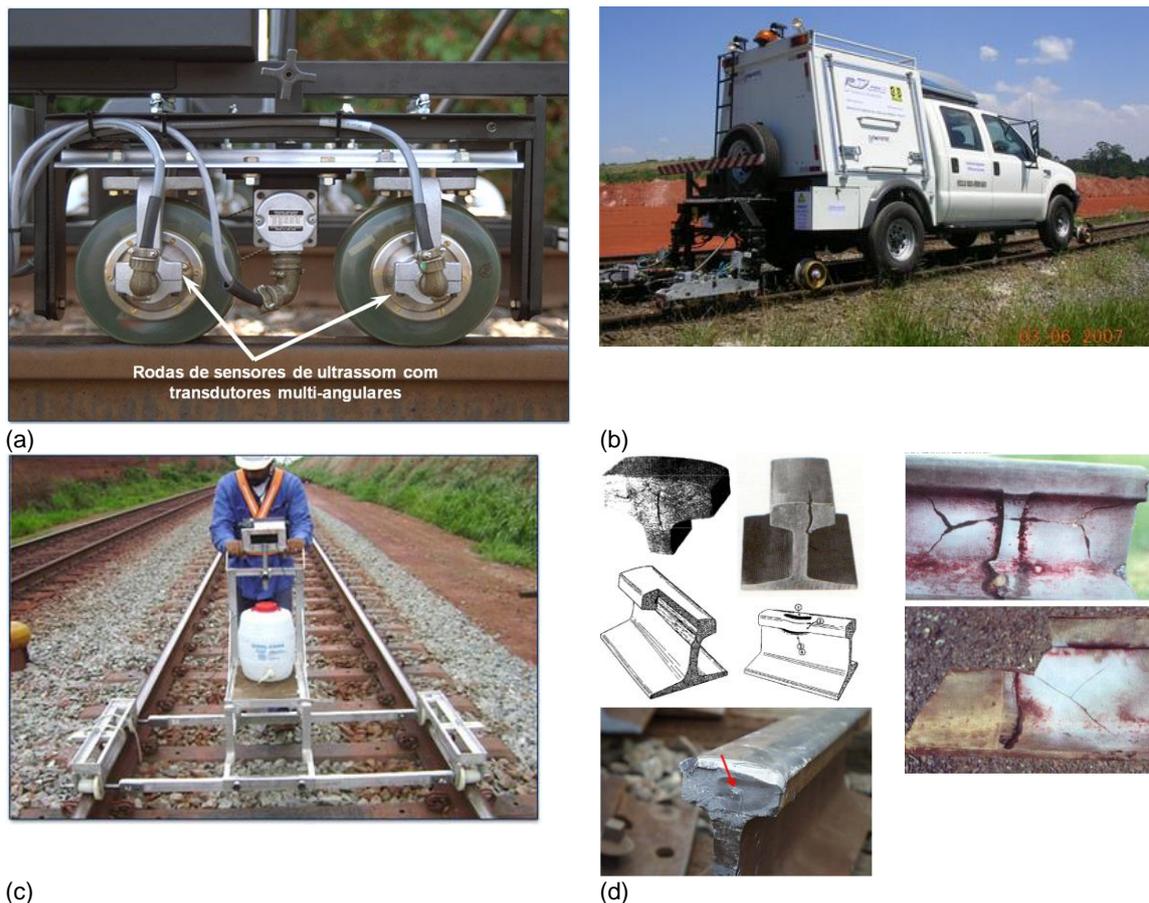
Figura 13 – Visão da câmera do carro controle



Sistema de câmeras filmam os trilhos, dormentes e elementos de fixação abaixo do veículo. Fonte: Auer (2013).

O Carro de Ultrassom é utilizado especificamente para avaliar defeitos superficiais e internos como trincas, fadiga e fratura dos trilhos. Há equipe própria e especializada para operar o Carro de Ultrassom. Geralmente é um auto de linha comum ou veículo rodoferroviário dotado de um sistema de ultrassom, conforme Figura 14. Podem ocorrer também na forma de equipamentos de medição que são empurrados manualmente pela via, nomeando-os ultrassom semiautomático.

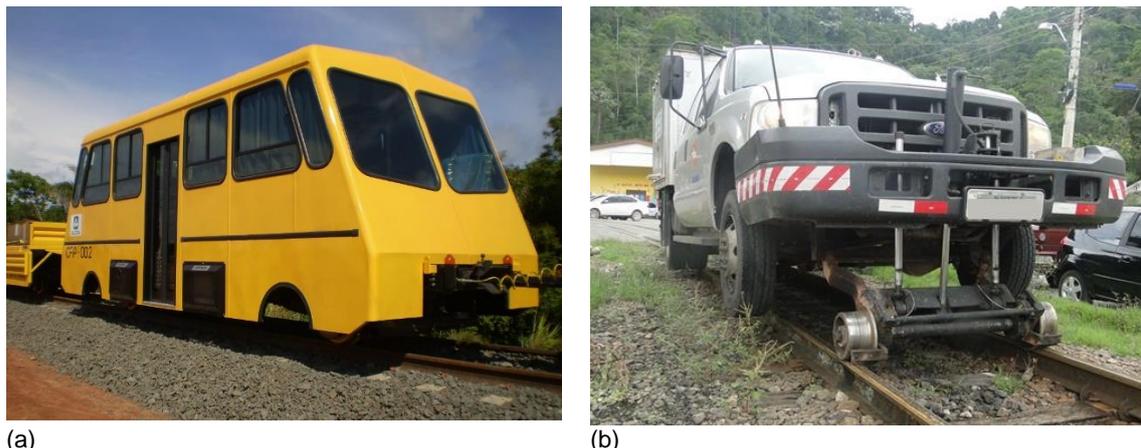
Figura 14 – Carro ultrassom



Detalhes do carro ultrassom: (a) Rodas do sistema de ultrassom com sensores de ultrassom. (b) Exemplo de sistema de ultrassom montado em um veículo rodoferroviário. (c) Exemplo de ultrassom semiautomático, onde o operador conduz o equipamento manualmente pela ferrovia. (d) Defeitos típicos encontrados pelo ultrassom: trincas, defeito de fabricação (inclusão não metálica/aço não limpo) e fratura de solda. Fonte: ALL (2009).

Auto de linha e veículo rodoferroviário são equipamentos habituais para deslocamento pela via (Figura 15). O primeiro apenas trafega na via enquanto o segundo pode trafegar tanto na via ferroviária como em rodovias. Eles permitem avaliar aspectos dinâmicos ao percorrer a via. Pode ser dotado de quase todos os sistemas de medição do carro controle ou pode contar apenas com a avaliação sensitiva dos passageiros que avaliam parâmetros pelo balanço do veículo ao trafegar ou pela identificação de algum aspecto anormal observado visualmente, por exemplo ausência de fixação e dormente, trilho fraturado, etc.

Figura 15 – Auto de linha e veículo rodoferroviário



(a) Veículos para deslocamento e inspeção. (a) Auto de linha e (b) Veículo rodoferroviário. Fonte: adaptado pelo autor.

Para a inspeção de trilhos, lastro e AMVs há parâmetros bem determinados em termos de valores aceitáveis para identificar a qualidade desses itens, conforme Brina (1979), Profillidis (2000), ALL (2009) e VALE (2011). Os trilhos e os AMVs possuem parâmetros especificados de dimensões, peso, rigidez, elasticidade, etc. O lastro possui aspectos definidos de dimensões, rugosidade, lixividade, abrasão, elasticidade, etc. No entanto, para a avaliação da qualidade dos dormentes, principalmente de madeira, o julgamento pode ser subjetivo para algumas características. As normas internas dos operadores ferroviários e os cursos de formação de pessoal especializado em manutenção ferroviária apenas especificam que os dormentes devem manter as capacidades de sustentação da ferrovia, sem determinar parâmetros objetivos a serem observados.

Os dormentes podem ser avaliados conforme a aparência visual externa, se apresentam fungos e insetos, se há rachaduras ou fraturas no dormente que comprometam a integridade; se a placa de fixação, parafusos e *tirefonds* estão soltos ou mal fixados, se os dormentes estão empenados, se estão ausentes ou mesmo se o barulho que emitem ao serem golpeados é incomum, indicando comprometimento do cerne do dormente de madeira. Os parâmetros mais afetados pela subjetividade são os que tratam da aparência externa (rachaduras nos dormentes de madeiras podem ser confundidos com os nós naturais da madeira ou mesmo não interferir na integridade física do dormente) e o teste do som produzido ao golpear o dormente para validar o conteúdo sadio.

Estas avaliações subjetivas são orientações encontradas nas empresas e no meio acadêmico para inspecionar os dormentes. Apesar disso, normas regulamentam os dormentes quanto aos parâmetros de defeitos aceitáveis em dormentes de madeira novos, não para dormentes em uso. Algumas normas ((ABNT 2013) e (DNIT, 2016)) definem parâmetros máximos de arqueamento, encurvamento, desquinado, saliência, fendilhamento nos topos, rachadura fora do topo, nós sadios, nós mortos, percentual de alburno e diferença de altura nas faces. Os itens mais interessantes para a inspeção visual da superfície dos dormentes são rachaduras fora do topo do dormente (faces menores), que devem ter comprimento máximo de 15 cm e abertura máxima de 2 cm e fora da zona de fixação; nós vivos, que não devem estar presentes na zona de fixação do trilho; e as dimensões dos nós mortos, que devem ser menores que 2 cm de diâmetro, menores que 5 cm de profundidade e a soma dos diâmetros de todos os nós deve ser inferior a 5 cm, além de não estarem presentes na região de fixação dos trilhos. Dormentes de aço e concreto não podem apresentar falhas construtivas e de geometria. Estes são parâmetros para o recebimento de dormentes novos. Estas normas não estabelecem parâmetros para a inspeção de dormentes em uso.

A AREMA (*American Railway Engineering and Maintenance-of-Way Association*), define em seu manual de boas práticas (AREMA, 2009) parâmetros para as fendas em dormentes de madeira: a largura não pode ser maior que 1/8" (3 mm) e/ou o comprimento deve ser menor que 4" (10 cm), para dormentes não tratados; e para dormentes tratados, a largura deve ser menor que 1/4" (6 mm) e/ou o comprimento menor que a largura da face que apresenta a fenda.

1.3.1 *Inspeção automática de ferrovias*

O monitoramento da condição da via permanente, em particular as condições dos dormentes, é oferecido como produto comercial por grandes fabricantes de equipamentos de monitoramento de manutenção ferroviária, como a Plasser e Theurer (AUER, 2013) e a RailVision (RAIL VISION EUROPE LTD, 201-?). Não há informação disponível e pública sobre o desempenho de plataformas comerciais quanto à avaliação da qualidade de dormentes. Portanto é dificultada a validação e a comparação de desempenho com outros métodos. Além disso, dado ao alto custo de aquisição do módulo de inspeção visual de elementos da via permanente, algumas ferrovias optam por não o adquirir, em detrimento do investimento em outros módulos,

como o módulo de medição de geometria da via e de inspeção de trilhos, mais críticos operacionalmente. Isto impulsiona a pesquisa e o desenvolvimento de soluções próprias em parceria com instituições de pesquisa.

Esta demanda por pesquisa acadêmica é recorrente de tal forma que se nota uma série de publicações objetivando a inspeção de elementos da via permanente utilizando técnicas de visão computacional, processamento de imagens e reconhecimento de padrões. Por exemplo, o projeto desenvolvido pelo laboratório de visão computacional da *University of Central Florida* em parceria com a *Florida Department of Transportation* (Shah, 2010) propôs e desenvolveu uma série de equipamentos para detectar defeitos e realizar medidas da via permanente, como tamanho de bitolas (distância entre trilhos), corrugação em trilho, fratura em trilho, ausência de fixação, entre outros usando diferentes técnicas de processamento de imagens e visão computacional. A solução de medição de bitola, com uso de laser, apresentou ótimo desempenho, no entanto as demais medidas, geralmente baseadas em visão computacional, apresentaram bom desempenho em ambientes controlados, com difícil implementação em ambiente operacional real.

Rubinsztein (2011) propõe em sua dissertação de mestrado o uso de reconhecimento de padrões usando o algoritmo de Viola-Jones (VIOLA; JONES, 2004) para identificação e localização de elementos de interesse na via. Neste trabalho os elementos de interesse procurados são os elementos de fixação. Não se preocupando com a identificação do tipo de elemento de fixação, apenas procurando localizá-lo, os resultados foram bem positivos: taxa de acerto de verdadeiro positivo de 98,5% e de falso positivo de 0,0000023%.

Em outra dissertação, Babenko (2009) propõe dois métodos para medir bitola da via, um usando apenas laser e outro usando apenas câmera de vídeo, e um terceiro método para identificar elementos de fixação e placas de apoio, detectando ausência ou defeito nesses elementos. A novidade neste trabalho é a classificação dos diferentes tipos de elementos de fixação (usando *MACH Filter*) e o uso de GPU (unidade de processamento gráfico dedicado), que torna a execução dos algoritmos mais rápida em 600 vezes se comparada à implementação em linguagem C e 8.000 vezes mais rápida se comparada a implementação no *software* Matlab.

Gibert, Patel e Chellappa (2015) propõem avaliar elementos de fixação em uma ferrovia americana com dormentes de concreto. Os autores qualificam os elementos em ausentes, quebrados e em bom estado. Os elementos em bom estado são ainda

classificados em 5 tipos diferentes de fixações. Usavam-se características extraídas com HOG (*Histogram of oriented gradients*) e uma combinação de classificadores SVM (*Support vector machine*). Alcançou-se 98% de acerto nas avaliações de qualificação (fixações ausentes e quebradas) e 1,28% de falso positivo (falso alarme). As avaliações foram feitas em 85 milhas de ferrovia, que correspondia 203.287 dormentes. Os autores afirmam ser o maior conjunto de dados de dormentes na literatura, até então. Destes, 2.524 dormentes estavam não-inspecionáveis (cobertos pelo lastro ou outras estruturas ou AMVs) e não foram retirados dos testes. Isto corrobora com o compromisso de retratar as dificuldades de tratar automaticamente dados reais da operação ferroviária (ambientes expostos a ruído, sujeira, dificuldades de iluminação e ambiente não controlado). O número de fixações defeituosas é apenas 0,13% do total do conjunto de dados. Este desbalanceamento entre as classes pode trazer dificuldades na comparação de desempenho do algoritmo, conforme será apresentado nos demais capítulos. A fim de comparar o desempenho do algoritmo proposto com outros métodos, os autores deste trabalho (Gibert, Patel e Chellappa) afirmaram que aplicaram o algoritmo de Babenko (2009) sobre o seu banco de dados e obtiveram resultado ligeiramente inferior para este algoritmo: 94,8% de acurácia.

Há alguns trabalhos que se propõem a avaliar as condições dos dormentes. Mohammad (2008), por exemplo, avaliou aspectos morfológicos da imagem dos dormentes como presença de rachaduras e o respectivo tamanho e forma para classificar os dormentes em bons ou ruins. Por sua vez, Yella et al. (2008) avaliaram a qualidade de 200 dormentes extraindo características de imagens dos dormentes assentados na via e uma estratégia de fusão de diferentes classificadores supervisionados (*Multi-layer Perceptron*, *Radial basis Function Neural Network* e *Support Vector Machine*). Já Yella, Gupta e Dougherty (2007) apresentaram um ensaio de impacto acústico para extrair características usando um microfone e um gravador eletrônico. Este método em particular tenta reproduzir a avaliação que o inspetor da via permanente utiliza ao golpear o dormente com uma ferramenta e avaliar o som resultante. Esta é a avaliação utilizada quando o dormente não apresenta aspectos visíveis que comprometam sua qualidade. No entanto, em artigo posterior, Yella, Rahman e Dougherty (2010) avaliaram que a fusão dos dois métodos propostos, processamento das imagens dos dormentes e ensaio de impacto acústico não aumentou o desempenho de forma considerável, devendo atuar, portanto como avaliações complementares.

Outros autores propõem descobrir danos em dormentes ou no lastro avaliando a resposta da ferrovia a uma vibração induzida. Plenge e Lammering (2003) submeteram um segmento de ferrovia montado em laboratório à diversas frequências de vibração e perceberam que os dormentes foram bastante receptivos à frequência de 150 Hz. Essa frequência específica estava relacionada às características mecânicas do segmento (e comprovadas pelo modelo numérico). Variando algumas dessas características, a frequência de melhor receptividade para os dormentes variava. Portanto a determinação dessa frequência dependeria das condições da via. A dificuldade seria definir as frequências em uma situação real.

Lam, Hu e Wong (2014) propõem avaliar a resposta de um segmento real de ferrovia de dormentes de concreto, montada em laboratório, submetido ao impacto de um martelo instrumentado. A metodologia primeiro determina o modelo Bayesiano mais provável dentro de uma lista de candidatos pré-definidos baseado em um conjunto de medidas. Depois de definido o modelo, uma função de densidade de probabilidade (PDF) é definida e o comportamento ao impacto é estimado. O resultado desse impacto é avaliado por 20 segundos em cada dormente sensoriado, procurando identificar comportamentos que diferem dos modelos determinados, a fim de identificar regiões que apresentam o suporte do lastro danificado.

Wang, Zhang e Lie (2017) propõem induzir uma frequência na ferrovia que possui adjacente uma massa vibrante auxiliar em um ponto específico. Medidas da resposta de vibração são tomadas em vários dormentes e nesta massa vibrante auxiliar. Essas respostas seriam suficientes para determinar as características para modelagem do sistema. Os modelos teóricos de suporte da ferrovia para fixações, dormentes e lastro foram transformados em modelos reais em escala reduzida para teste experimental. Os testes experimentais permitiram identificar de forma diferenciada problemas como fixação ausente, lastro danificado, dormente laqueado (dormente suspenso) e a situação ideal de sustentação. Apesar dos resultados terem sido conduzidos apenas para os testes em escala reduzida, há muita expectativa de que os testes em campo reproduzam esses resultados em vista do que foi apresentado pelos artigos anteriores. Esse método é mais prático pois não é preciso determinar a priori informações de estruturas danificadas (este é objetivo do modelo) ou parâmetros de modelos de elementos finitos que representem a ferrovia.

Nota-se, então, uma grande variedade de técnicas e resultados, porém ainda permanece o desafio de se associar, a partir de novas técnicas, a contribuição

científica existente à situação real que a operação ferroviária impõe. Em uníssono, muitos dos autores apresentam que há muitos estudos para avaliar os defeitos e o comportamento dos trilhos e do lastro, mas há poucos trabalhos avaliando dormentes.

Apesar de representar um trabalho essencialmente de engenharia, monitorar e identificar a condição dos dormentes de uma ferrovia também é, em sua essência, um trabalho de reconhecimento de padrões e classificação. Portanto, apresenta potencial para geração de trabalhos acadêmicos quando envolve o emprego de técnicas de processamento de imagens, métodos de classificação e fusão de características para atingir o seu objetivo.

A contribuição científica deste trabalho, então, poderá ser alcançada no desenvolvimento de um novo método a ser aplicado assim como na comparação dos resultados com outros trabalhos publicados na área. Junte-se a isso, a avaliação dos resultados obtidos com sua aplicação em um ambiente ferroviário real.

1.4 Objetivo da Dissertação

Diante da importância da ferrovia e da dificuldade e subjetividade que é realizar a inspeção de dormentes, a proposta geral deste trabalho é realizar a tarefa de inspeção automática de dormentes utilizando técnicas de processamento de imagens, reconhecimento de padrões, fusão de características e heurísticas. Para tanto serão utilizadas imagens da ferrovia coletadas por veículos ferroviários.

A forma das amostras de dados disponíveis influencia bastante na forma da solução que será implementada. Como o recurso humano de inspeção de ferrovias é limitado, o conjunto de dados coletados não será pré-classificado. Não serão indicados por um especialista, previamente nas imagens, onde estão os dormentes, que tipo de dormente está presente e se existe algum defeito nos dormentes. Esta é uma avaliação de custo muito alto para a quantidade de imagens que se pretende utilizar. Portanto a solução a ser proposta deverá ser uma solução não supervisionada em termos de classificação.

Além disso, como o ambiente da aplicação é um ambiente não controlado, externo, influenciado pelas variações de iluminação e aleatoriedade do que poderá estar presente na imagem (além dos elementos da ferrovia, poderá haver vegetação, sujeira, terra, objetos descartados como latas e pedaços de madeira, etc.) teme-se

que a quantidade de imagens coletadas não seja suficiente para propor uma abordagem de aprendizagem de máquinas.

Os objetivos específicos são:

1. Contabilizar e inventariar os tipos de dormentes presentes em cada trecho ferroviário;
2. Identificar a condição dos dormentes nos trechos analisados;
3. Gerar um relatório com as informações pertinentes para atuação da manutenção da via permanente.

A solução foi implementada considerando heurísticas, fusão de características, reconhecimento de padrões e bordas. Primeiro identifica-se a posição dos trilhos na imagem, em seguida, por várias técnicas diferentes e independentes reconhecem-se características que indicam candidatos a dormentes. Faz-se a fusão desses candidatos de forma a alcançar a melhor posição dos dormentes, inclusive com a indicação de dormente não visível (visão obstruída) onde esperava-se encontrar algum. Determina-se o tipo de dormente pela avaliação de textura de sua superfície exposta e pela classificação dos demais dormentes na imagem. Por fim, a avaliação de defeitos nos dormentes é feita pela procura de características dos defeitos mais comuns.

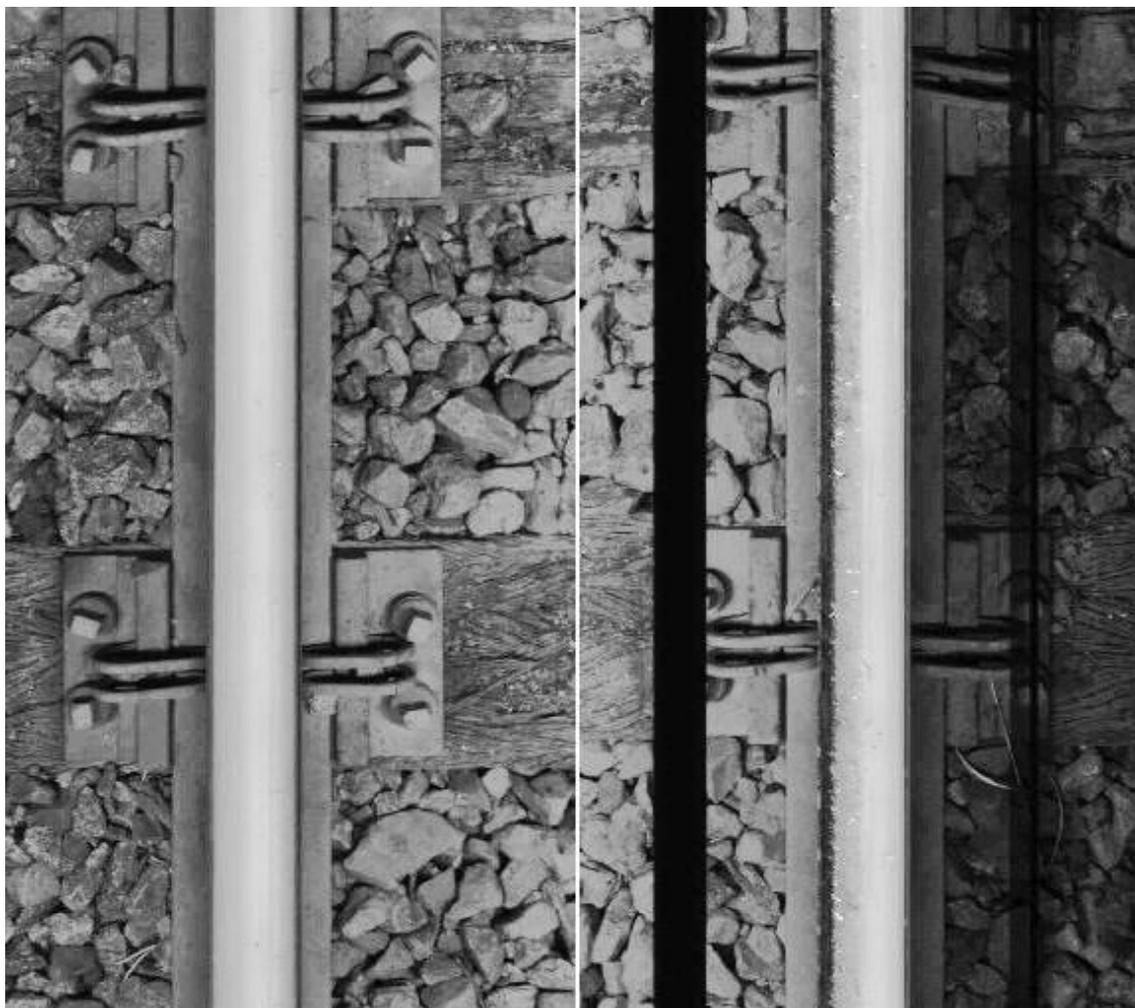
A estrutura desta dissertação será definida pelas seguintes seções:

- Desenvolvimento: seção com as características das imagens disponíveis, o racional sobre cada etapa do algoritmo, as técnicas combinadas que geraram cada etapa do algoritmo e algumas implementações que não alcançaram bons resultados e os motivos para tal;
- Desempenho e resultados: caracterização dos dados disponíveis, métricas de desempenho e resultados alcançados;
- Conclusão: síntese dos objetivos e resultados, implementações a desenvolver e trabalhos futuros e considerações finais.

2. DESENVOLVIMENTO

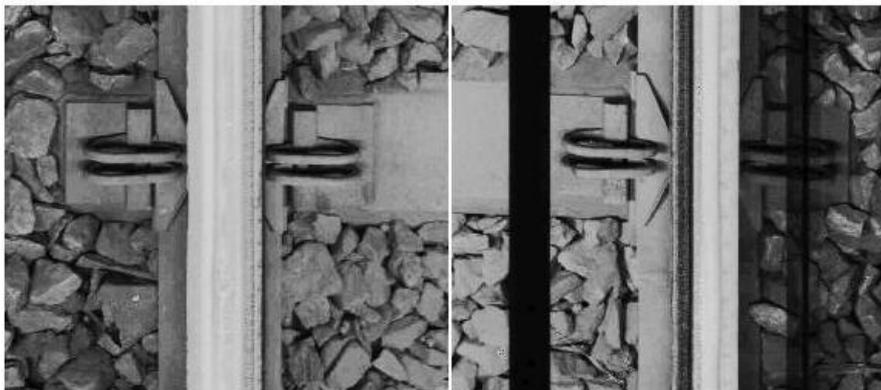
Neste capítulo serão apresentados os aspectos das imagens disponíveis no banco de dados, o esquema geral do algoritmo proposto e o desenvolvimento de cada etapa do algoritmo. Foram utilizadas imagens capturadas a partir de um veículo ferroviário com um sistema de câmeras e iluminação apontadas para a superfície superior dos trilhos. Os bancos de imagens são compostos de 32.917 imagens reais em formato *jpg* com visão parcial dos dormentes que podem ser de madeira ou de aço com tamanhos de imagens que variam de 256, 512 e 1.204 *pixels* de altura por 576 *pixels* de largura. Estas imagens geralmente possuem, respectivamente 1, 2 ou 4 dormentes. Alguns exemplos das imagens que serão utilizadas para reconhecimento dos dormentes estão apresentados nas Figura 16 e Figura 17.

Figura 16 – Exemplo de imagem utilizada para detecção de dormente de madeira



Fonte: adaptado pelo autor.

Figura 17 – Exemplo de imagem utilizada para detecção de dormente de aço



Fonte: adaptado pelo autor.

Nas imagens é possível observar:

1. Os trilhos. São as estruturas que percorrem a imagem no sentido vertical e sempre estarão presentes e visíveis em qualquer imagem. Na imagem é possível ver o boleto (parte superior do trilho) e parte do patim (parte inferior do trilho). Eventualmente o patim pode estar ocluído com outras estruturas como lastro, placas de fixação ou outros elementos;
2. Grampos de fixação. São estruturas elásticas que fixam o patim do trilho (base) às placas de fixação (solidárias aos dormentes). Podem estar ausentes ou ocluídas por outros elementos;
3. Placas de apoio ou placas de fixação. São estruturas chatas, como placas, que acomodam os grampos, e os tensionam contra a base do trilho. Geralmente estão ligadas aos dormentes de madeira por *tirefonds* (parafusos) e nos dormentes de aço fazem parte da própria estrutura do dormente;
4. Dormentes. São estruturas dispostas horizontalmente. Na Figura 16 estão exemplificados dormentes de madeira e na Figura 17 estão apresentados dormentes de aço;
5. Lastro. Material granular responsável por distribuir o peso e os esforços dos dormentes para o sublastro e o terreno. Geralmente formado por brita de granulometria controlada;

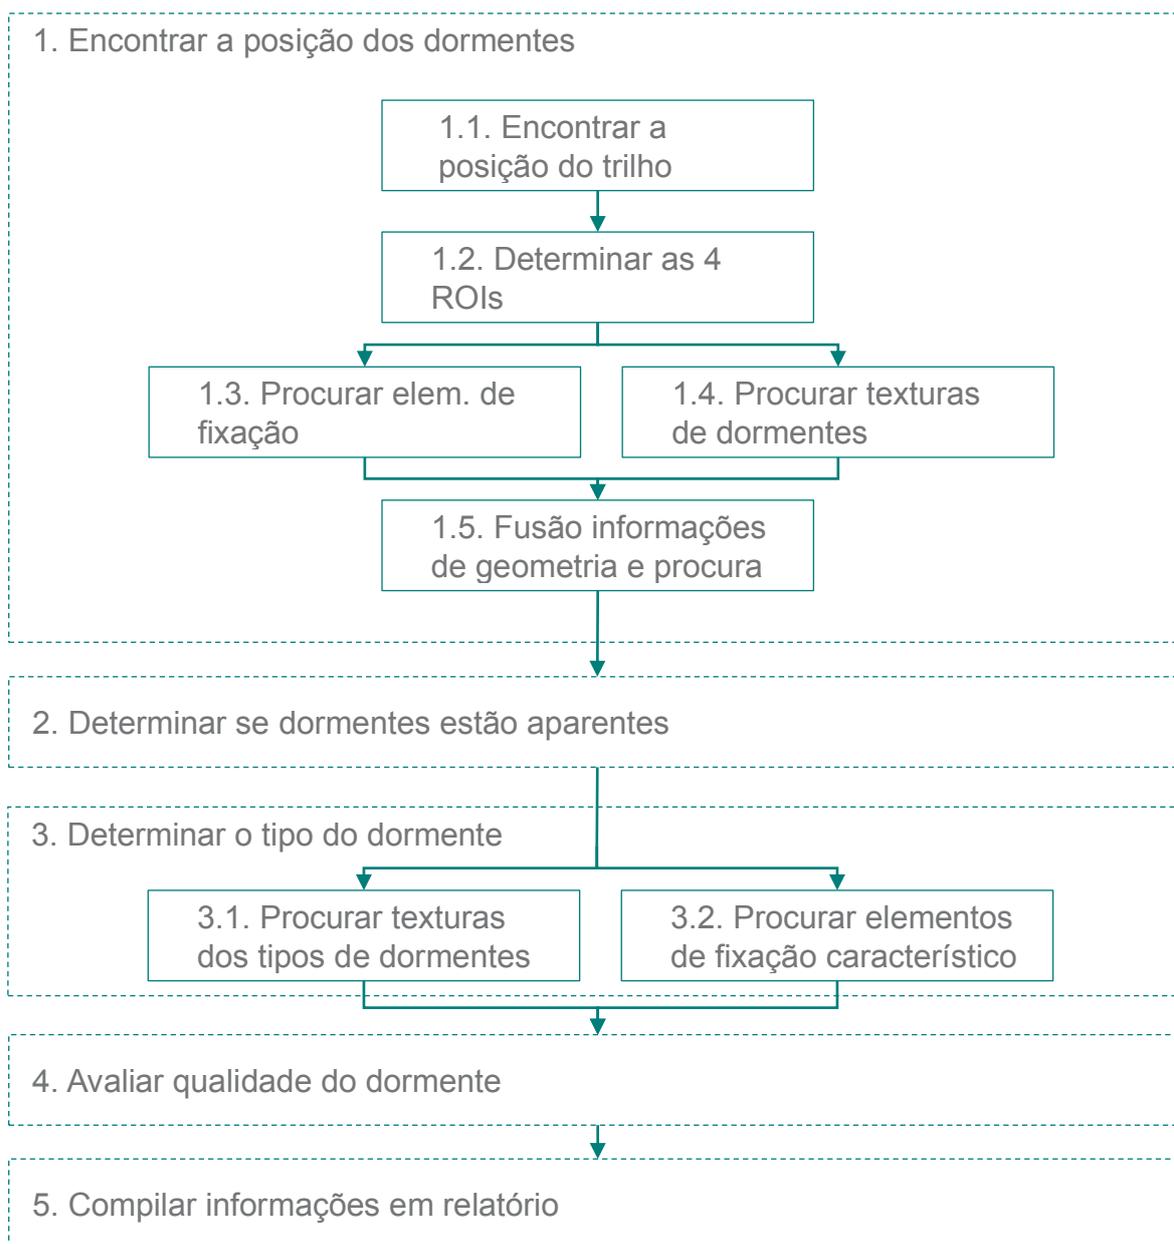
6. Outros elementos podem aparecer nas imagens como talas de junção, partes de aparelhos de mudança de via (jacaré, agulha, contratrilho, etc.);
7. Linha branca no meio da imagem, no sentido vertical. Apenas a região da fixação é observada nas imagens, portanto parte da região central dos dormentes e as extremidades não são observadas nas imagens;
8. Linhas pretas, no sentido vertical. Estas linhas são defeitos nos sensores de uma das câmeras. Este defeito é recorrente em todas as imagens e causam uma região contida e escura;
9. Os dormentes à direita e à esquerda na imagem podem estar levemente defasados no sentido vertical. Estes dormentes compõem a mesma estrutura retilínea e linear e, portanto, é esperado que estivessem alinhados. No entanto isso não ocorre por dois motivos: o primeiro, por causa das curvas do traçado ferroviário e por causa do movimento do rodeiro do veículo ferroviário ao circunscrever a grade ferroviária, a posição relativa do dormente não é totalmente horizontal. Assim sendo, como a parte central do dormente foi suprimida da imagem, não há encaixe perfeito das duas metades dos dormentes; o segundo motivo é que o instante de aquisição das câmeras de cada um dos lados da imagem não é o mesmo;
10. Os dormentes, considerando uma margem apreciável de erro, estão espaçados entre si de uma distância uniforme. Essa distância compõe alguns dos valores de topologia considerados no algoritmo.

Com base nessas observações é possível determinar um algoritmo para identificar a posição dos dormentes na imagem. Com mais algumas etapas e de posse da posição dos dormentes é possível avaliar se o dormente está aparente (não ocluso) e determinar o tipo do dormente. Por fim é possível determinar a qualidade do dormente. O algoritmo simplificado é apresentado na Figura 18 e cada etapa será explicada em seguida:

1. Encontrar a posição dos dormentes;
 - 1.1. Encontrar a posição horizontal dos trilhos da imagem;
 - 1.2. Determinar as quatro regiões de interesse (ROIs, do inglês *regions of interest*) para a procura dos dormentes visíveis: região à esquerda e à direita do trilho esquerdo e região à esquerda e à direita do trilho direito;

- 1.3. Procurar pelas fixações comuns à ferrovia nas ROIs. A posição dos elementos de fixação, quando visíveis, são um bom indicativo da posição dos dormentes;
- 1.4. Procurar pelas texturas dos dormentes visíveis nas ROIs;
- 1.5. Compilar e fundir as respostas destas procuras com outras informações de geometria e topologia da via férrea para determinar a região mais provável dos dormentes, estejam eles visíveis ou não;
2. De posse da posição dos dormentes, determinar se está aparente ou não, procurando por características esperadas para as texturas dos dormentes;
3. Determinar o tipo de dormente;
 - 3.1. Procurar por características de cada uma das texturas dos dormentes;
 - 3.2. Procurar por características específicas das placas de apoio de cada um dos tipos de dormentes;
4. Avaliar qualidade aparente do dormente, quando visível;
5. Compilar essas informações em relatório detalhado contendo o tipo de dormente encontrado, a presença ou não de defeitos e sua quantificação, a imagem a que se refere e demais informações pertinentes.

Figura 18 – Estrutura do algoritmo (diagrama)



Fonte: elaborado pelo autor.

A seguir será discutida detalhadamente cada uma dessas etapas, apresentando as dificuldades, as ideias que não foram bem-sucedidas e as soluções empregadas.

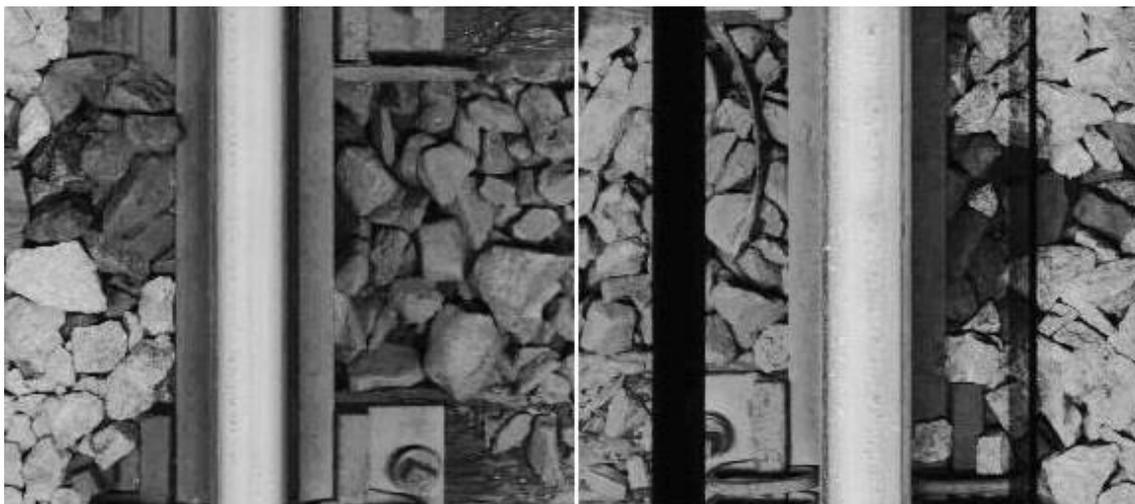
2.1 Encontrando a posição dos dormentes

2.1.1 *Encontrando os trilhos na imagem*

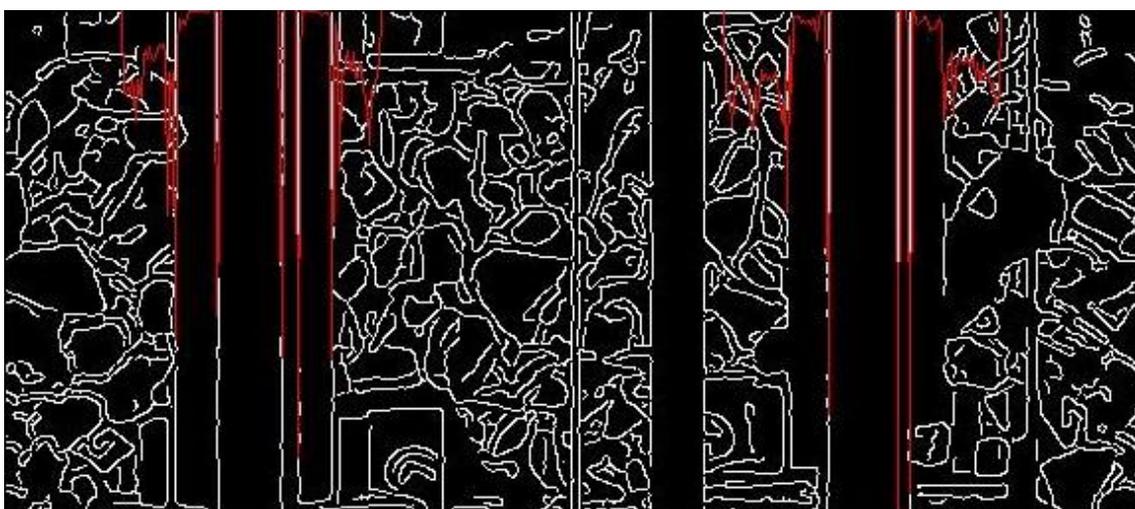
Descobrir a posição dos trilhos na imagem é o primeiro passo para encontrar os dormentes. Sua posição define quatro regiões de interesse (ROIs) onde podem se encontrar as superfícies visíveis dos dormentes: à esquerda e à direita do trilho esquerdo e à esquerda e à direita do trilho direito. As superfícies superiores dos trilhos (boleto) estão sempre presentes na imagem. Percorrem verticalmente (longitudinalmente) toda a imagem e se apresentam como retângulos mais claros que a vizinhança. No entanto sua posição horizontal varia de acordo com as curvas de via férrea ou de acordo com o movimento que o rodeiro faz ao circunscrever a face interna do boleto. Por isso a posição do trilho varia em cada imagem e com isso variam as posições e os tamanhos das ROIs em cada imagem.

Diversas técnicas foram testadas para encontrar a posição dos trilhos na imagem. Entre elas, estão testes com filtros de contornos de Canny, Sobel e outros, pois é esperado que a borda do trilho esteja essencialmente no sentido vertical. No entanto, a aplicação dessas técnicas gerava muitos candidatos a borda do trilho (borda do boleto do trilho), principalmente pela característica aleatória do lastro e dos demais objetos que apareciam na imagem, como placas de apoio e vegetação. Mesmo usando filtro Gaussiano ou filtro bilateral como pré-filtragem da imagem para eliminar alguns destes candidatos não se obteve uma resposta satisfatória. As imagens da Figura 19, Figura 20 e Figura 21 apresentam algumas dessas respostas. A Figura 19 apresenta a tentativa de procura sobre uma imagem sem pré-filtragem. A Figura 20 apresenta a tentativa sobre a mesma imagem da Figura 19, no entanto, pré-filtrada com o filtro Gaussiano e a Figura 21, pré-filtrada com o filtro Bilateral. As marcações em vermelho representam os vários candidatos a lateral do trilho. Quanto mais embaixo da imagem se encontra o candidato (maior dimensão), maior a probabilidade de indicar a lateral do trilho. Note que há muitos candidatos com probabilidades próximas e por vezes o patim (e não o boleto) era indicado como lateral superior do trilho.

Figura 19 – Tentativa de procurar os trilhos com filtro de borda (imagem original)



(a)



(b)



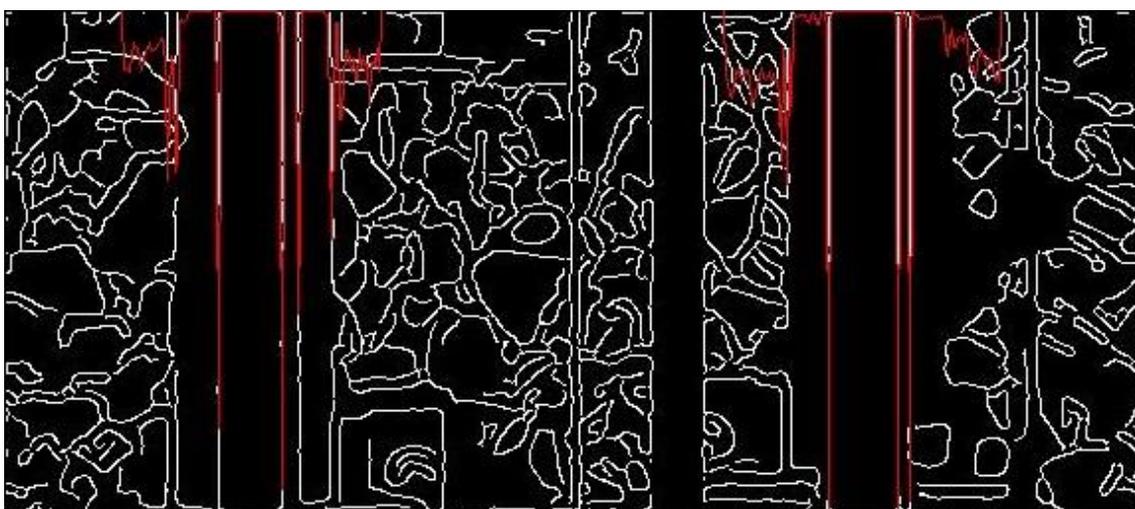
(c)

Procura do trilho usando filtros de borda geravam inúmeros candidatos que poderiam gerar conclusões erradas sobre a borda correta do trilho (linhas vermelhas). (a) Um exemplo de imagem sem filtragem. Aplicação do filtro Canny (b) e filtro Sobel Vertical (c) sobre essa imagem. Fonte: elaborado pelo autor.

Figura 20 – Tentativa de procurar os trilhos com filtro de borda (filtro Gaussiano)



(a)



(b)



(c)

Procura do trilho usando filtros de borda geravam inúmeros candidatos que poderiam gerar conclusões erradas sobre a borda correta do trilho (linhas vermelhas). (a) A mesma imagem da figura anterior com pré-filtragem usando um filtro Gaussiano. Aplicação do filtro Canny (b) e filtro Sobel Vertical (c) sobre essa imagem. Fonte: elaborado pelo autor.

Figura 21 – Tentativa de procurar os trilhos com filtro de borda (filtro Bilateral)



(a)



(b)



(c)

A imagem com pré-filtragem usando um filtro Bilateral (a). Aplicação do filtro Canny (b) e filtro Sobel Vertical (c) sobre essa imagem. Nota-se que há alguns candidatos (linhas vermelhas) com dimensões semelhantes, erroneamente indicando a borda lateral do boleto do trilho. Fonte: elaborado pelo autor.

Também foram implementadas soluções usando a transformada de Hough (GONZALEZ; WOODS, 2007), mas dado o tempo de processamento e a quantidade imensa de candidatos, a solução não era razoável. Como o tempo de processamento é uma condição importante a ser observada, tentou-se implementar soluções rápidas e de baixo custo computacional, apoiando-se principalmente em filtros de resposta rápida.

Por fim, buscando uma solução de resposta rápida e usando operações elementares de soma, foi proposta uma combinação entre o valor dos *pixels* acumulados verticalmente e a sua variância. Tome um vetor de mesmo tamanho da largura da imagem que receba a soma de todos os *pixels* das colunas. Os maiores valores desses vetores podem estar localizados na mesma posição da superfície do boleto, geralmente a região mais clara da imagem de cima a baixo. Tome um outro vetor de mesma largura que a imagem, entretanto que contenha a variância do valor dos *pixels* ao longo das colunas da imagem. Subtraia de cada elemento deste vetor o maior valor de variância observado e tome o seu valor absoluto. Os maiores valores deste vetor indicam regiões com maior constância de intensidade. Como o trilho se dispõem verticalmente ao longo da imagem e sua superfície é uniforme, as intensidades de seus *pixels* é bem constante. Então o produto elemento a elemento do primeiro vetor e do último pode indicar superfície do boleto do trilho. Essa explicação está representada pelas equações seguintes, onde o primeiro vetor é expresso pela Equação (1), que contém a soma das intensidades dos *pixels*. O segundo vetor é indicado pela Equação (2), com a variância dos *pixels*. Por fim a combinação dos dois vetores é indicado pela Equação (3) e que corresponde a linha vermelha na Figura 22:

$$Soma(j) = \sum_{i=1}^w I(i, j) \quad (1)$$

$$Variância(j) = \sum_{i=1}^w Var(I(i, j)) \quad (2)$$

$$LinhaVerme\ lha(j) = Soma(j) \cdot |(Variância(j)) - Máximo(Variância(j))| \quad (3)$$

Onde

I: Matriz de instensidades da imagem

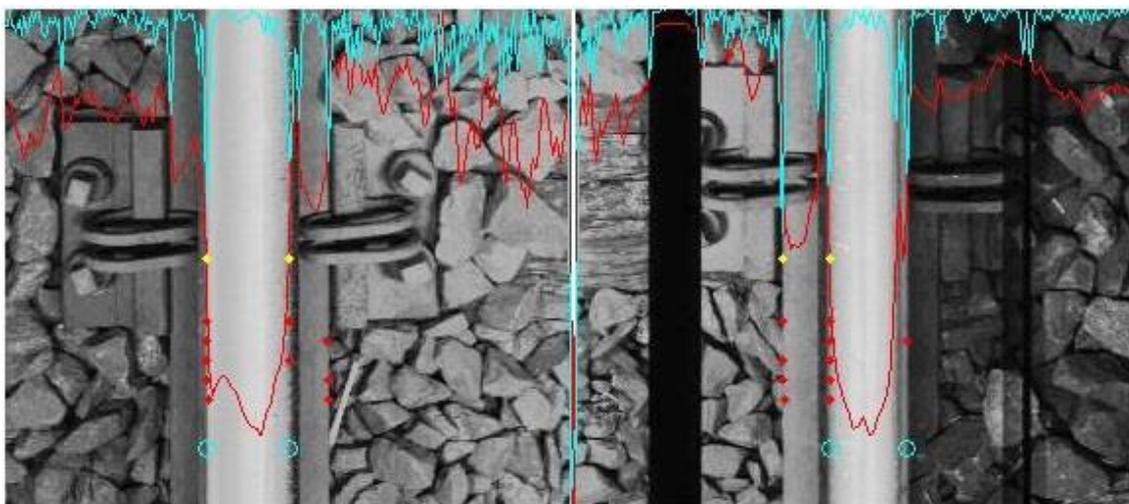
w: Número de linhas da imagem

i: Variável que percorre as linhas da matriz

j: Variável que percorre as colunas na matriz

Conforme a Figura 22, a linha vermelha indica o vetor resultante dessa multiplicação elemento a elemento (Equação (3)). Note que a posição sobre o boleto possui valor bem destacado (deslocado para baixo). A linha ciano (azul claro) indica o gradiente da linha vermelha. Assim, os pontos de grande gradiente podem indicar o limite lateral do boleto. Para melhorar a acurácia, essa medida é tomada em 5 pontos da imagem (pontos vermelhos), ao dividi-la em 5 faixas horizontais. O ponto amarelo resume a votação entre os pontos vermelhos para melhor representá-los com o ponto mais frequente (moda). Por fim, o círculo ciano é a resposta final entre os candidatos (pontos vermelhos) e considera, além dos candidatos, o valor esperado de topologia dos elementos (largura do boleto do trilho e distância entre trilhos). Este método apresenta resultados satisfatórios e até corrige eventuais posições erradas de candidatos. Responde rapidamente pois contém operações simples e otimizadas para operações matriciais.

Figura 22 – Tentativa de identificação da lateral do boleto do trilho



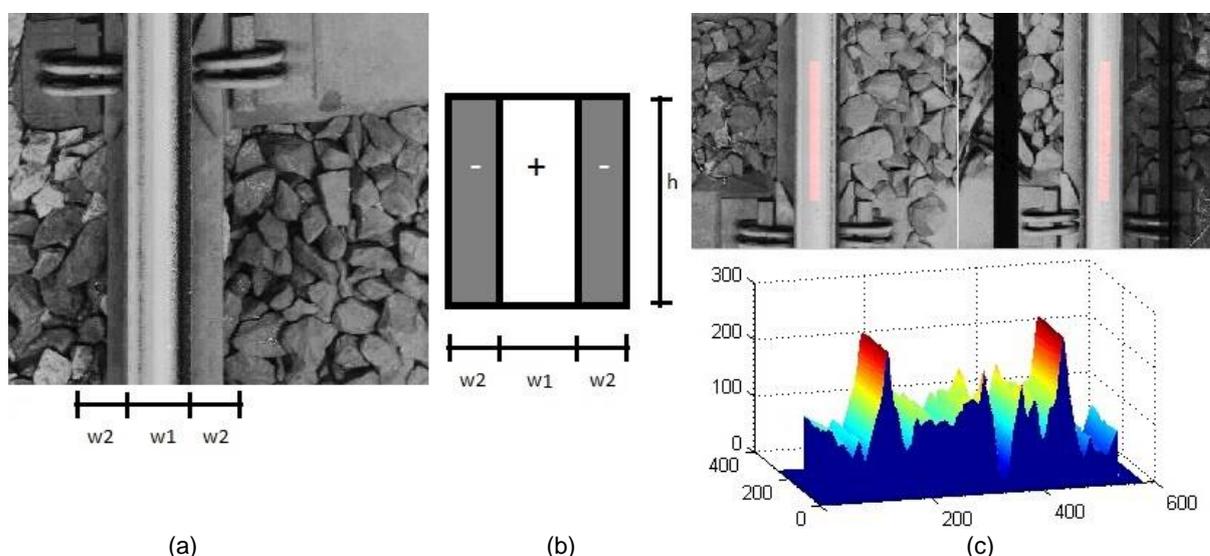
Um dos métodos para identificar as dimensões do boleto do trilho. Este leva em consideração que o boleto do trilho geralmente possui *pixels* mais claros e com valores uniformes. Fonte: elaborado pelo autor.

No entanto, a técnica que se mostrou bastante valorosa pela assertividade e rapidez na resposta foi a combinação de Imagens Integrais (chamadas de Tabelas de Áreas Somadas em Crow (1984)) e filtro de Haar (Haar *wavelets* em Papageorgiou, Oren e Poggio (1998)). Entretanto, nesta implementação não foi utilizada a arquitetura

de classificadores em cascata e nem foi preciso treinar o classificador de forma recorrente, como acontece no algoritmo de reconhecimento de face Viola-Jones (VIOLA; JONES, 2004). Apenas se utiliza a rapidez e robustez da combinação das Imagens Integrais e do filtro de Haar para calcular derivadas para todos os *pixels* da imagem em praticamente um único passo.

Tomando como base a dimensão do boleto (parte superior) do trilho e sua disposição na imagem, o elemento do filtro de Haar foi estabelecido conforme mostrado na Figura 23. A *feature* $w1$ é a média da dimensão do boleto do trilho, em *pixels* e $w2$ é a metade de $w1$. A *feature* h é definida como 1/5 da altura da imagem. Assim há uma série de candidatos ao longo da altura da imagem.

Figura 23 – Características do trilho e filtro de Haar peculiar



(a) Exemplo de extração de *feature* do trilho. (b) Filtro de Haar usado para encontrar a posição do trilho. (c) Resultado da aplicação do filtro sobre a imagem (região vermelha indicando o centro do trilho).
Fonte: elaborado pelo autor.

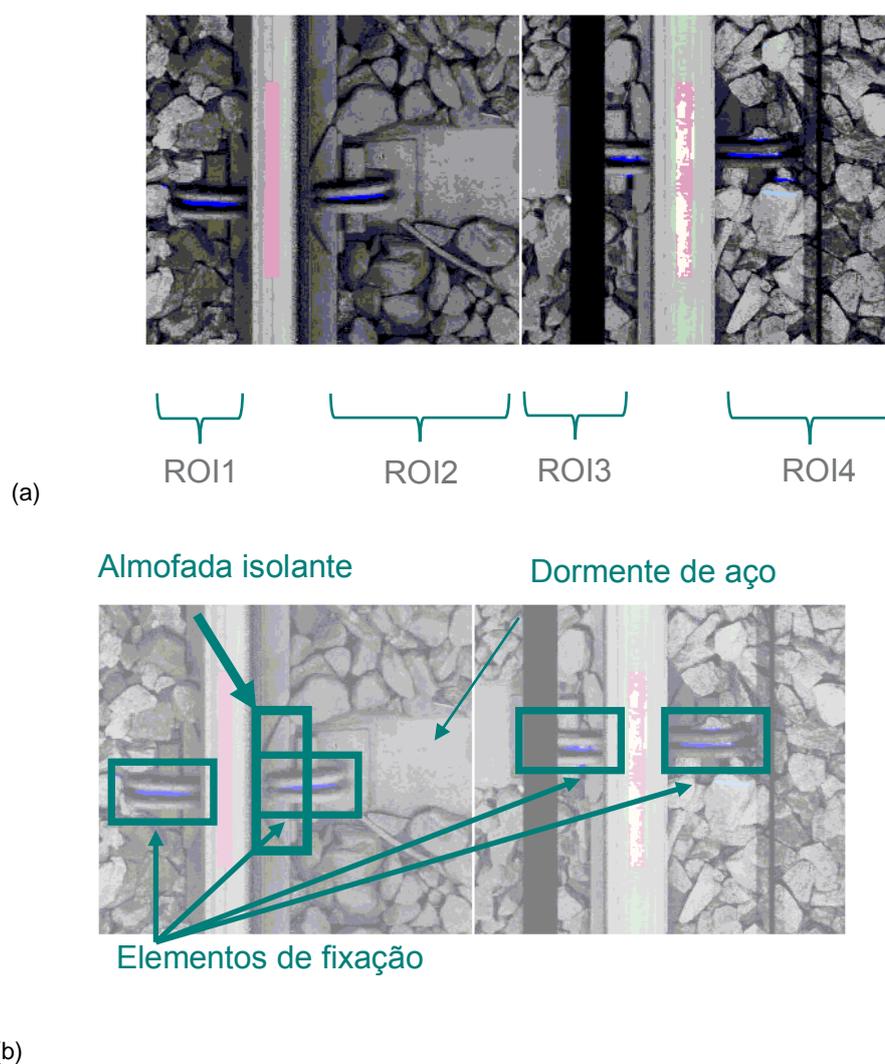
O resultado do filtro de Haar é a posição mais provável horizontalmente de onde o trilho se encontra na imagem. Erros e falsos positivos são descartados considerando informações de distância entre trilhos (comumente conhecida como bitola) e dimensão da imagem.

Portanto, de posse da posição do trilho, é possível determinar as possíveis quatro regiões de interesse (ROIs) onde os dormentes poderão ser vislumbrados.

2.1.2 Determinando as ROIs

As ROIs são quatro regiões que, em cada imagem, provavelmente conterão as partes visíveis dos dormentes. Além dos dormentes, estruturas importantes, como elementos de fixação (grampos) e placas de apoio, eventualmente poderão ser observados (Figura 24).

Figura 24 – Regiões de interesse



(a) Regiões de interesse e (b) elementos geralmente encontrados. Fonte: elaborado pelo autor.

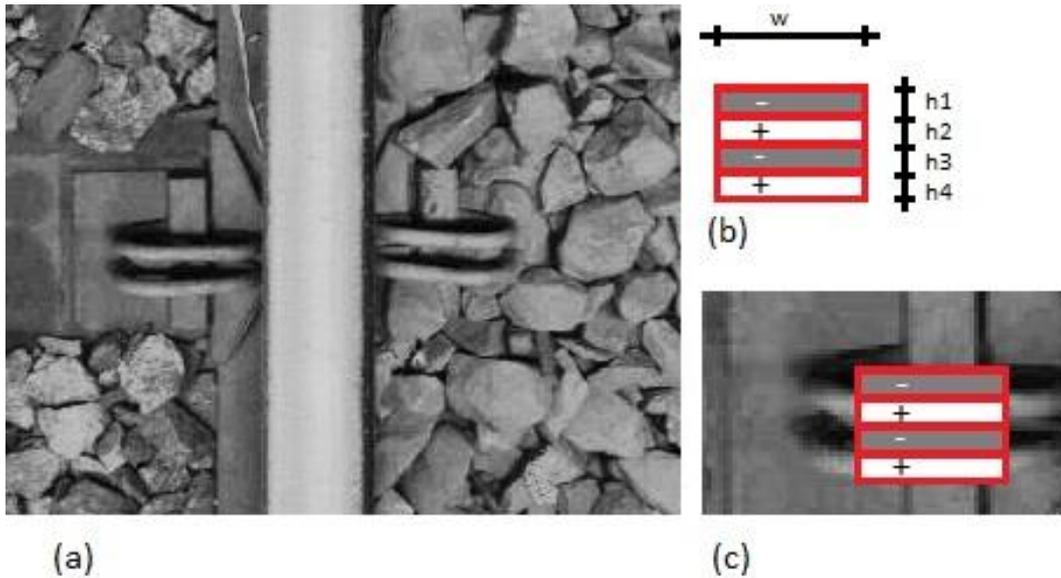
Dentro das ROIs, as áreas mais próximas aos boletos dos trilhos são prováveis de conterem elementos de fixação e placas de apoio. As áreas restantes são propícias para encontrar as faces dos dormentes, quando visíveis.

2.1.3 *Encontrando as fixações*

Os elementos de fixação são o elo de ligação entre os dormentes e os trilhos e, portanto, sua presença é indicativo da posição dos dormentes. Por vezes, mesmo com o dormente encoberto é possível visualizar a fixação na imagem.

Para a localização da fixação usou-se a mesma ideia da procura do trilho: imagens Integrais e filtro de Haar. No entanto, o filtro utilizado foi bem diferente. No caso do trilho, que possui uma dimensão bem significativa, pois corta toda a imagem verticalmente, o filtro adotado é bem simples (apenas 3 elementos de áreas retangulares). Sua maior vantagem para evitar falsos positivos é que sua dimensão vertical é maior que qualquer outro elemento presente na imagem (mesmo assim bem menor que a dimensão da imagem). No caso da fixação, como a dimensão da estrutura metálica visível é bem menor que qualquer dimensão da imagem e por vezes de dimensões semelhantes a outros elementos como pedras e vegetação presentes, o filtro deve ter o grau de complexidade adequado para este caso. Deve ser complexo o suficiente, de forma a não realçar outros elementos que não sejam fixações e também deve ser simples o bastante para representar bem o elemento procurado, não se perdendo em variações de tamanho e posição da fixação. Alguns testes com filtros complexos, com mais de 5 regiões diferenciadas no filtro, falharam consideravelmente. As melhores respostas vieram de filtros mais simples, conforme mostrado na Figura 25. O filtro foi implementado considerando que a fixação normalmente se apresenta com o grampo aparente (conforme Figura 25) e, portanto, com uma região de sombra característica que o grampo gera devido ao sistema de iluminação projetar a sombra para a parte superior da imagem.

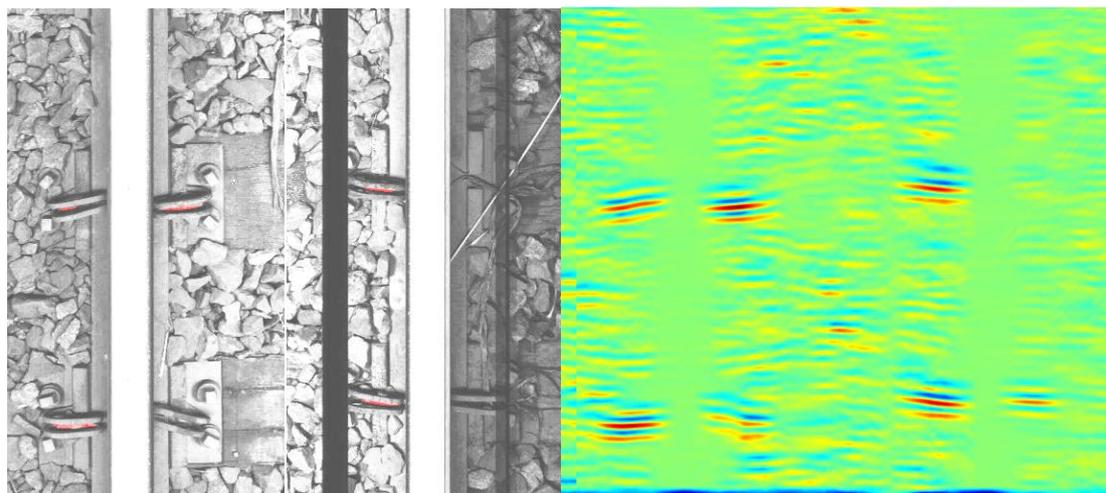
Figura 25 – Características da fixação e filtro de Haar peculiar



(a) Exemplo de imagem com a fixação aparente e o dormente aparente e não aparente. (b) Filtro de Haar para encontrar a fixação. (c) Aplicação do filtro sobre a região da fixação e a correspondência (*matching*) com as regiões de sombra.

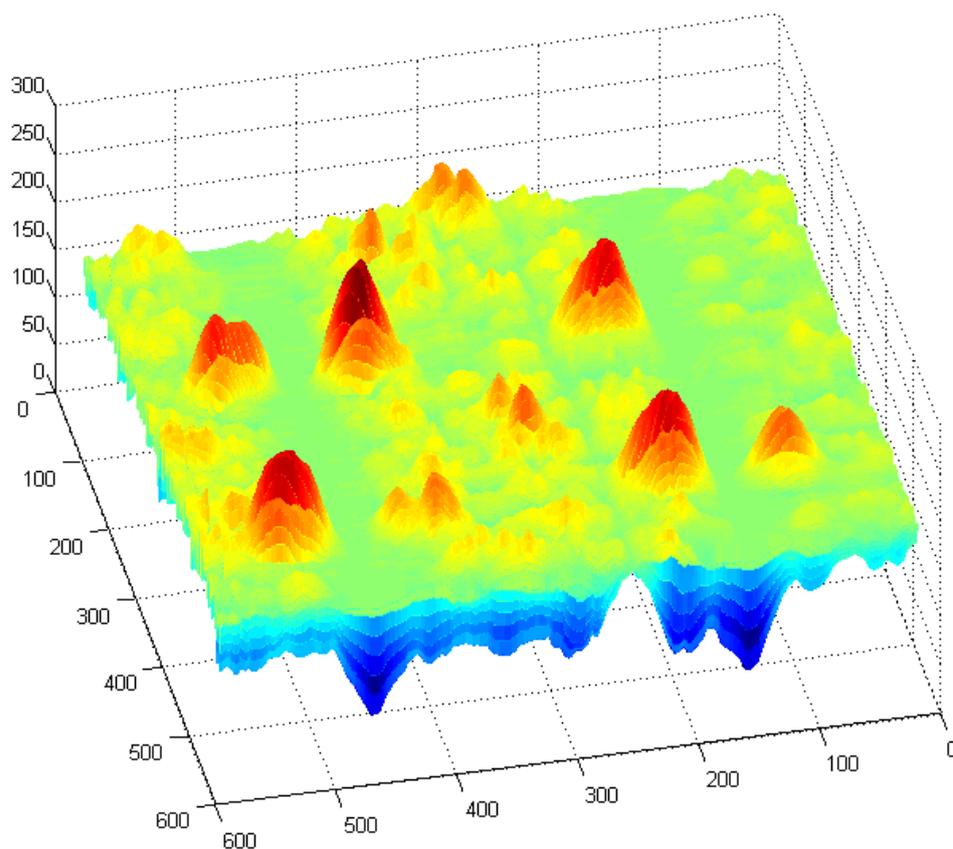
Da mesma forma que na procura do trilho, o resultado da filtragem retorna as prováveis posições das fixações. Com base na posição do trilho, topologia das fixações nas quatro ROIs e geometria da linha, alguns casos de falsos positivos que ainda possam ocorrer são facilmente descartados. Uma aplicação do filtro é apresentada na Figura 26.

Figura 26 – Resultado do filtro de Haar de fixação sobre a imagem



(a)

(b)



(c)

(a) Exemplo de filtragem para encontrar as fixações. O destaque em vermelho são os maiores valores retornados pelo filtro da Haar. A imagem foi propositalmente clareada para melhor visualização. (b) Resultado da filtragem em mapa de cores. (c) Resultado da filtragem em mapa de cores e em três dimensões. Os picos vermelhos são os maiores valores. Fonte: elaborado pelo autor.

2.1.4 Procurando dormentes

Nas regiões de interesse, as fixações são os elementos que aparecem mais próximos aos trilhos. Os dormentes, quando visíveis, aparecem após as fixações. Portanto a região mais propícia para a procura dos dormentes é esta região de interesse, excluindo a região destinada à fixação.

De posse das regiões de procura dos dormentes, foram buscadas informações na imagem que poderiam diferenciar uma imagem com dormentes de uma imagem com brita. Uma imagem com brita possui informação aleatória de intensidade e as dimensões dos elementos são inferiores à largura dos dormentes padrões. Deste modo, duas técnicas foram empregadas para usar essas informações e determinar se há dormente visível na região.

A primeira foi avaliar a entropia da região (MADASU; YARLAGADDA, 2007). Se a região apresenta uma alta entropia (entenda-se entropia como grande variabilidade das intensidades dos *pixels* em relação aos vizinhos), então é bem provável que haja apenas brita (do lastro) visível ou outro elemento naturalmente aleatório. Por outro lado, se houver baixa entropia em uma grande área, pode significar um grande elemento com uma superfície de baixa variância, ou seja, uma textura homogênea.

A característica de entropia, para cada *pixel* de uma imagem é definida conforme a Equação (4):

$$E(i, j) = - \sum_{i=1}^w \sum_{j=1}^w Y(i, j) \log Y(i, j) \quad (4)$$

Onde

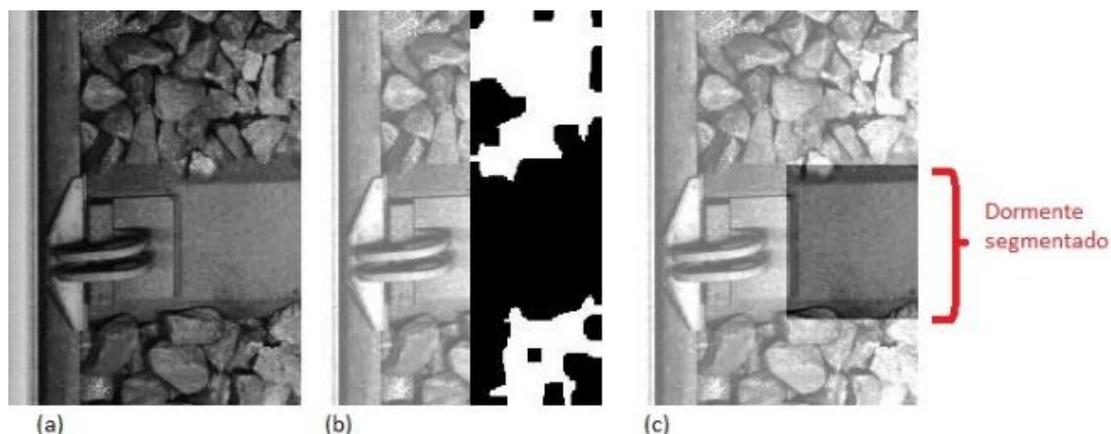
E: Entropia de cada *pixel* da imagem

Y: Probabilidade da similaridade entre *pixels* vizinhos

w: Janela de avaliação de vizinhos, foi utilizado 9x9 *pixels*

Para um limiar de entropia estabelecido, fica claro o destaque das regiões de baixa entropia. Por fim são agrupadas e consideradas como candidatas a dormentes as regiões que apresentam baixa entropia e que possuem dimensão esperada de dormente. A Figura 27 exemplifica essas características.

Figura 27 – Identificação de textura usando Entropia



(a) Exemplo de imagem com dormentes a serem procurados. (b) Aplicação de Filtro de Entropia na região de interesse. (c) Região com baixa resposta ao filtro de Entropia destacada e identificando o dormente segmentado. Fonte: elaborado pelo autor.

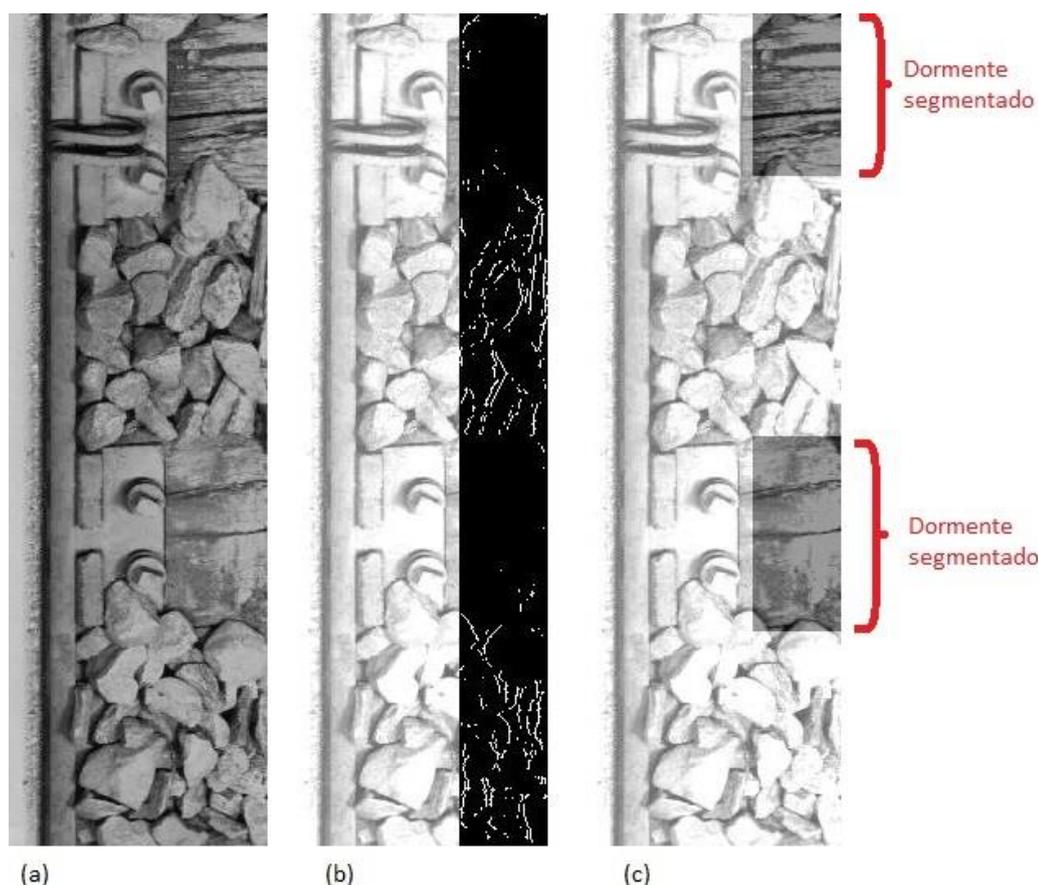
Claramente a avaliação de entropia atende bem quando o dormente analisado é de aço e está desobstruído. Para dormentes de madeira, há também uma boa resposta quando a superfície do dormente possui apenas algumas ranhuras, não muito profundas ou em grande quantidade. No entanto, em alguns casos a entropia de dormentes de madeira aparente apresenta-se alta.

A fim de aumentar a acurácia para identificar dormentes de madeira e também avaliar outra característica dos dormentes de aço, emprega-se outra técnica adicional. Procuram-se regiões que possuem poucas bordas verticais. Nos dormentes (sejam eles de madeira ou de aço) não são esperadas muitas bordas verticais. Com exceção dos elementos de fixação e de eventuais objetos sobrepostos, a rigor, na região dos dormentes não haverá bordas verticais. Em particular nos dormentes de madeira esperam-se algumas bordas horizontais. Ademais, nas regiões de brita, dada a sua natureza aleatória, esperam-se muitas bordas verticais e horizontais. Para avaliar as bordas verticais utilizou-se um filtro Sobel Vertical.

Da mesma forma que a avaliação anterior, regiões que possuíam pouca presença de bordas verticais e que possuíam a dimensão da largura dos dormentes são as mais prováveis de o serem de fato (Figura 28).

Essa avaliação é apreciada como necessária pois, no caso de dormentes de madeira, se a superfície do dormente possuir muitos nós na madeira, eventualmente na avaliação de entropia pode-se presumir que não se trata de um dormente. No entanto na avaliação de bordas verticais, isso será desmentido.

Figura 28 – Identificação de textura usando Sobel



(a) Exemplo de imagem com dormentes a serem procurados. (b) Aplicação de Filtro de borda Sobel Vertical na região de interesse. (c) Região com baixa resposta ao filtro de borda destacada e identificando o dormente segmentado. Fonte: elaborado pelo autor.

2.1.5 Fundindo informações para definir a posição definitiva dos dormentes

Sintetizando o que foi apresentado anteriormente, tem-se as informações das possíveis posições dos dormentes obtidas de diferentes formas:

- Posição da fixação;
- Regiões de baixa entropia;
- Regiões com poucas bordas verticais (usando Sobel Vertical).

Considerar-se-á cada uma dessas três técnicas como um sensor disponível e sua resposta é a posição de um, vários ou nenhum candidato a dormente avaliado em cada uma das 4 ROIs. Todas as avaliações desses sensores são independentes entre si, ou seja, não usam informações comuns ou necessitam das respostas uns dos outros (não estão cascadeados). Logo, uma avaliação não influencia a outra. Com isso, uma avaliação errada não induz erro em outra avaliação e assim, evita-se que o

erro de uma avaliação se propague até outra avaliação e tenha uma forte influência na avaliação final.

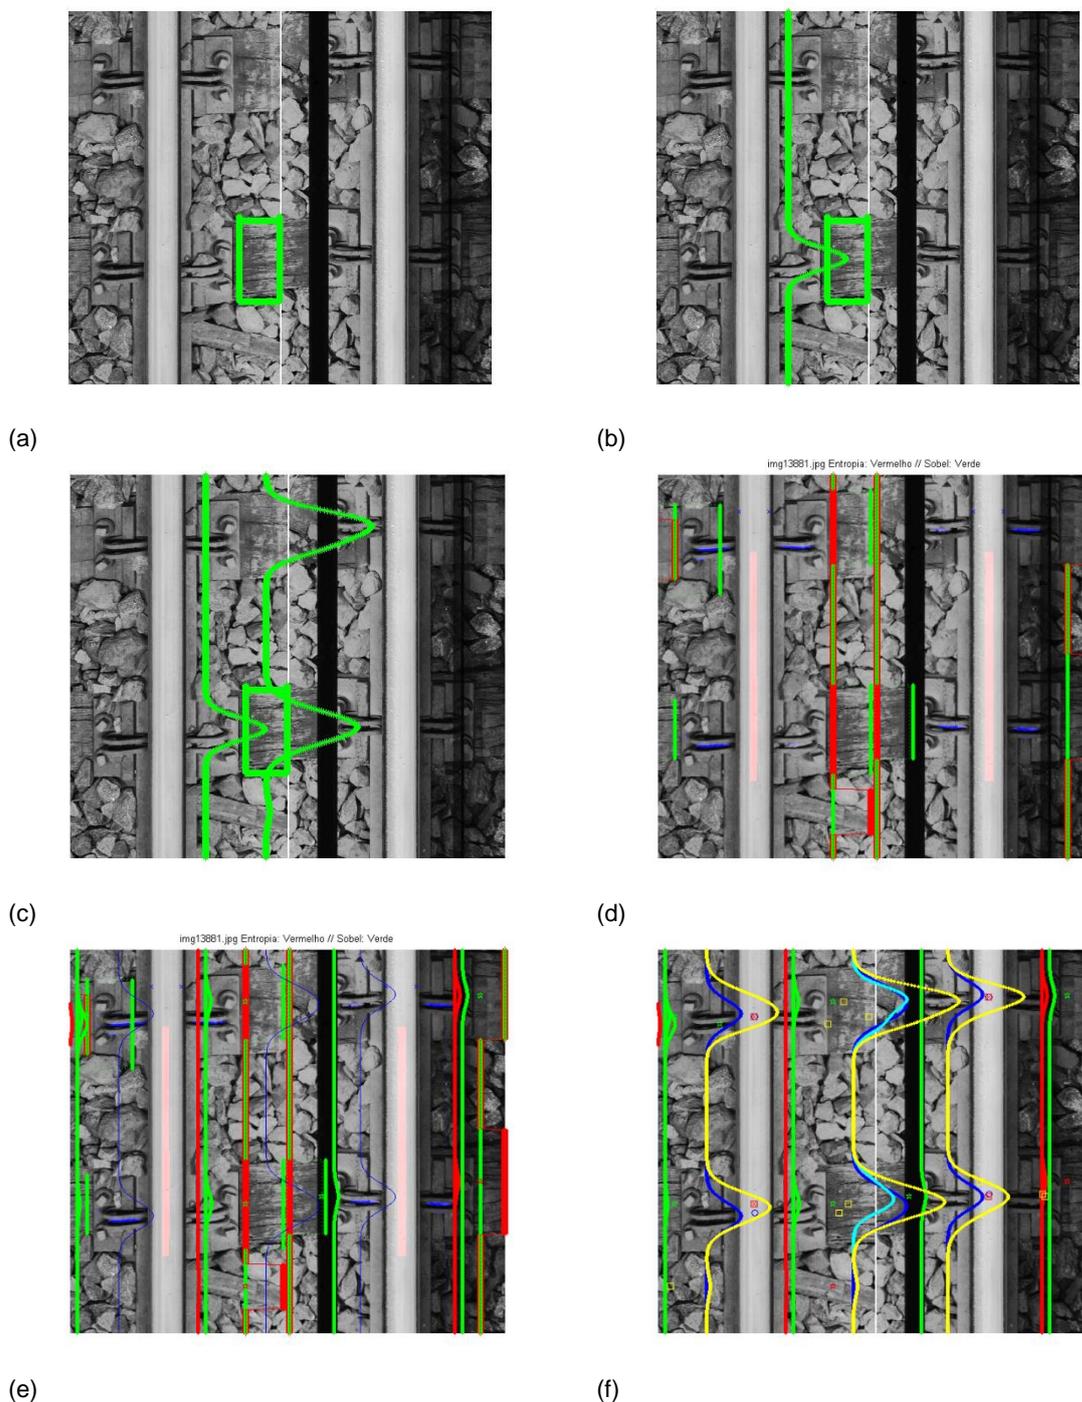
Além disso, as implementações foram construídas de forma a não serem sensíveis à variação de iluminação e dependerem minimamente de constantes e *thresholds* fixos. Quando presentes, estes parâmetros são adaptativos, pois são ajustados ou definidos de acordo com as características atuais de cada ROI analisado. Por exemplo, a medida limite de entropia é uma fração da média de entropia de todo o ROI. Os métodos empregados são métodos de segmentação e classificação não supervisionados e, portanto, não necessitam de treinamento prévio. No entanto se apoiam muito nos parâmetros de topologia e dimensões dos elementos comuns da via férrea.

Para a estimativa cabal da posição são consideradas as informações citadas anteriormente e também a informação da quantidade de dormentes esperados (de acordo com a dimensão da imagem) e distância mínima e máxima entre dormentes. Tudo isso é compilado em um sistema de votação (com pesos balanceados de acordo com as informações mais fidedignas). Como um único dormente que apoia os dois trilhos está razoavelmente alinhado dos dois lados da imagem (veja Figura 26 (a)), há, no melhor caso, 12 oportunidades para confirmar verdadeiramente a posição de um dormente (4 regiões diferentes x 3 métodos independentes). Essas oportunidades diminuem, por exemplo, quando um dormente está encoberto nas ROIs (veja Figura 25 ou Figura 26) ou a fixação está ausente (Figura 26) ou quando uma das 4 regiões é tão curta que possui a dimensão dos elementos da brita e por isso não pode ser considerada como informação útil. Isto ocorre principalmente quando a via férrea está em uma curva.

O melhor caso ocorre quando a imagem é grande o suficiente de forma que é esperado mais de um dormente na imagem. Assim, além das 12 oportunidades de encontrar um dormente há outros dormentes dispostos ao longo da dimensão vertical da imagem que também fornecem informações sobre a posição mais provável dos dormentes. Isto porque é esperado que os dormentes estejam posicionados a uma distância padrão. Por tratar-se de posição mais provável, para simplificação, trataremos no texto com o termo probabilidade. No entanto, no rigor da palavra, não se trata de probabilidade por não estar fundamentada numa avaliação estatística literal, apenas assume valores entre zero e um, conforme a maior chance de conter a posição do dormente. Portanto, cada resposta positiva de um sensor para a presença

de um dormente é usada como ancoragem para uma grade de probabilidades que influenciam, além da probabilidade de existir um dormente nesta posição, também a probabilidade de existir um dormente nas 3 outras ROIs, nesta mesma posição horizontal e em posições verticais diferentes, nas 4 ROIs. Na Figura 29 é apresentado a influência de um sensor ao encontrar um indício de dormente e sua influência no restante da imagem, propondo que outras posições na imagem também contém uma probabilidade de existir dormentes. A Figura 29 (a) apresenta a resposta do filtro Sobel indicando a possível presença de um dormente. A Figura 29 (b) distribui a probabilidade da posição do centro deste dormente e sobre o próprio dormente associado (em verde). A Figura 29 (c) apresenta a influência deste dormente na proposição de existência de dormentes em outras posições. A Figura 29 (d) apresenta a resposta dos sensores de Entropia (em vermelho) e Sobel (em verde), indicando presença de dormente. Na Figura 29 (e) é possível perceber a influência de cada resposta dos sensores de Entropia (em vermelho) e Sobel (em verde) em toda a imagem por meio da probabilidade da posição dos dormentes. Por fim, a Figura 29 (f) apresenta a fusão dos diversos sensores em várias curvas de probabilidade: elementos de fixação encontrados (linhas azuis); resposta do filtro de Entropia (linhas vermelhas); resposta do filtro Sobel (linhas verdes); fusão dos sensores de Entropia e Sobel (linha ciano) e fusão de todos os sensores (linhas amarelas). Há três respostas das linhas amarelas e azuis pois as respostas das ROIs 1 e 2 são combinadas para gerar uma única resposta e das ROIs 3 e 4 também são combinadas para gerar uma única curva pois estas ROIs são perfeitamente alinhadas (trilho esquerdo e trilho direito) e uma terceira curva composta da resposta das 4 ROIs.

Figura 29 – Exemplo da influência de um dormente descoberto na procura de outros dormentes e fusão de sensores



(a) Indicação de dormente usando Sobel (retângulo verde). (b) Probabilidade da posição do dormente (linha verde). (c) Probabilidade da posição em outros dormentes (linha verde). (d) Respostas dos sensores de Entropia (Linhas vermelhas) e Sobel (Linhas verdes). (e) Probabilidades das posições dos dormentes provenientes dos sensores de Entropia (linhas vermelhas) e Sobel (Linhas verdes). (f) Probabilidades das posições dos dormentes vários sensores: Entropia (Linhas vermelhas), Sobel (Linhas verdes), Fixação (Linhas azuis), fusão de Entropia e Sobel (Linha ciano) e fusão de todos os sensores (Linhas amarelas). Fonte elaborado pelo autor.

A fusão dos sensores dá-se ao computar a probabilidade de cada um dos sensores para encontrar, entre os candidatos, as posições mais prováveis de conterem o centro do dormente. Para o sensor que identifica os elementos de fixação, cada elemento identificado gera uma probabilidade da posição de um dormente e também a uma distância padrão de deslocamento de dormentes. Para os sensores do filtro de Entropia e Sobel, as probabilidades serão maiores quando:

1. Nas proximidades, há outros sensores também apontando candidatos, contribuindo para aumentar a probabilidade local;
2. Quanto mais próximo da dimensão vertical esperada de um dormente for a resposta do sensor. Acompanha uma distribuição normal pré-definida;
3. Quanto maior for a dimensão horizontal da ROI observada, limitado a um valor pré-definido.

Portando cada uma das probabilidades é definida conforme as equações a seguir

Considere a função de densidade de probabilidade de uma distribuição normal:

$$N(y, \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{\left(-\frac{(y-\mu)^2}{2\sigma^2}\right)}, -\infty < y < \infty, \sigma > 0 \quad (5)$$

Dado uma posição vertical μ identificada pelo sensor de elementos de fixação como a provável posição de dormentes, a função que define a probabilidade de encontrar outros dormentes resultantes da influência da resposta do sensor é dada por:

$$ProbFixação(y, \mu, \sigma, \delta) = \sum_{i=-3}^3 N(y, \mu + i \cdot \delta, \sigma) \quad (6)$$

Onde

y : cada posição vertical (na altura) da imagem

μ : posição vertical na imagem indicada pelo sensor

σ : desvio padrão da posição centrada no dormente

δ : deslocamento entre dormentes subsequentes

As imagens processadas podem conter até 4 dormentes, por isso é calculada, através da variável i a influência de até 3 dormentes antes e depois de um possível dormente. Como podem haver dormentes próximos as extremidades das imagens, as influências destes são calculadas também foram das dimensões verticais da imagem, pois a posição central de um dormente pode estar fora das dimensões da imagem, mesmo com parte do dormente ainda dentro da imagem. Por isso, o vetor de probabilidades tem a dimensão horizontal maior que a dimensão da imagem.

As funções que definem a probabilidade de encontrar dormentes dada uma resposta de posição do centro do dormente μ dos sensores de filtro de Entropia e Sobel são semelhantes entre si e um pouco mais elaboradas que função de fixação. Esta função leva em consideração também a dimensão vertical x_v da resposta de dormente encontrado e a dimensão horizontal n da região de interesse (ROI) observada. Observe as equações abaixo

$$\begin{aligned} ProbEntropia(y, \mu, \sigma, y_v, \mu_v, \sigma_v, y_h, \mu_{min}, \mu_{max}) \\ = ProbSobel(y, \mu, \sigma, y_v, \mu_v, \sigma_v, y_h, \mu_{min}, \mu_{max}) \\ = (F_v(y_v, \mu_v, \sigma_v)) \cdot (F_h(y_h, \mu_{min}, \mu_{max})) \cdot (N(y, \mu, \sigma)) \end{aligned} \quad (7)$$

$$F_v(y_v, \mu_v, \sigma_v) = N(y_v, \mu_v, \sigma_v)/16 \quad (8)$$

$$F_h(x_h, \mu_{min}, \mu_{max}) = 1 + (I(x_h, \mu_{min})) \cdot (x_h - \mu_{min}) / (\mu_{max} - \mu_{min}) \quad (9)$$

$$I(x_h, \mu_{min}) = \begin{cases} 1, & \text{se } x_h \geq \mu_{min} \\ 0, & \text{se } x_h < \mu_{min} \end{cases} \quad (10)$$

Onde

y : toda posição vertical na imagem

μ : posição vertical na imagem indicada pelo sensor

σ : desvio padrão da posição centrada no dormente

y_v : dimensão vertical do dormente identificado pelo sensor

μ_v : dimensão vertical padrão dos dormentes

σ_v : desvio padrão da dimensão vertical padrão dos dormentes

x_h : dimensão horizontal da região de interesse observada

μ_{min} : dimensão horizontal mínima esperada das ROIs

μ_{max} : dimensão horizontal máxima esperada das ROIs

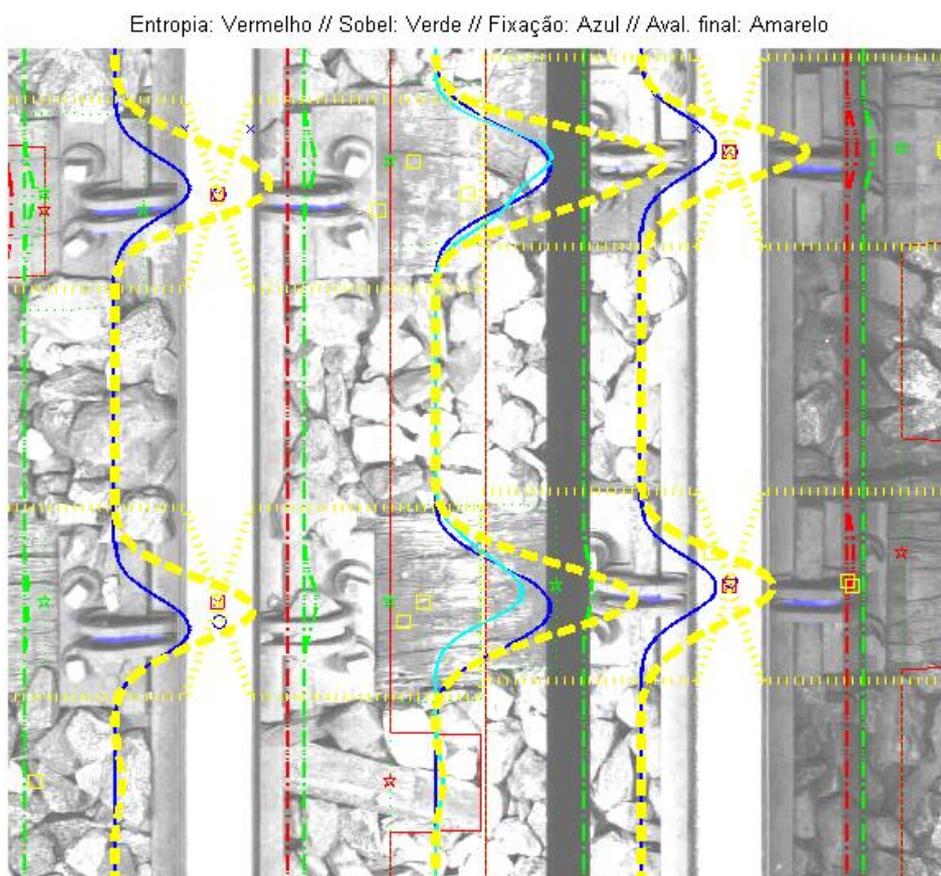
As Equações (8) e (9) indicam fatores que multiplicam a distribuição de probabilidade da resposta de determinado sensor. Esses fatores podem assumir valores que aumentam ou diminuem a contribuição do determinado sensor, de acordo com certas características encontradas. Por exemplo, a Equação (8) avalia o quanto o sensor percebe uma estrutura com a dimensão vertical mais próxima possível de um dormente real. Se estiver visualizando apenas parte do dormente ou um pedaço de madeira (como visualizado na Figura 29 (d)), sua influência é menor. O mesmo ocorre caso a estrutura observada seja maior que o esperado, como quando ocorre no caso de o lastro estar coberto de areia, formando uma camada uniforme e contínua na imagem. Neste caso, sua influência também é diminuída. A Equação (8) possui um fator de divisão igual a 16 porque este é o número máximo de avaliações para um dormente. Acompanhe: há 2 tipos de sensores (Entropia e Sobel); há 4 ROIs para se avaliar; cada ROI é avaliada 2 vezes. O motivo de se avaliar cada ROI duas vezes é porque uma vez avalia-se a ROI apenas na área destinada a superfície do dormente (sem considerar a placa de fixação) e caso essa área seja significativamente considerável, avalia-se novamente a mesma área. No entanto, caso a área não seja extensa a ponto de se diferenciar da dimensão da brita, estende-se a área até a placa de fixação, considerando, portanto, toda ROI definida. Os testes experimentais ratificaram que esta consideração aumenta a taxa de acerto da posição do dormente na imagem.

Por fim, ao computar a curva de densidade de probabilidade de cada sensor obtém-se uma curva para cada lado da imagem (trilho esquerdo e trilho direito). A curva à esquerda corresponde à soma das curvas dos sensores à esquerda (sobre o trilho esquerdo) dividida por dois mais a soma das curvas dos sensores à esquerda e à direita dividida por dois, de modo que o máximo valor alcançado é 1 e que a influência do lado esquerdo é $3/4$ e do lado direito é $1/4$. De forma análoga, a curva à direita possui uma parcela apenas de sensores à direita e outra parcela referente a todos os sensores. Assim, é estabelecida a influência de um lado em relação ao outro. Note, na Figura 30, que o mesmo dormente, quando comparado nos dois lados da imagem, pode estar ligeiramente defasado. Por isso a influência dos sensores de lados diferentes da imagem é presente, mas diminuída.

Portanto, na Figura 30 é possível observar todas as proposições descritas até então:

1. As marcações em azul correspondem ao sensor de elementos de fixação. Estruturas elípticas sólidas azuis são as posições dos elementos de fixação encontrados. As linhas sólidas em azul são a probabilidade de encontrar dormentes por esse sensor. Há uma curva à esquerda, outra à direita e outra ao centro, indicando as repostas dos sensores à esquerda, à direita e todos os sensores juntos;
2. As marcações em vermelho são as respostas ao sensor de Entropia. As estruturas em forma retangular são as respostas positivas a este sensor. Note que algumas estruturas combinam exatamente com a dimensão vertical do dormente real, outras são maiores e outras menores. Isto influenciará nos pesos a se considerar. Inclusive há uma marcação em uma estrutura que não é dormente e sim em um pedaço de madeira sobre o lastro. As linhas tracejadas em vermelho são as linhas de probabilidade deste sensor;
3. De forma semelhante, as marcações em verde são as respostas ao sensor Sobel. Novamente, as estruturas retangulares são as respostas positivas aos sensores. Interessante notar que no primeiro dormente da ROI à esquerda do trilho esquerdo (canto superior esquerdo da imagem), pelo fato da região ser muito curta, foi avaliada também a região sobre a placa de fixação, retornando positivamente para um candidato a dormente. As linhas tracejadas em verde são as linhas de probabilidades;
4. A linha em ciano (azul claro) é a composição de todos os sensores de Entropia e Sobel;
5. As linhas tracejadas em amarelo são as linhas de probabilidade dos sensores à esquerda, à direita e de todos os sensores (linha ao centro). Os quadrados em amarelos são todos os candidatos a centro dos dormentes, de cada lado da imagem. Quanto mais à direita na imagem, maior a probabilidade correspondente. Por fim os quadrados vermelhos sobre os trilhos são a resposta final para cada dormente em cada lado da imagem.

Figura 30 – Posição do dormente identificado



A avaliação da posição do dormente em cada lado da imagem é indicada pelo retângulo tracejado em amarelo. É possível perceber a influência dos diversos sensores: Fixação (linhas azuis), Entropia (vermelho), Sobel (verde) e a avaliação final (linhas amarelas). A imagem foi clareada para melhor visualização. Fonte: elaborado pelo autor.

2.2 Definindo onde os dormentes estão aparentes

Uma vez definido as posições dos dormente é possível avaliar, para um dormente específico, quais ROIs contêm dormentes aparentes e, portanto, informação útil para avaliar o tipo de dormente e sua qualidade. Uma vez que se identifique que uma ROI contém apenas lastro, essa ROI específica não poderá ser contabilizada para definir qual o tipo de dormente.

Nas áreas consideradas como área de dormente, usam-se as mesmas técnicas aplicadas anteriormente de Entropia e detector de borda Sobel Vertical. Quando os filtros respondem positivamente a um ou aos dois filtros (Alta Entropia e/ou presença de borda vertical) indica presença de brita sobre a região esperada do dormente.

Considerando que a brita ou outra estrutura pode cobrir apenas parte do dormente, optou-se por dividir a região a ser analisada em faixas horizontais com a altura (dimensão vertical) limitada a uma quantidade de *pixels* pré-definida e a largura (dimensão horizontal) tão grande quanto a da ROI a ser avaliada. Isto equivale a avaliar a ROI em janelas adjacentes. Cada janela possui uma resposta e a compilação da votação de cada resposta das janelas é considerada para a ROI em questão para definir a presença de brita cobrindo o dormente. Assim, pondera-se a decisão se as estruturas que cobrem apenas parte do dormente inviabilizam a decisão sobre o tipo do dormente. Esta estratégia também apresentou melhor resposta para dormentes que estavam localizados nos extremos da imagem (na parte superior ou inferior da imagem) e, portanto, não estavam sendo visualizados em sua totalidade. O sistema de votação de janelas adjacentes trouxe melhor resposta pois considera que um dormente pode ter a região disponível para avaliação menor que o esperado quando nas extremidades da imagem.

2.3 Determinando o tipo de dormente

2.3.1 Procurando texturas nos dormentes visíveis

Uma vez definida, dentro de cada ROI, o que é dormente ocluso e o que é dormente visível, o próximo passo é definir, entre estes, quais são os tipos de dormentes. Assim, avalia-se a resposta da região usando o filtro de borda Sobel horizontal. Caso a resposta seja certa presença de borda horizontal, a indicação é para que o tipo de dormente seja de madeira, pois indica presença de nós na madeira. Caso contrário será de aço.

Da mesma forma que a avaliação de brita, avalia-se a região através de janelas adjacentes e compila-se através de votação da maioria.

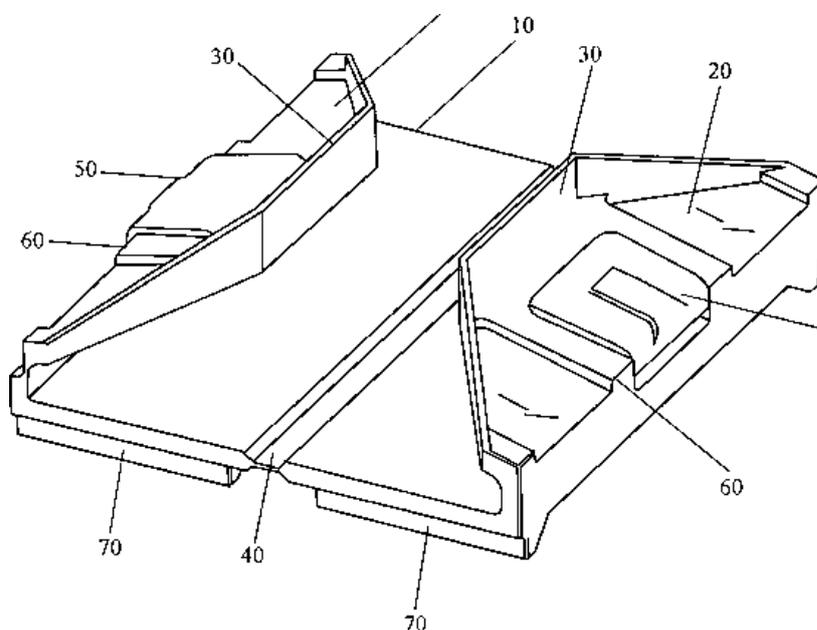
Observando as imagens apresentadas até então, percebe-se que a iluminação varia em cada uma das ROIs de forma diferente: ora a iluminação é afetada pela posição do Sol; ora o sistema de iluminação se encontra avariado (ROI constantemente mais escuro que os demais, conforme Figura 30, a ROI à direita); ora o sistema de captura de imagens apresenta defeitos, como é o caso da linha escura que acompanha todas as imagens nas duas ROIs à direita. A fim de evitar que esses percalços afetem tanto as avaliações dos parâmetros de Entropia e Sobel, os

parâmetros de limites e *thresholds* são adaptativos. Por exemplo, o nível de entropia que define o que é lastro ou dormente visível é proporcional à entropia média da ROI. Assim, mesmo numa região de iluminação insuficiente, é possível diferenciar as regiões de lastro ou dormente.

2.3.2 Procurando elementos de fixação característico de certos tipos de dormentes

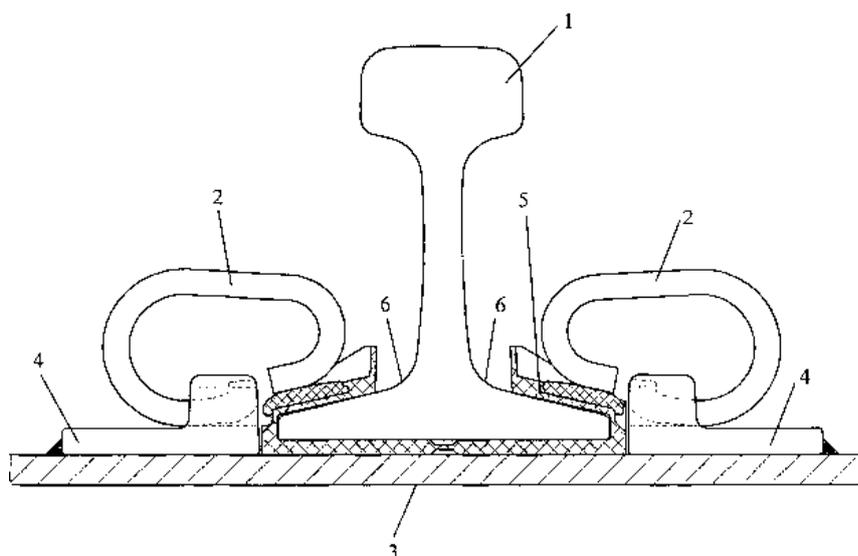
Os elementos de apoio podem apresentar formas diferentes para cada um dos dormentes. Isto é também um indício do tipo de dormente que se encontra na imagem. Por exemplo, no caso de dormentes de aço, há uma estrutura de poliamida que fica entre o dormente de aço e o patim (base) do trilho. Este material é conhecido como almofada isolante ou galocha e serve como isolante elétrico entre o trilho e o dormente de aço. Por haver transmissão de sinais de controle elétricos através dos trilhos é preciso isolá-los dos dormentes de aço para que não haja fuga do sinal para o lastro e para a terra. Essas mesmas estruturas não são necessárias no caso dos dormentes de madeira porque a madeira é isolante elétrica na classe da tensão de operação dos sinais elétricos da ferrovia. Essas almofadas estão representadas na Figura 31 e na Figura 32 pelo numeral 5.

Figura 31 – Almofada isolante em detalhe



Fonte: INPI (2011).

Figura 32 – Posição da almofada isolante entre o trilho e o dormente

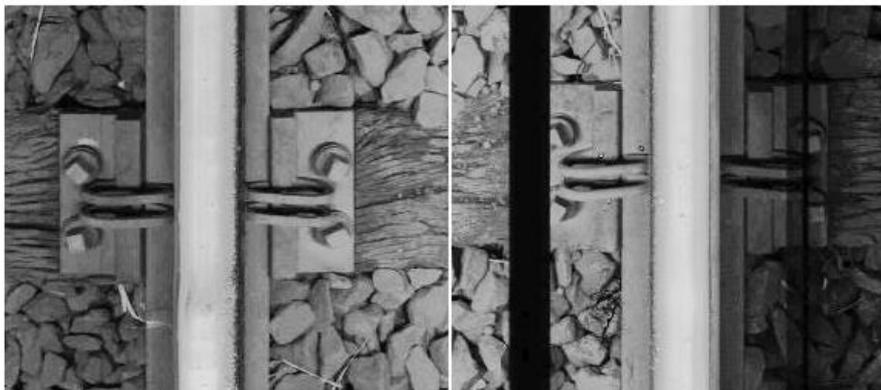


Diversos itens da ferrovia em corte transversal: boleto do trilho (1), grampo do tipo Deenik (2), dormente de aço (3), ombreiras (4), almofada isolante (5) envolvendo o patim do trilho (6). Fonte: INPI (2011).

Na Figura 24 pode ser observado que a almofada é visualizada sobre o patim do trilho. Eventualmente o patim pode estar obstruído com outros elementos, como a brita do lastro, conforme pode ser observado na mesma Figura 24, na região indicada como ROI 4. Portanto, apesar da presença da almofada ser um forte indício da presença de dormente de aço, o contrário não pode ser afirmado. A ausência de almofada pode indicar dormente de madeira (pois não possui almofada) ou dormente de aço que possui a almofada mas pode estar encoberta por outros elementos, portanto não é possível afirmar sobre o tipo de dormente neste caso.

Na almofada isolante são bem características as estruturas em diagonal (com ângulo aproximado de $+65^\circ$ e -65° com a horizontal), próxima ao grampo. Essas estruturas não estão presentes quando o dormente é de madeira. A Figura 33 apresenta um exemplo de imagem com dormente de madeira, e, portanto, sem a almofada.

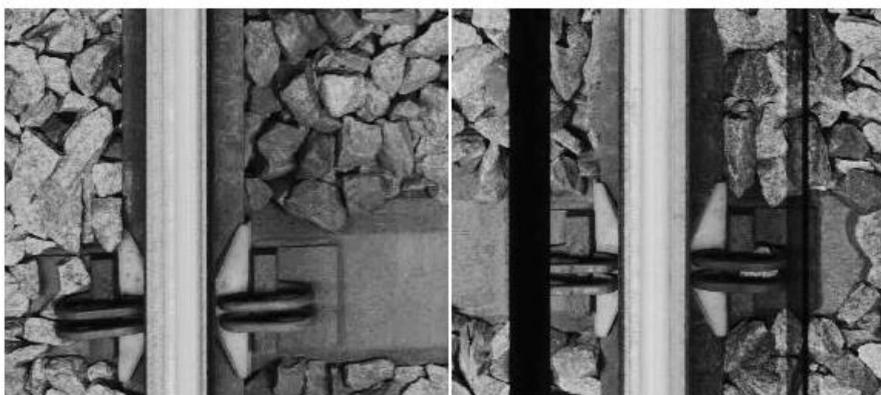
Figura 33 – Almofada isolante não está presente em dormente de madeira



Exemplo de imagem com dormente de madeira. Nota-se que não há presença de almofada isolante ou qualquer outra estrutura sobre o patim do trilho. Fonte: elaborado pelo autor.

A Figura 34 apresenta um exemplo de imagem com dormente de aço. Nota-se claramente a presença da almofada sobre o patim do trilho.

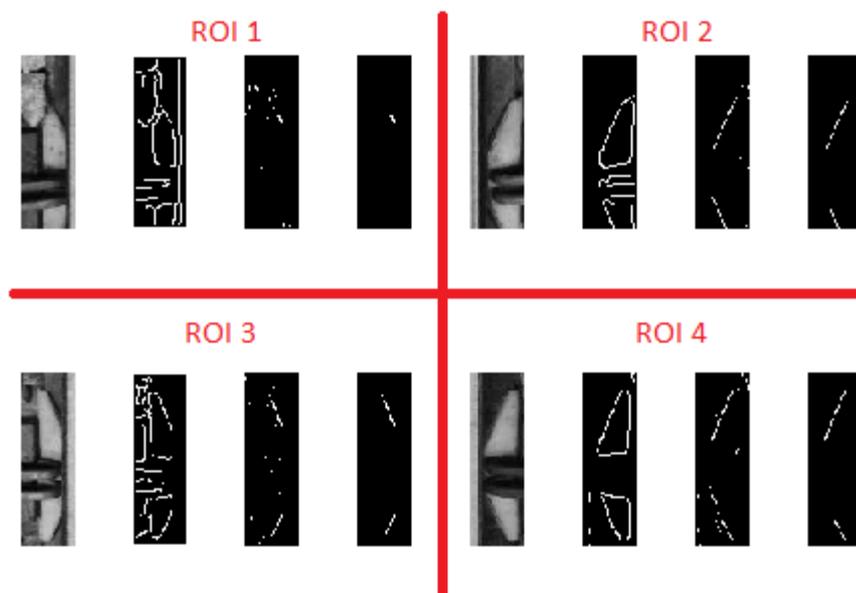
Figura 34 – Almofada presente em dormente de aço



Exemplo de imagem com dormentes de aço. Nota-se a presença da almofada isolante sobre o patim do trilho e a sua estrutura triangular característica. Fonte: elaborado pelo autor.

A Figura 35 apresenta a Figura 34 processada para realçar as almofadas e posteriormente a estrutura diagonal. Cada uma das 4 ROIs são processadas separadamente e apenas na área destinada ao patim.

Figura 35 – Segmentação de estrutura da almofada



Processamento sobre a imagem da Figura 34, destacando as estruturas de interesse da almofada. Fonte: elaborado pelo autor.

Para realçar as estruturas, primeiro aplicou-se um filtro de borda Canny. A escolha pelo Canny é porque ele mantém muitas estruturas conectadas, ou seja, as bordas ficam contínuas. Depois aplicam-se os filtros de dimensões 12x8, menor que a dimensão esperada da estrutura e com inclinação próxima de $+65^\circ$ e -65° , conforme as máscaras mostradas nas Equações (11) e (12):

$$F1/= \begin{bmatrix} 0 & 0 & 0 & 0 & -1 & -1 & +1 & -1 \\ 0 & 0 & 0 & -1 & -1 & +1 & +1 & -1 \\ 0 & 0 & 0 & -1 & -1 & +1 & -1 & -1 \\ 0 & 0 & -1 & -1 & +1 & +1 & -1 & -1 \\ 0 & 0 & -1 & -1 & +1 & -1 & -1 & 0 \\ 0 & -1 & -1 & +1 & +1 & -1 & -1 & 0 \\ 0 & -1 & -1 & +1 & -1 & -1 & 0 & 0 \\ -1 & -1 & +1 & +1 & -1 & -1 & 0 & 0 \\ -1 & -1 & +1 & -1 & -1 & 0 & 0 & 0 \\ -1 & +1 & +1 & -1 & -1 & 0 & 0 & 0 \\ -1 & +1 & -1 & -1 & 0 & 0 & 0 & 0 \\ +1 & +1 & -1 & -1 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (11)$$

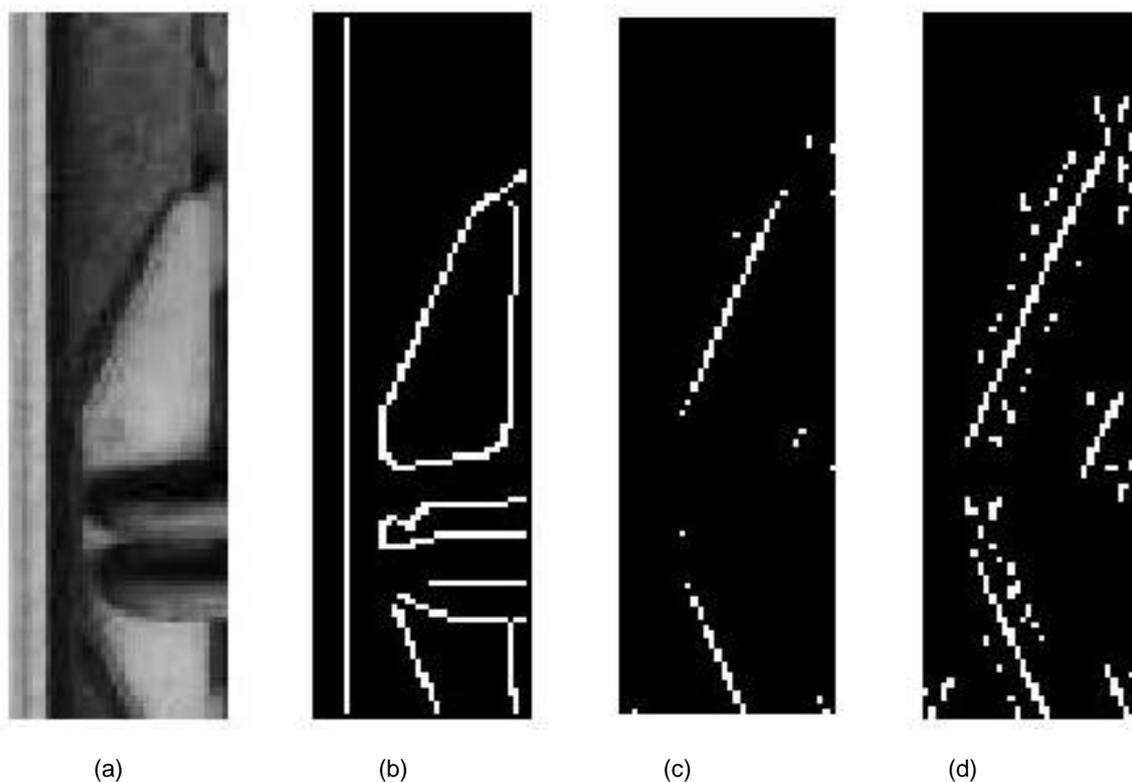
$$F2 \setminus = \begin{bmatrix} +1 & +1 & -1 & -1 & 0 & 0 & 0 & 0 \\ -1 & +1 & -1 & -1 & 0 & 0 & 0 & 0 \\ -1 & +1 & +1 & -1 & -1 & 0 & 0 & 0 \\ -1 & -1 & +1 & -1 & -1 & 0 & 0 & 0 \\ -1 & -1 & +1 & +1 & -1 & -1 & 0 & 0 \\ 0 & -1 & -1 & +1 & -1 & -1 & 0 & 0 \\ 0 & -1 & -1 & +1 & +1 & -1 & -1 & 0 \\ 0 & 0 & -1 & -1 & +1 & -1 & -1 & 0 \\ 0 & 0 & -1 & -1 & +1 & +1 & -1 & -1 \\ 0 & 0 & 0 & -1 & -1 & +1 & -1 & -1 \\ 0 & 0 & 0 & -1 & -1 & +1 & +1 & -1 \\ 0 & 0 & 0 & 0 & -1 & -1 & +1 & -1 \end{bmatrix} \quad (12)$$

Depois de aplicar os filtros, os objetos são agrupados quando apresentam conectividade 8. Por fim são considerados apenas os objetos com mais de 11 *pixels* (limite baseado em uma fração do tamanho das estruturas da almofada). Assim estão apresentados na Figura 35, para cada uma das ROIs, cada uma dessas etapas. Na primeira imagem, a imagem original da seção destinada ao patim do trilho, em seguida a detecção de borda com Canny, depois a aplicação dos filtros definidos pelas Equações (11) e (12). Por fim, definição de objetos por conectividade 8 e número mínimo de *pixels*.

Antes da definição dessas etapas para destacar as almofadas outras técnicas foram empregadas. Não apresentaram desempenho adequado por isso foram descartadas. No entanto, para enriquecer a discussão, serão apresentadas algumas delas.

A primeira tentativa foi aplicar os filtros definidos pelas Equações (11) e (12) duas vezes. O objetivo era reforçar a presença das estruturas (com determinado ângulo) e diminuir as demais estruturas e ruídos. No entanto, a aplicação de ambos os filtros, com ângulos de $+65^\circ$ e -65° , criavam muitos artefatos novos, conforme Figura 36.

Figura 36 – Aplicação dupla dos filtros cria artefatos

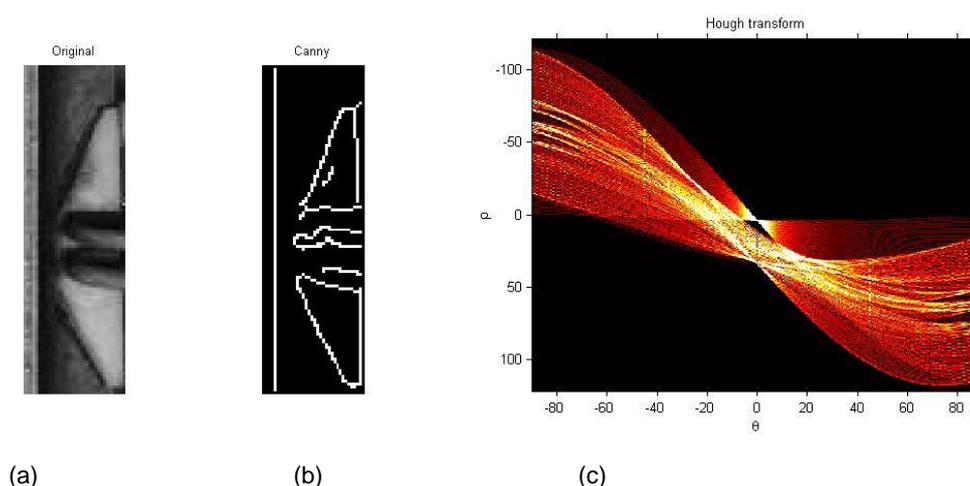


Exemplo de artefatos criados com a aplicação dupla do filtro. (a) Imagem original. (b) Aplicação do filtro Canny. (c) Primeira aplicação das máscaras. (d) Segunda aplicação das máscaras. Nota-se a criação de vários artefatos indesejáveis. Fonte: elaborado pelo autor.

A segunda ideia para reforçar a estrutura da almofada foi usar a transformada de Hough para encontrar as estruturas que pertenciam a equações lineares com fatores angulares próximos aos desejados. É tendencioso pensar que se a estrutura possui uma inclinação específica (com pouca variação) é possível obter ótimos resultados com a transformada de Hough. No entanto, o tempo para processar cada ROI com a transformada de Hough (com resolução de ρ e θ igual a 0,5), mesmo para uma região pequena (117x36 *pixels*) levava o mesmo tempo que todo o algoritmo definido até então para uma imagem de 256x576 *pixels*. Além disso retornava um número muito grande de candidatos com as características esperadas, mesmo quando não deveria (quando não havia a estrutura da almofada na imagem). Isso se dava porque ruídos e pequenas estruturas por vezes, ao acaso, alinhavam-se em retas com fatores angulares procurados. Isso não ocorreria com tanta frequência se a imagem a ser analisada fosse maior. Assim haveriam mais pontos para compor as retas procuradas. Com uma região pequena, a probabilidade de outros pontos ruidosos atrapalharem a identificação é maior.

Por exemplo, na Figura 37, percebe-se claramente a almofada presente na imagem. Na Figura 37 (a), a visão original da almofada. Na Figura 37 (b) a aplicação do filtro Canny. Na Figura 37 (c) a transformada de Hough sobre a segunda imagem. Para retas com ângulos de $\pm 65^\circ$ com o eixo horizontal são esperadas respostas significativas (cores mais claras) entre $\pm 20^\circ$ e $\pm 30^\circ$ para os valores de θ (como a orientação padrão da imagem é com o eixo vertical, temos $90^\circ - 65^\circ = 25^\circ$, além de $\pm 5^\circ$ de erro).

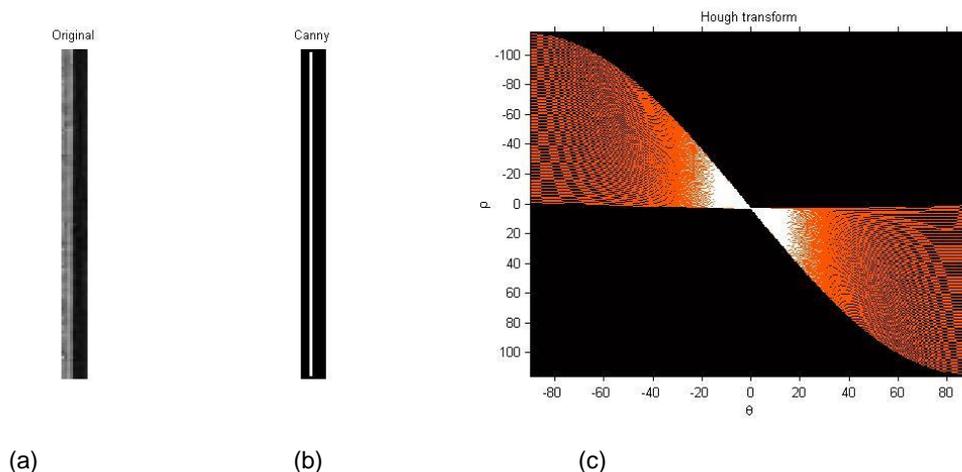
Figura 37 – Transformada de Hough sobre toda a almofada



Transformada de Hough sobre a imagem da almofada. Fonte: elaborado pelo autor.

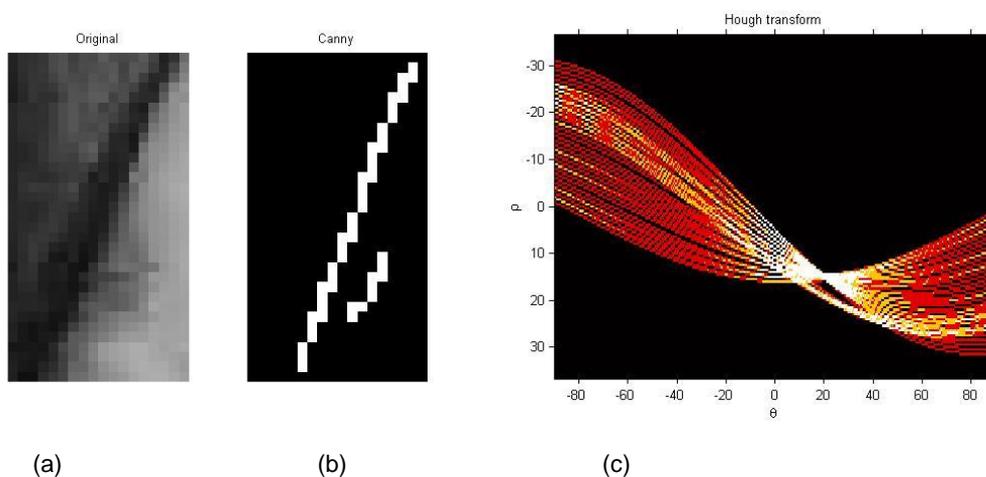
Nota-se que se forem analisados apenas segmentos específicos da Figura 37 (a), obtêm-se com a transformada de Hough uma caracterização muito boa das retas procuradas. Por exemplo, na Figura 38 foi avaliado apenas o trecho da reta vertical presente na Figura 37, caracterizado profundamente pelo θ igual a 0° ; A Figura 39, com a seção superior da almofada, caracterizada pelo θ próximo de $22,3^\circ$ (correspondente a $68,7^\circ$ com a horizontal); Na Figura 40, o θ característico próximo a $-25,7^\circ$ (correspondente a $-64,3^\circ$).

Figura 38 – Transformada de Hough para borda vertical da almofada



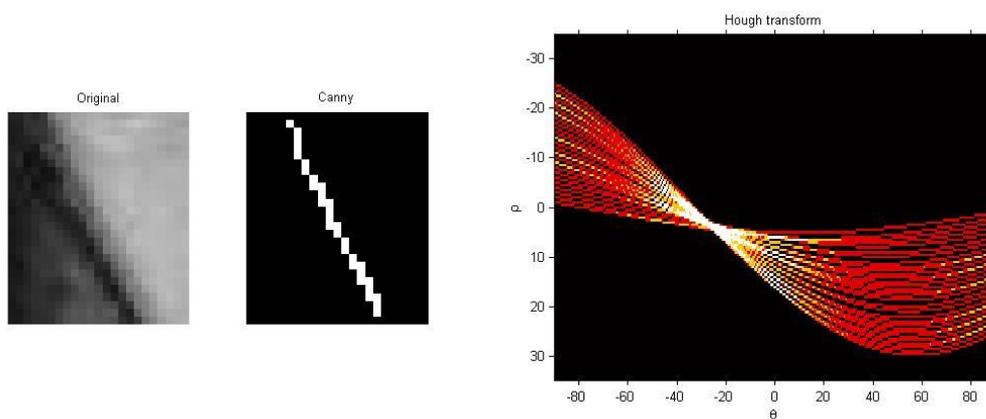
Transformada de Hough sobre reta vertical (parte da imagem original). Fonte: elaborado pelo autor.

Figura 39 – Transformada de Hough para uma borda inclinada da almofada



Transformada de Hough sobre reta inclinada (parte da imagem original). Fonte: elaborado pelo autor.

Figura 40 – Transformada de Hough sobre outra borda inclinada da almofada

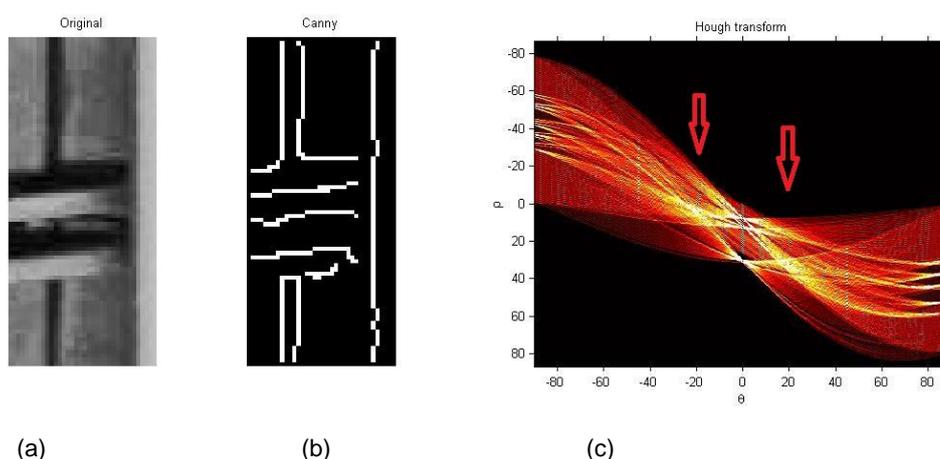


Transformada de Hough sobre reta vertical (parte da imagem original). Fonte: elaborado pelo autor.

Apesar da Figura 37 possuir componentes relevantes de θ próximos a $\pm 25^\circ$, componentes em outras posições também estão bem caracterizadas, dificultando a diferenciação de quais componentes são mais prevalentes.

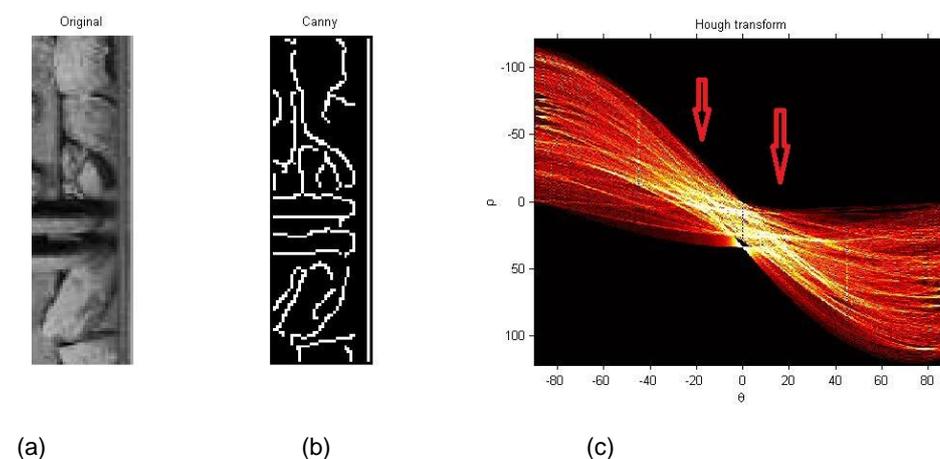
Porém, mesmo quando não há presença de almofada, aparentemente, na posição de θ próximo a $\pm 25^\circ$ aparecem componentes significativos. Conforme pode ser identificado nas Figura 41 e Figura 42, indicado pelas setas vermelhas, há componentes significativos. Estes ocorrem por coincidência de componentes que fortaleceram o ponto em θ igual a zero e tornaram a se encontrar em θ igual $\pm 25^\circ$.

Figura 41 – Transformada de Hough em imagem sem almofada



Transformada de Hough em imagem sem almofada. Forte indicação em torno de θ igual a $\pm 20^\circ$. Fonte: elaborado pelo autor.

Figura 42 – Transformada de Hough em imagem com visão da almofada oclusa



Transformada de Hough em imagem sem almofada e coberta por brita. Forte indicação em torno de θ igual a $\pm 20^\circ$. Fonte: elaborado pelo autor.

Uma terceira tentativa foi, a partir, da aplicação dos filtros definidos nas Equações (11) e (12) sobre a resposta da detecção de borda com Canny (Figura 36 (c)), reforçar as estruturas da almofada com erosão seguida de dilatação. Assim, o objetivo era descartar os ruídos e em seguida reforçar as demais estruturas que poderiam permanecer na imagem. No entanto como todas as estruturas depois da aplicação dos filtros possuíam aproximadamente a dimensão de um *pixel* de largura, após as operações de erosão todas as estruturas desapareciam.

Por fim, para destacar a estrutura característica da almofada cogitou-se em avaliar o gradiente da imagem. As bordas da almofada e sua inclinação são bem caracterizadas, portanto o gradiente esperado seria também bem caracterizado. Na Figura 43 é apresentada uma imagem de almofada e o gradiente obtido dessa imagem. Para fins de exibição, apenas serão mostrados os vetores a cada 2 *pixels* e com uma magnitude superior a 50 unidades.

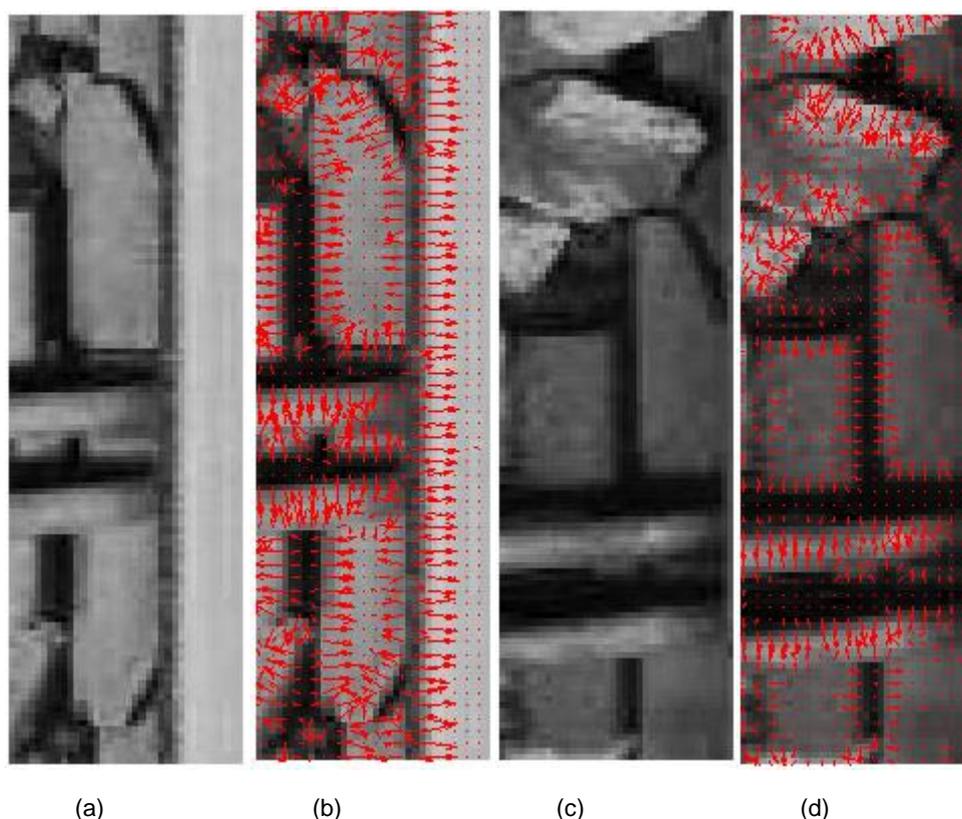
Figura 43 – Gradiente sobre a almofada



Imagem de uma almofada e seu gradiente. A estrutura inclinada da almofada está bem caracterizada pelo gradiente, com os vetores indicando a inclinação esperada. Fonte: elaborado pelo autor.

Em alguns casos o gradiente resultante sobre a estrutura inclinada da almofada não apresenta um comportamento conforme esperado, com uma inclinação específica, principalmente pela interferência de outros elementos próximos à estrutura da almofada que se deseja ressaltar. Por exemplo, quando próxima à almofada há pedras ou outras estruturas de fixação, conforme Figura 44, a resultante local dos vetores próximos à almofada não possuirá a inclinação esperada. Isso poderia ser contornado se, por exemplo, a imagem a ser analisada fosse maior e a estrutura a ser reconhecida também fosse maior. Assim a resultante do gradiente sobre determinada área, seria pouco influenciada por vetores de gradientes de outros objetos que não os da almofada. No entanto, como a almofada possui pequena dimensão e poucos *pixels* compõem a sua borda, poucos vetores de gradiente também comporão o vetor resultante e serão fortemente influenciados pelos vetores gradiente de outros objetos.

Figura 44 – Exemplos de gradientes em almofadas com presença de brita

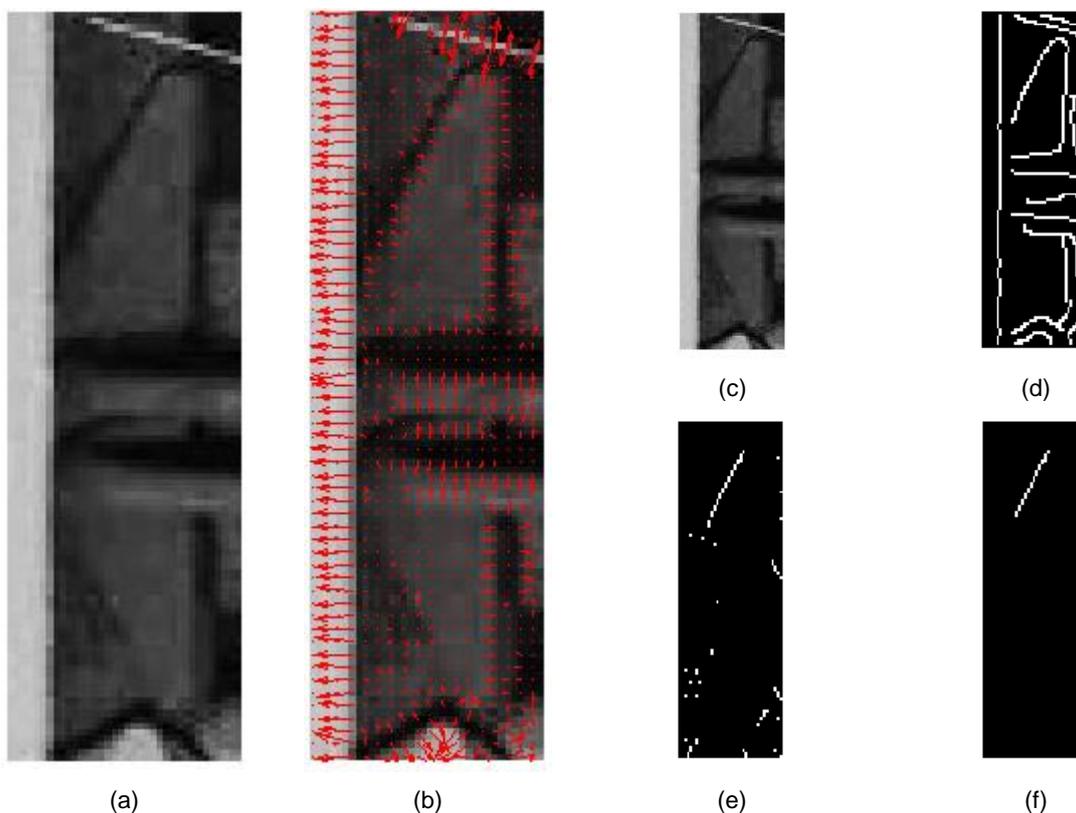


Dois exemplos de almofadas e o gradiente correspondente. Nota-se que na estrutura superior da almofada, pela presença de pedras e outras estruturas próximas, o gradiente resultante não possui a inclinação esperada. Fonte: elaborado pelo autor.

Além disso, em situações de iluminação ineficiente (contraste da imagem relativamente baixo) o gradiente não fica bem caracterizado. Na Figura 45, apesar da

borda da almofada estar visível, o gradiente não possui magnitude considerável. No entanto se utilizar os filtros definidos pelas Equações (11) e (12), a mesma imagem destaca bem a estrutura da almofada.

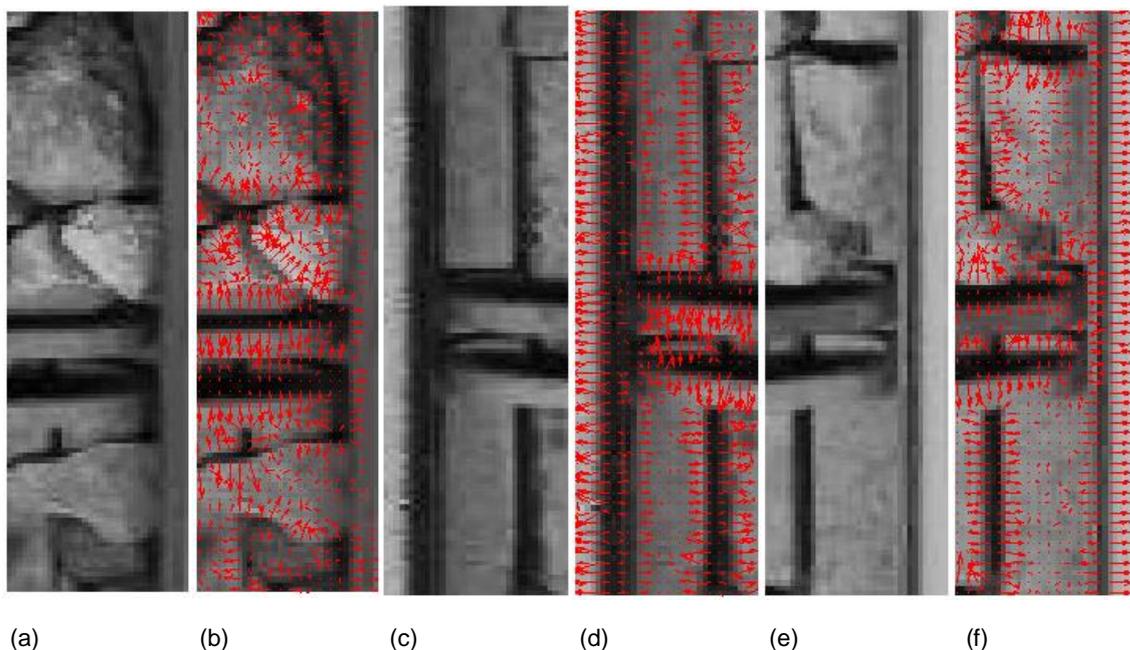
Figura 45 – Exemplo de gradiente de imagem com iluminação deficiente



(a) Almofada e (b) seu gradiente em situação de baixo contraste, a almofada não fica bem caracterizada. (c) A mesma imagem analisada (d) com filtro de borda Canny e (e, f) filtros de inclinação definidos, destacam bem a estrutura da almofada. Fonte: elaborado pelo autor.

Por fim, a análise por gradiente das imagens que não possuem almofada presentes podem apresentar resultados aleatórios para a inclinação dos vetores resultantes semelhantes as inclinações esperadas para almofadas porque qualquer forma pode ser apresentada nas imagens, conforme os exemplos da Figura 46.

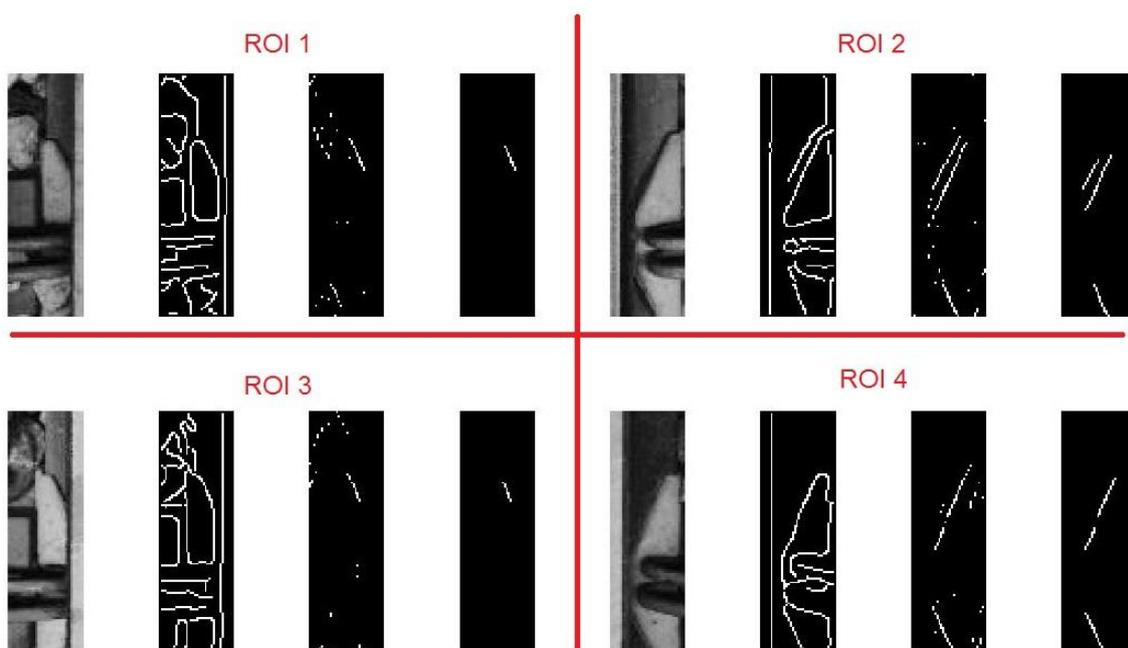
Figura 46 – Exemplos de imagens sem almofada e o respectivo gradiente resultante



Imagens sem almofada presente e os respectivos gradientes. Observa-se a aleatoriedade do gradiente resultante. Fonte: elaborado pelo autor.

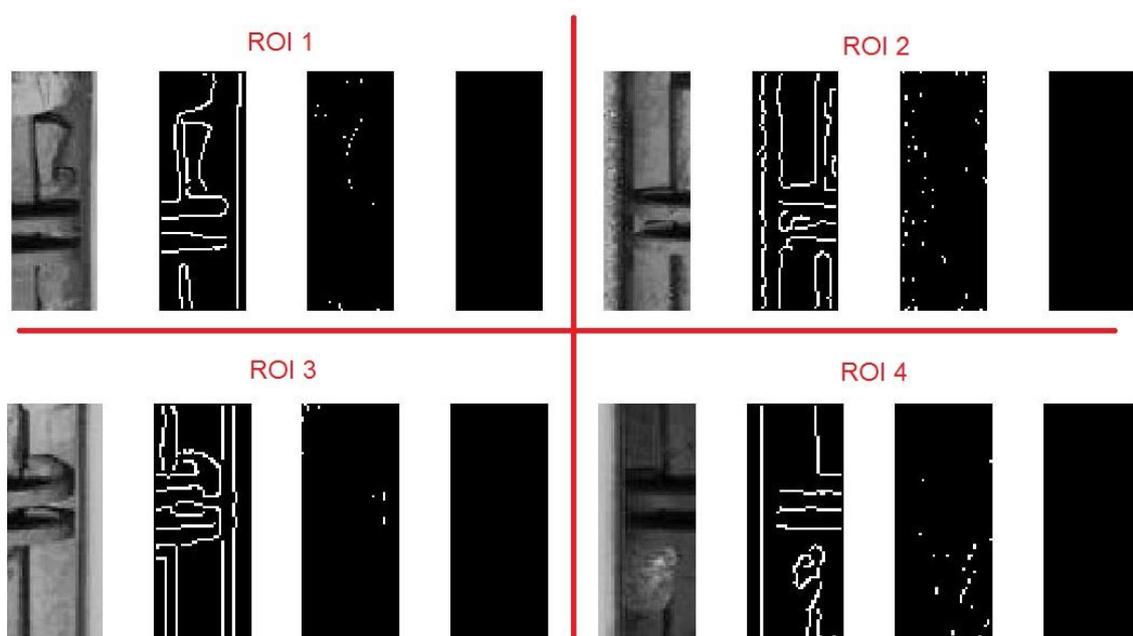
Deste modo, por tudo o que foi exposto anteriormente, a metodologia que melhor apresentou resultados para identificar a presença de almofadas foi a aplicação do filtro de borda de Canny, seguido da aplicação dos filtros definidos pelas Equações (11) e (12) e a segmentação de elementos com conectividade 8 e que possui dimensão considerável. Na Figura 47 é apresentado novamente um exemplo desse processamento para uma imagem com almofada aparente. Na Figura 48 é apresentado o mesmo processamento mas para uma imagem sem almofada presente. Nota-se que a última imagem de cada ROI é o resultado final sobre a presença ou não de almofada na respectiva ROI.

Figura 47 – Exemplo de identificação de imagem com almofada



Imagens de ROIs com almofadas presentes. Fonte: elaborado pelo autor.

Figura 48 – Exemplo de identificação de imagem sem almofada



Imagens de ROIs sem almofada visíveis. Fonte: elaborado pelo autor.

Enfim, a estratégia para definir o tipo de dormente, uma vez identificada a posição esperada do dormente (item 3 do diagrama da Figura 18) é procurar na região do patim do trilho indícios de almofada isolante (item 3.2 do diagrama da Figura 18). Em caso positivo o dormente é definido como dormente de aço. Em caso negativo,

ainda não é possível indicar nada sobre o tipo de dormente. Pode se tratar de dormente de madeira ou de dormente de aço com a almofada obstruída pelo lastro, por exemplo. Então, é preciso avaliar as superfícies dos dormentes aparentes, conforme já mencionado (item 3.1 do diagrama da Figura 18), procurando pelas características de texturas de cada tipo de dormente. Novamente, como pode haver mais de uma ROI para se avaliar, a votação é o meio de decidir o tipo do dormente que está presente na imagem.

Em resumo, as imagens da Figura 49 a Figura 54 apresentam as etapas definidas na Figura 18 para identificar o tipo de dormente da imagem:

- Figura 49 - imagem original carregada e identificação da posição do trilho (destaque em vermelho). Determinar as quatro regiões de interesse (ROIs). As ROIs indicam onde se é esperado encontrar certas estruturas como a face exposta dos dormentes, os elementos de fixação ou as almofadas;

- Figura 50 - procurar elementos de fixação dos dormentes (destaque em azul) e a influência de uma resposta positiva nas demais posições;

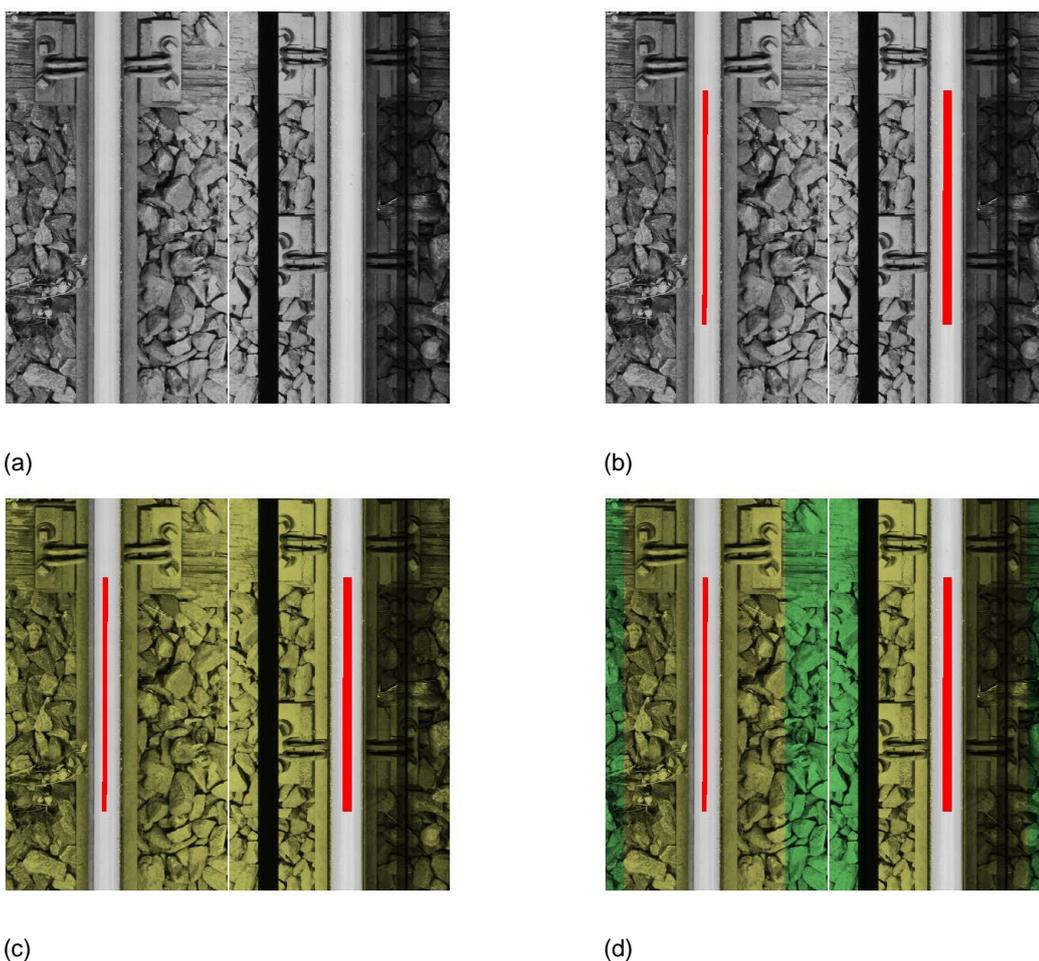
- Figura 51 - procurar texturas dos dormentes usando Entropia (em vermelho) e Sobel vertical (em verde). Para cada ROI, percorrendo as linhas vermelhas e verdes no sentido vertical, onde há uma descontinuidade é a resposta para um possível dormente encontrado. As respostas são compiladas para a região da ROI onde se espera observar a face dos dormentes e em alguns casos em uma região estendida. Nestes casos, a dimensão horizontal da ROI é tão curta que se assemelha à dimensão dos elementos da brita e por isso é preciso estender a área de análise para cima da região dos elementos de fixação, sem prejuízo na identificação da localização dos dormentes. Nesse momento a busca é pela posição, ainda não do tipo de dormente. No caso da imagem, foi preciso estender apenas a ROI 1. É fácil perceber, se comparado à imagem anterior, como a linha verde avançou sobre a fixação;

- Figura 52 - avaliar a fusão das informações de posição da fixação (em azul), textura dos dormentes (Entropia em vermelho e Sobel em verde), informações de geometria e topologia e os candidatos a dormentes (pontos amarelos) e as posições escolhidas (pontos vermelhos). Um ponto interessante nessa imagem é que, mesmo esperando dois dormentes por lado da imagem, no lado esquerdo, por falta de candidato, só foi identificado um dormente. Corroborando com o que é visualizado na imagem, ou seja, não há qualquer vestígio de dormente aparente ou fixação na área em questão;

- Figura 53 - depois de identificadas as posições dos dormentes, avaliar as texturas para identificar os dormentes oclusos, os dormentes de madeira e dormentes de aço;

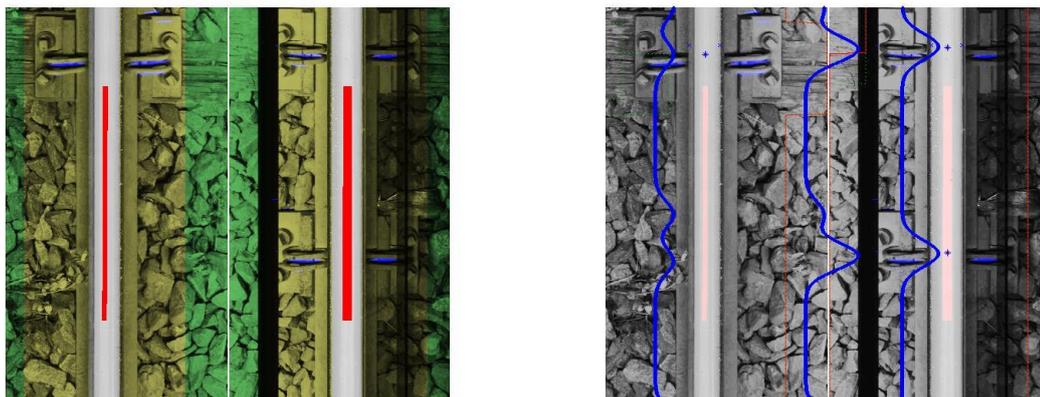
- Figura 54 - procurar a almofada característica de dormente de aço. Caso não seja identificada a almofada, para avaliação final são consideradas as avaliações de textura.

Figura 49 – Identificação dos trilhos e dos ROIs



(a) Imagem original e (b) posição identificada do trilho. (c) As 4 ROIs identificadas (em amarelo). (d) Na última imagem, dentro de cada ROI, em verde, a área correspondente a região onde estará a superfície do dormente. Na região em amarelo, a área da fixação. Fonte: elaborado pelo autor.

Figura 50 – Identificação da fixação

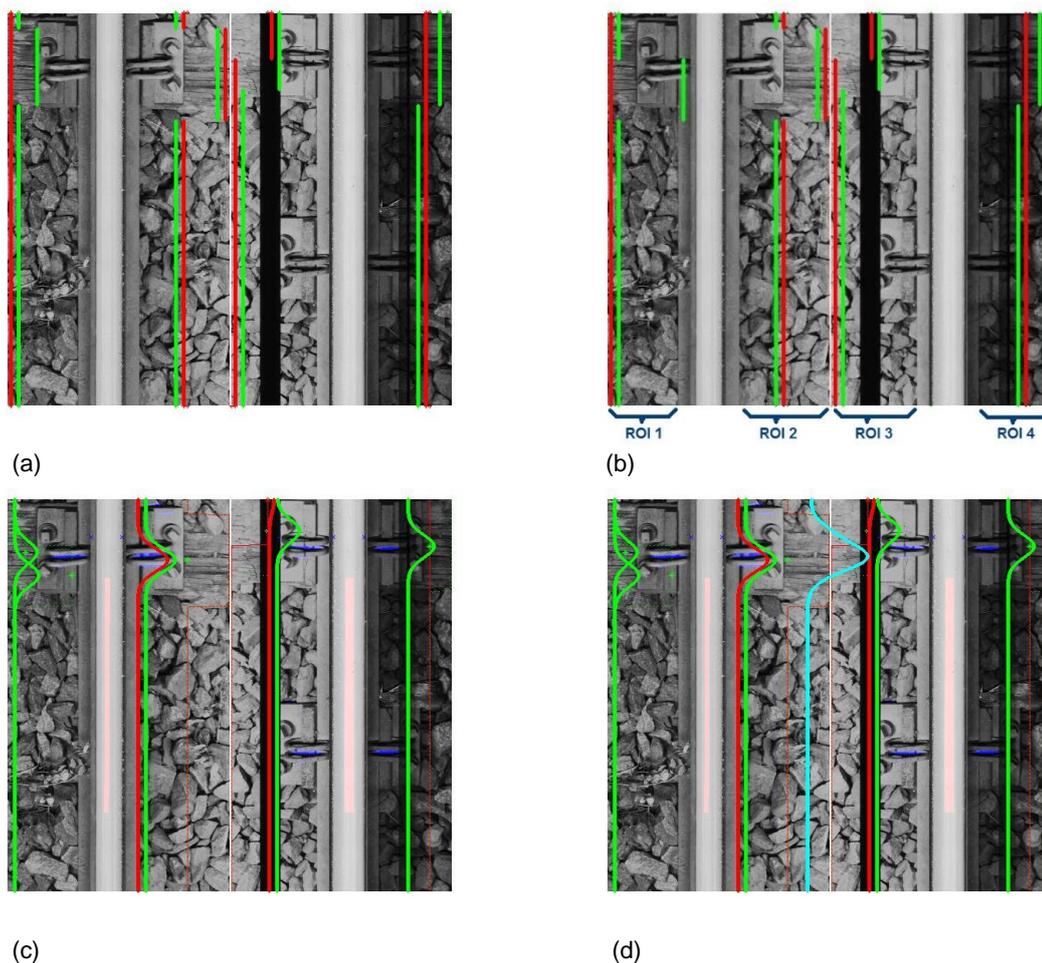


(a)

(a) Grampo de fixação em azul. Na segunda imagem (b), a contribuição de cada fixação encontrada na distribuição de probabilidade de encontrar dormentes (no trilho esquerdo, trilho direito e em toda a imagem, ao centro). Fonte: elaborado pelo autor.

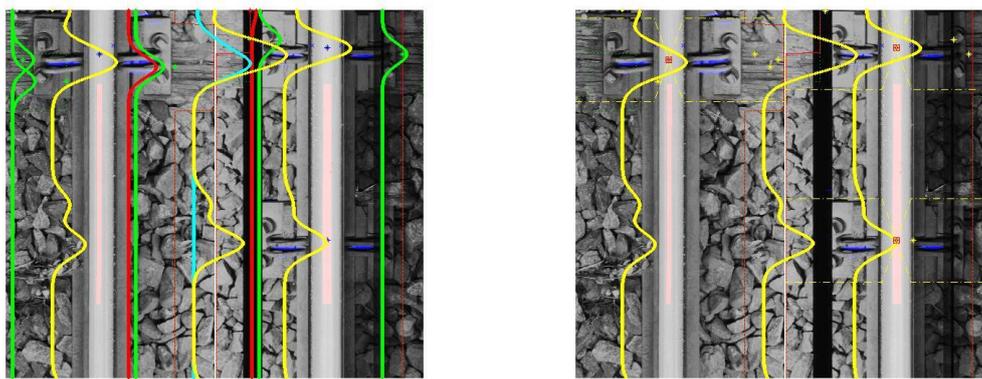
(b)

Figura 51 – Avaliação de texturas com Entropia e Sobel



(a) Avaliação Entropia (vermelho) e Sobel (verde) para encontrar dormentes aparentes, considerando apenas a região sobre os dormentes. (b) A mesma avaliação considerando agora a área estendida sobre a fixação. Note que apenas a ROI1 foi estendida, devido o comprimento do ROI. (c) Distribuição de probabilidade devido as respostas ao sensor de Entropia e ao sensor de Sobel. (d) A linha ciano é a compilação de todas as probabilidades de Entropia e Sobel. Fonte: elaborado pelo autor.

Figura 52 – Fusão de características e escolha das posições dos dormentes

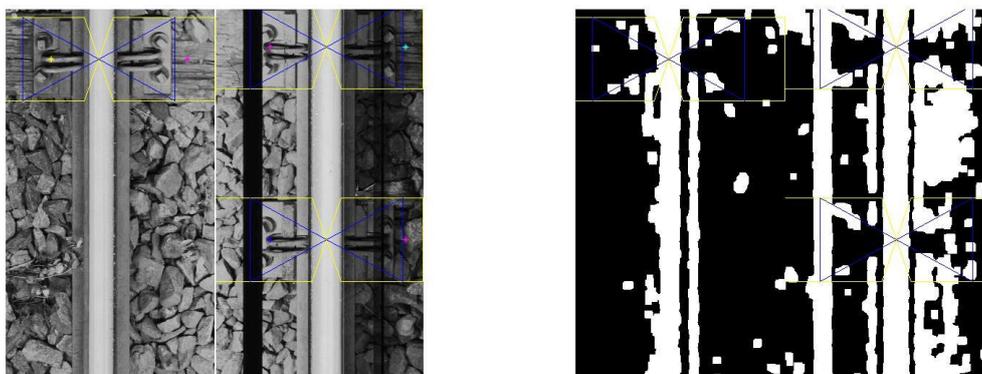


(a)

(b)

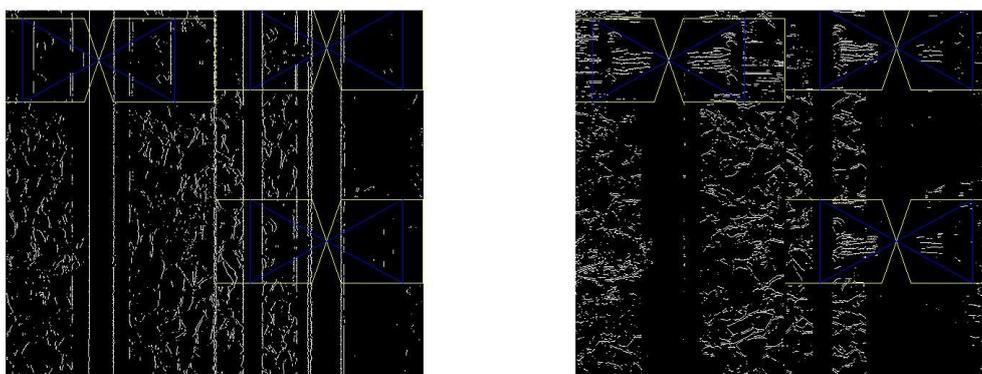
Todas as densidades de probabilidade são apresentadas, com suas respectivas cores. As curvas em amarelo são a compilação de todas as curvas (à esquerda, à direita e ao centro, considerando todas as curvas). (b) Os candidatos a centro do dormente são os pontos em amarelo. Quanto mais à direita, maior a probabilidade de ser dormente. Os pontos em vermelho são a avaliação final sobre os candidatos. Nota-se que um dos dormentes não foi encontrado porque não há qualquer evidência visível. Fonte: elaborado pelo autor.

Figura 53 – Avaliação da textura para identificar o dormente de madeira, aço ou brita



(a)

(b)

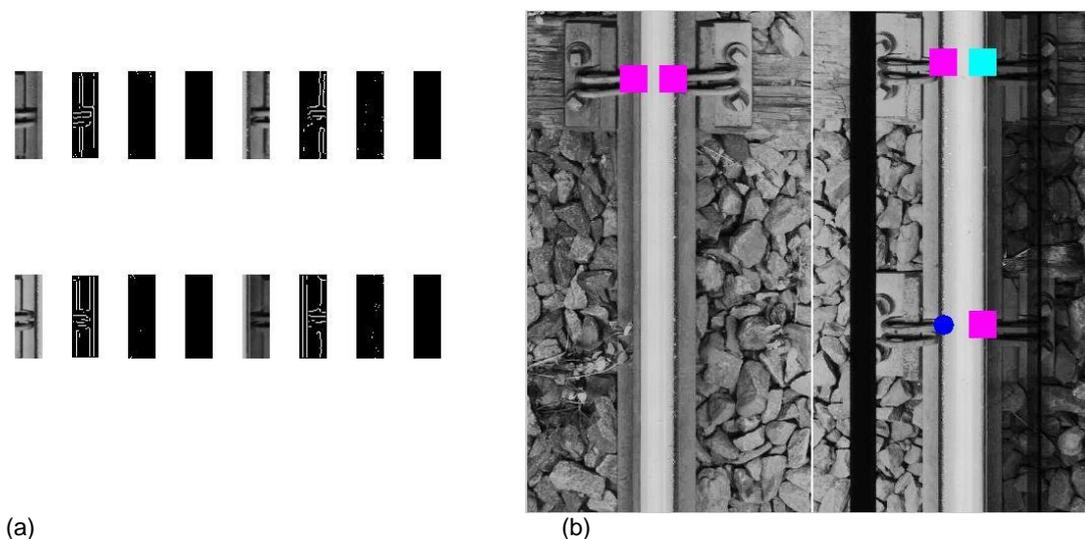


(c)

(d)

Análise de Entropia (em (b)) e Sobel Vertical (em (c)) e Sobel Horizontal (em (d)), agora apenas sobre a região do dormente. O resultado da avaliação está na primeira imagem (em (a)). Indica presença de brita, dormente de madeira ou dormente de aço. Fonte: elaborado pelo autor.

Figura 54 – Identificação de almofadas



(a) Avaliação de almofada. Nesta imagem, não foi detectada almofada. (b) O resultado final indica que os dormentes são de madeira pela votação de cada dormente identificado: madeira (quadrado magenta), quadrado ciano (aço), círculo azul (brita). Fonte: elaborado pelo autor.

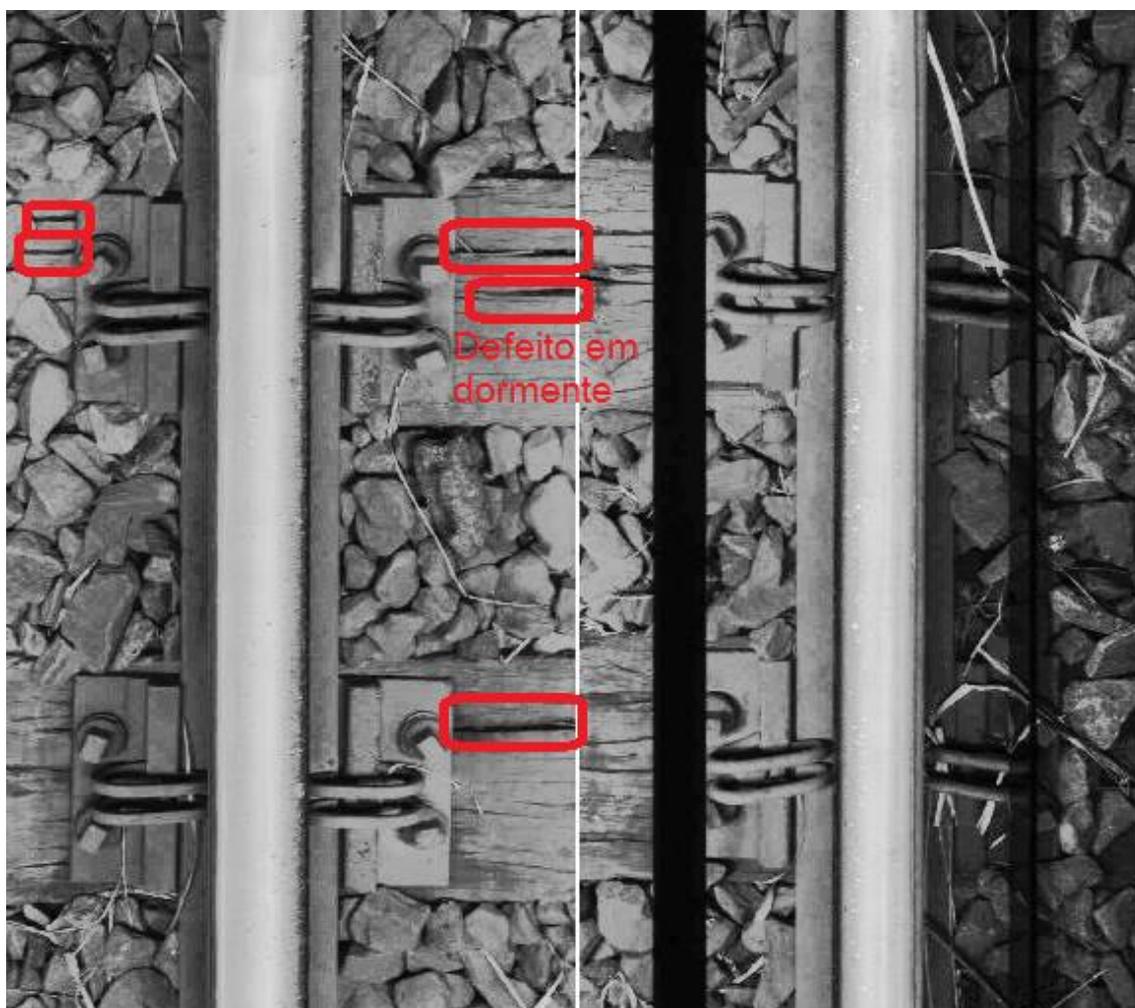
2.4 Avaliando a qualidade dos dormentes

É sabido que a avaliação dos dormentes através das imagens disponíveis é restrita aos problemas que ocorrem na superfície. Há casos em que os dormentes de madeira apresentam uma camada superficial em perfeito estado, mas seu interior ou a porção abaixo do lastro está apodrecido ou comprometido, dando a falsa impressão visual de dormente de boa qualidade. Há outras formas de avaliar a qualidade dos dormentes, neste caso. Há propostas com avaliação acústica como em Yella, Ghiamati e Dougherty (2009) e Wang, Zhang e Lie (2017). Mas nada muito prático de modo a substituir a avaliação humana. No caso de dormentes de aço a qualidade pode ser afetada por microfissuras não visíveis, detectáveis normalmente por análise de ultrassom.

Apesar disso, uma quantidade grande de defeitos pode ser identificada com a inspeção visual dos dormentes. A forma como os defeitos se manifestam depende intrinsecamente do tipo de dormente. Dormentes de madeira podem apresentar falhas entre os nós naturais da madeira, que geralmente se apresentam no sentido longitudinal da madeira (horizontal). Esses defeitos ocorrem principalmente devido à ação de fungos ou insetos na matéria orgânica do dormente ou pelo esforço de tração dos *tirefonds* e parafusos sobre os furos feitos no dormente, diante da dinâmica da

movimentação. Acidentes ferroviários podem causar defeitos também na superfície dos dormentes. A Figura 55 mostra dormentes de madeira com defeitos.

Figura 55 – Defeitos em dormentes de madeira



Defeitos em dormente de madeira circundados em vermelho. Fonte: elaborado pelo auto.

Das imagens avaliadas pode-se perceber características comuns a estes defeitos:

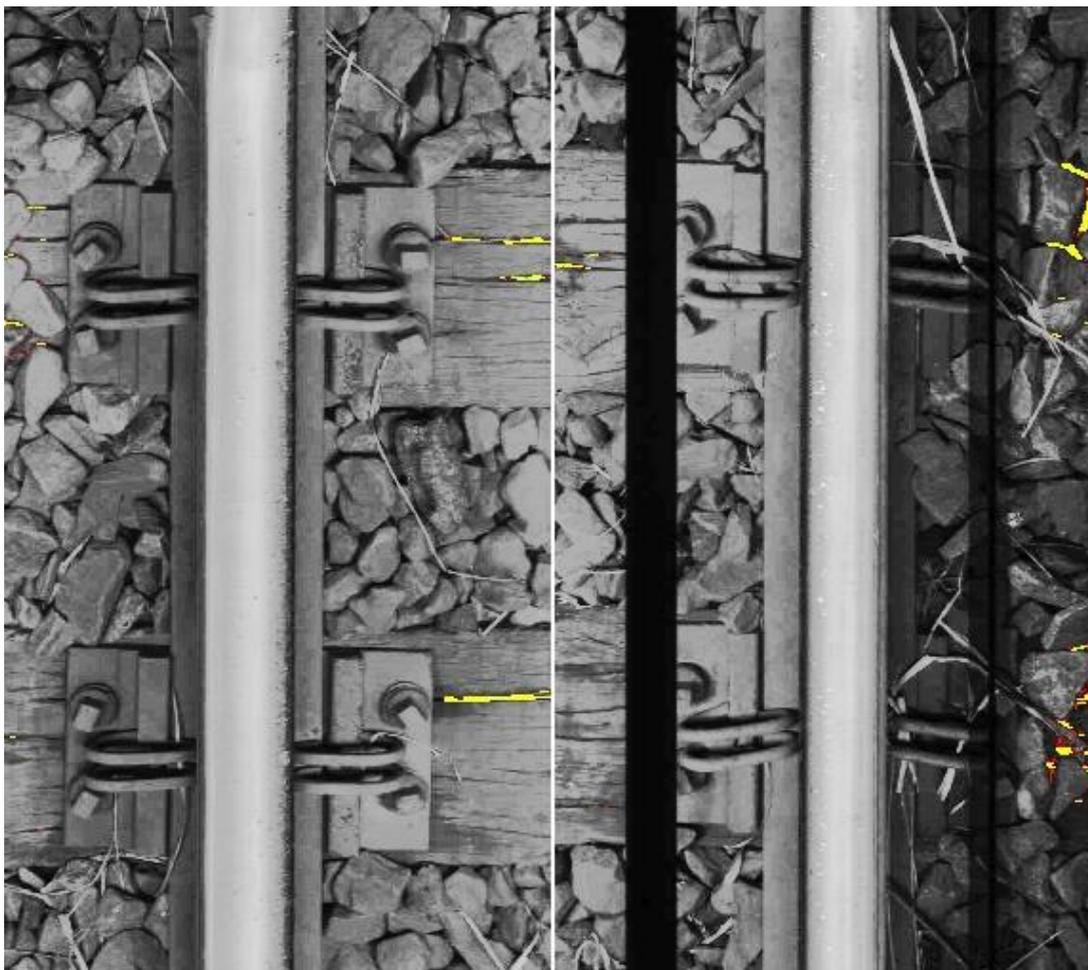
1. Característica 1 - os defeitos se apresentam como cavas ou falhas profundas. Em termos da imagem são regiões escuras;
2. Característica 2 - predominantemente se apresentam no sentido horizontal;
3. Característica 3 - a dimensão horizontal da falha é muito maior que dimensão vertical;

4. Característica 4 - a dimensão vertical possui um valor mínimo, para ser considerada defeito.

Estas características serão decisivas para identificar os defeitos em dormentes de madeira dentre os possíveis candidatos.

Para definir os possíveis candidatos, basta identificar as regiões contínuas e escuras sobre a região definida para o dormente. O conceito de escuro é relativo à iluminação de cada ROI. Cada ROI pode possuir um nível de iluminação diferente devido à iluminação deficiente em algumas ROIs, sombras ou iluminação natural direcionada no nascer ou pôr do Sol. Ou seja, o limite de escuro de cada ROI pode ser definido, por exemplo, por uma proporção da média dos valores de toda a ROI. Claro que só são avaliados candidatos sobre a região previamente identificada como dormente. Por fim, os vários elementos escuros são agrupados pela conectividade 4 para identificar um único candidato. Os candidatos podem ser observados na Figura 56.

Figura 56 – Candidatos a defeitos



Candidatos a defeito em dormente, ainda passarão por outras avaliações para a efetiva classificação.
Fonte: elaborado pelo autor.

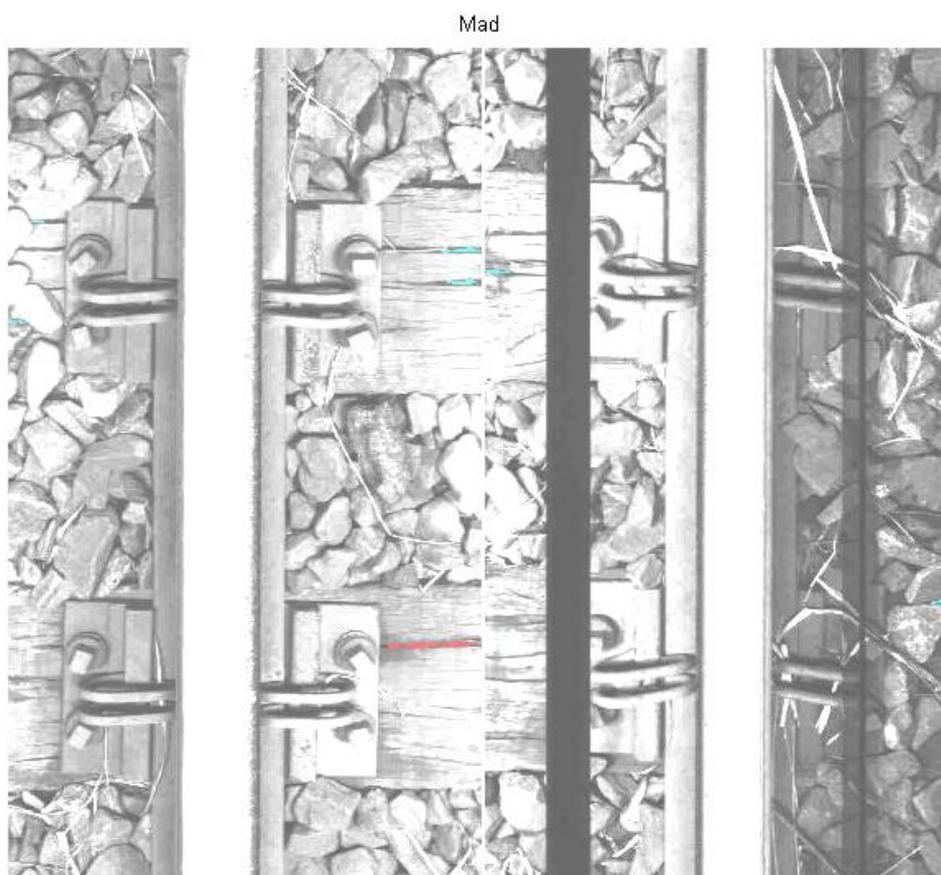
Os candidatos até então identificados concordam com a Característica 1 definida. Os defeitos se apresentam como regiões escuras. As demais características serão garantidas pelas seguintes regras definidas empiricamente:

1. A reta que melhor representa todos *pixels* de um candidato (por regressão linear) possui inclinação entre $\pm 20^\circ$ com a horizontal (Característica de defeito 2);
2. A dimensão horizontal de um candidato deve ser, ao menos, 4 vezes maior que a dimensão vertical. (Corrobora com a Característica de defeito 3);
3. A dimensão vertical deve ser de pelo menos 3 *pixels*. (Característica de defeito 4);

4. A dimensão horizontal deve ser pelo menos um terço da dimensão horizontal da ROI analisada. Assim são identificadas grandes áreas de defeitos e excluídos alguns falsos positivos.

Todos estes itens, de certa forma reforçam as características dos defeitos. Se os candidatos atendem a todas as 4 regras, a detecção de defeito é mais assertiva e é marcada na imagem com a cor vermelha. Caso o candidato atenda apenas as regras 1, 2 e 3, o candidato será marcado com a cor verde. E por fim, caso o candidato responda positivamente para as regras 1, 2 e 4, será marcado com a cor azul (ciano). Assim, há um indício da ordenação da probabilidade de ocorrência dos defeitos. A Figura 57 apresenta o resultado final com os defeitos identificados.

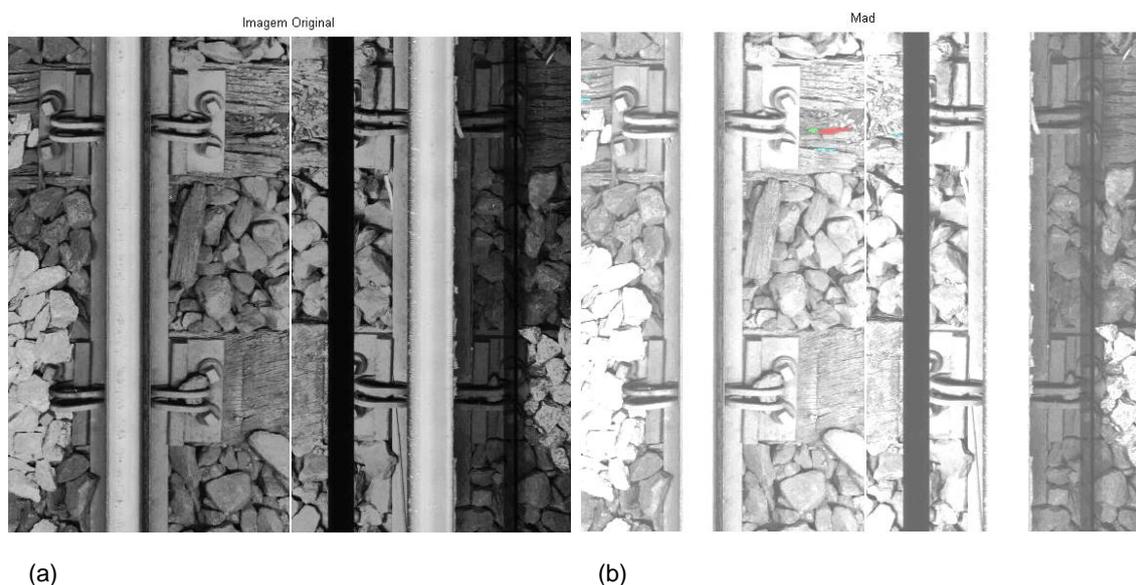
Figura 57 – Defeitos identificados nos dormentes de madeira



Defeitos identificados nos dormentes. As várias cores indicam graus de assertividade sobre os defeitos. A figura foi propositalmente clareada para melhor identificar as marcações. Fonte: elaborado pelo autor.

Outro exemplo de identificação de defeitos é apresentado na Figura 58. Notam-se identificações com as cores diferentes: vermelho para o caso quando atende a todas as 4 regras; verde para o caso quando apenas o defeito não toma boa parte da ROI (não atende a Característica 4); azul (ciano) para quando não é especificado espessura mínima da abertura do nó da madeira (não atende a Característica 3).

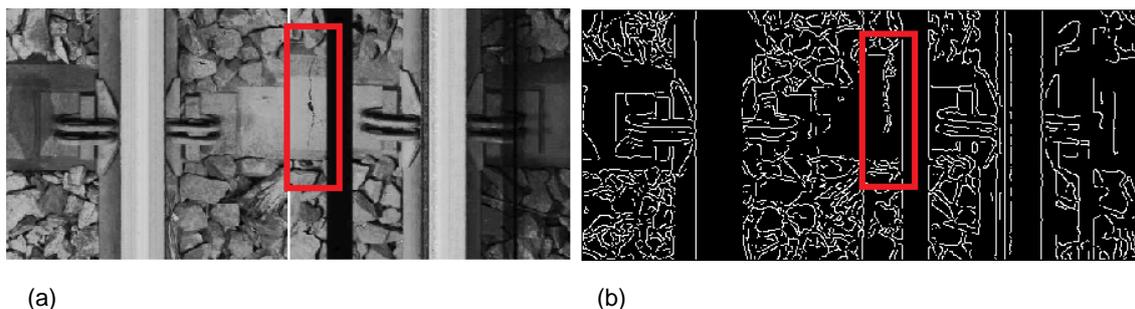
Figura 58 – Exemplos de defeitos em dormentes de madeira



(a) Imagem original e (b) defeitos identificados segundo sua prioridade. A imagem foi propositalmente clareada para realçar as regiões em cores: vermelho, verde e ciano. Fonte: elaborado pelo autor.

Portanto os defeitos em dormentes de madeira são identificados e este esquema de cores representa a confiabilidade da identificação dos defeitos em dormentes. Quando a identificação é em vermelho, maior é a confiança na identificação do defeito. Quando em verde e posterior em azul (ciano) menor é a confiança nessa identificação, pois suprime a observação de algumas das regras definidas. No capítulo seguinte serão apresentados os resultados e desempenhos do algoritmo.

Figura 59 – Defeito em dormente de aço



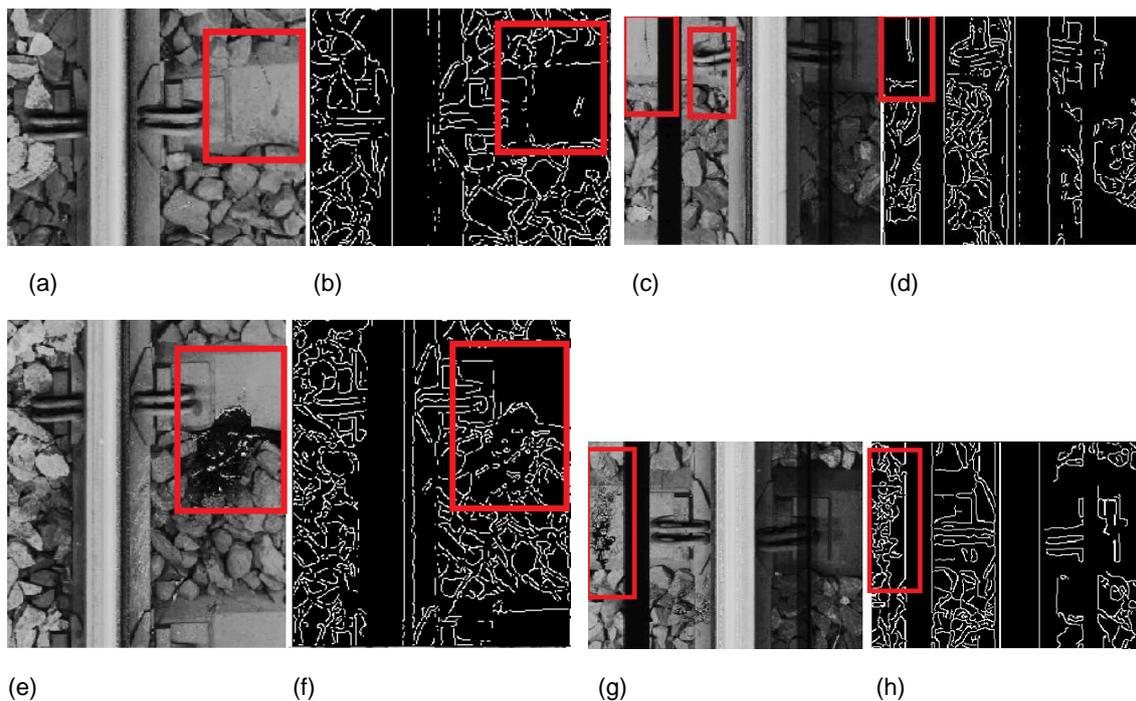
(a) Imagem com defeito no dormente de aço. (b) Segmentação de borda com Canny para melhor definir os contornos. Fonte: elaborado pelo autor.

Para o caso de dormentes de aço, dentre todas as imagens do banco de dados, apenas uma imagem apresentava defeito superficial no dormente de aço (Figura 59). O defeito manifestou-se como uma trinca no aço no sentido transversal do dormente. Em boa parte do dormente aparente não há qualquer outra marca na vizinhança, apenas o segmento da trinca com intensidade de brilho levemente mais escuro. No entanto, uma única imagem não é suficiente para determinar as características dos defeitos que podem vir a aparecer. O formato, tamanho e disposição desse defeito é difícil de prever ou segregar. Esses parâmetros variarão conforme a causa do defeito e mesmo do material do dormente. Sabe-se que podem aparecer devido a acidentes ferroviários, uso contínuo inapropriado ou decorrente da formação de microfissuras internas ou externas no material durante o processo de fabricação; ou ainda por uma combinação desses fatores. Dadas as características aleatórias que o defeito pode aparentar e as miríades de configurações de outras estruturas que podem estar na superfície do dormente será difícil diferenciar um defeito deste com, por exemplo, brita sobre o dormente que forma sombra, um resto de vegetação, um rastro de líquido que desprende do dreno vagão, conforme Figura 60, Figura 61 e Figura 62. Cada imagem, que evidencia um exemplo descrito anteriormente, possui a sua correspondente segmentação de borda usando Filtro de Canny para identificar melhor os objetos em questão e facilitar a comparação das características dos objetos destacados com as características do defeito no dormente de aço da Figura 59.

Nota-se que é muito simples obter características semelhantes como formato, cor (tons de cinza), intensidade, dimensões e textura. Humanamente, consegue-se distinguir (ou estimar razoavelmente) as ocorrências entre trincas ou manchas de óleo, sombras e vegetação pois leva-se em conta experiências pregressas sobre como cada item se comporta no mundo real. Por exemplo, um filete de óleo que se

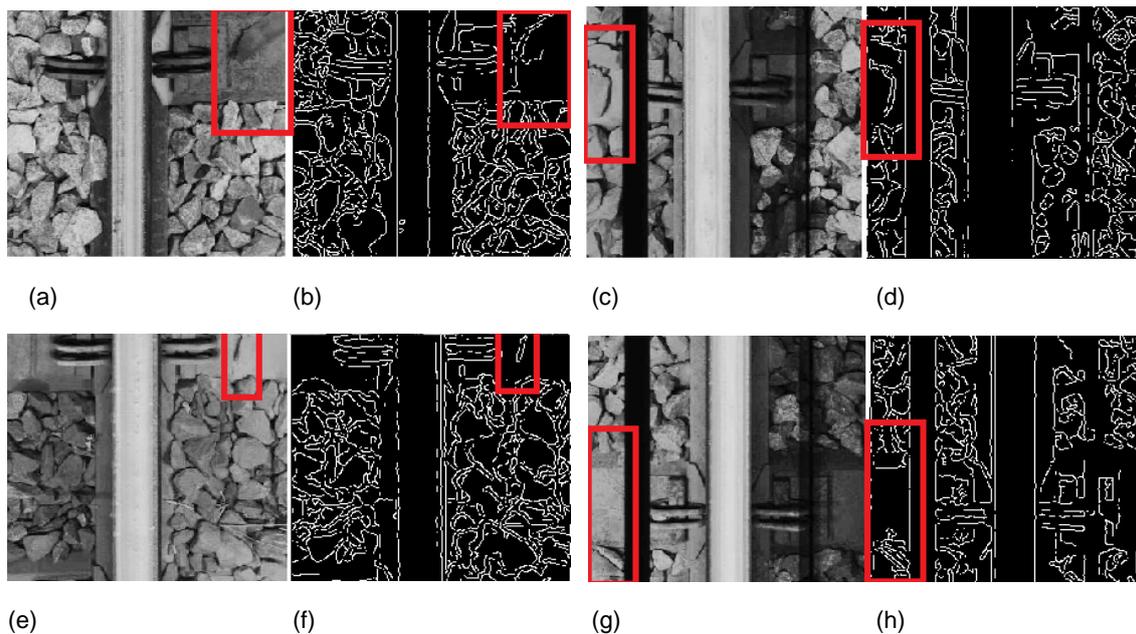
desprende do vagão e pinga sobre o dormente, é facilmente identificado pelos seres humanos pois, é possível observar o mesmo padrão de rastros continuando sobre a brita (na Figura 60 (a) há um exemplo acima do dormente) e, a partir daí, criativamente imagina-se a cena do óleo derramando continuamente sobre o dormente e depois sobre a brita e compreende-se a dinâmica da formação da imagem. Isso faz dos seres humanos fantásticas máquinas para identificação de padrões.

Figura 60 – Exemplos de dormentes com manchas de líquidos



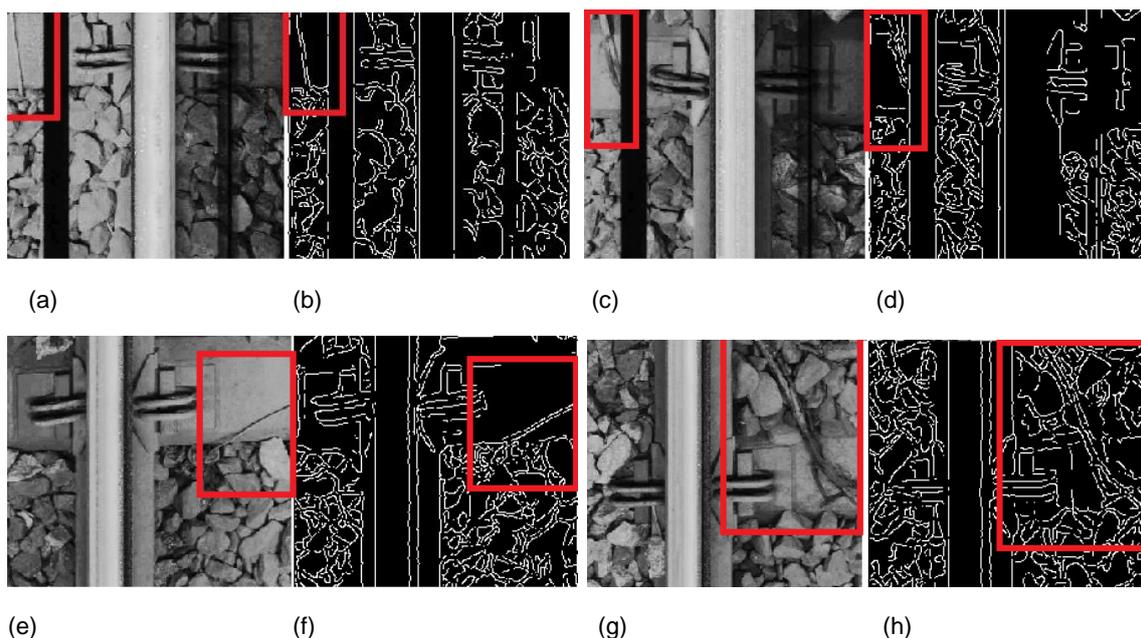
Imagens com manchas de líquidos sobre os dormentes. Fonte: elaborado pelo autor.

Figura 61 – Exemplos de dormentes obstruídos parcialmente por brita



Imagens com sombras de brita e outros elementos que poderiam confundir o algoritmo ao procurar trincas superficiais nos dormentes. Por vezes a textura e as intensidades de brilho da brita não diferem das mesmas características do dormente. Fonte: elaborado pelo autor.

Figura 62 – Exemplos de dormentes com vegetação



Vegetação sobre os dormentes geram perfis semelhantes aos gerados por trincas. Considere também que a vegetação pode assumir coloração escura e se assemelhar aos defeitos procurados. Fonte: elaborado pelo autor.

Portanto, com essas imagens não é possível identificar esse tipo de defeito superficial para dormentes de aço. Inevitavelmente, a quebra de dormentes de aço causa outro atributo na via que facilmente é percebido por outros sensores. A quebra

parcial ou total de um dormente de aço causa abertura de bitola. Ditosamente este item é controlado com bastante rigor em ferrovias de forma automática dada a sua importância para a segurança, por exemplo, pelos sensores lasers já apresentados do carro controle. Portanto o problema não ficará descoberto e potencialmente negligenciado.

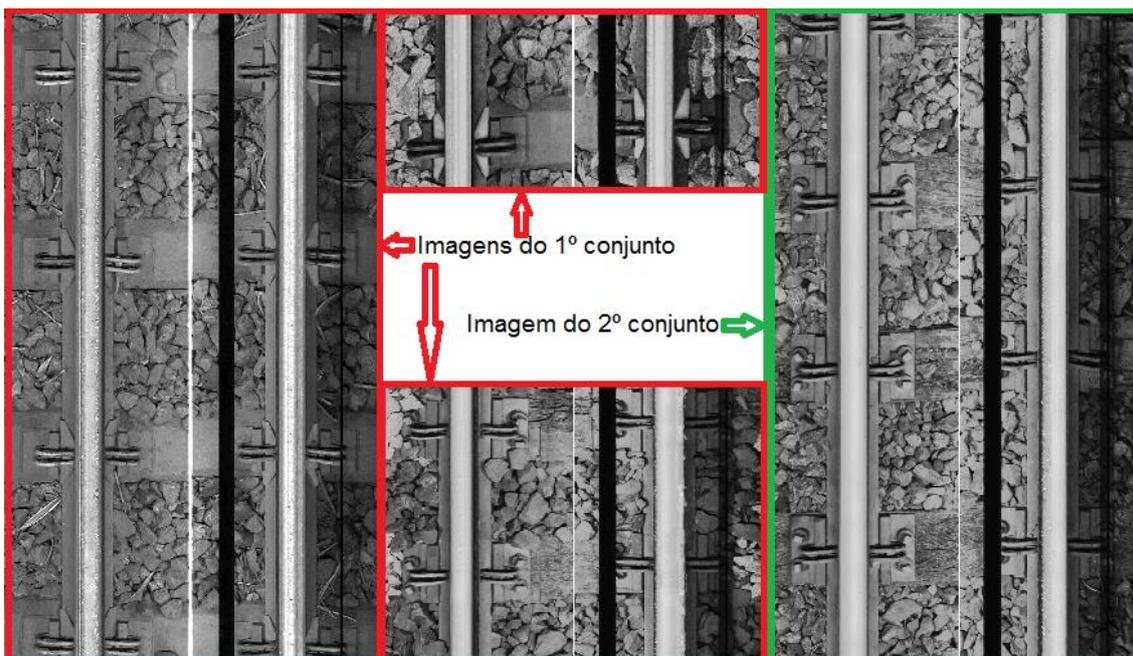
3 DESEMPENHO E RESULTADOS

O sistema de visão do carro controle é formado por duas câmeras *line scan* (câmeras de varredura em linha - captam um vetor de *pixels* por frame e permite melhor sensibilidade e fidelidade a alta velocidade) montadas sobre a estrutura do veículo ferroviário e apontadas verticalmente para baixo, de forma que o seu campo visual principal capture as superfícies horizontais dos trilhos (boletos), elementos de fixação (grampos, placas de fixação, almofadas), parte dos dormentes e do lastro próximos aos trilhos. A distância entre a câmera e o topo do boleto é de 37 cm. A iluminação do sistema de visão é dada por iluminação contínua de lâmpadas halógenas. O processamento é realizado posteriormente à aquisição das imagens em notebook comum, de uso pessoal, com sistema operacional Windows 8 Enterprise 64 bits, processador Intel Core i7-363QM 2,2Ghz e 8Gb de memória RAM. O computador possui placa de vídeo dedicada NVIDIA GeForce GT 630M, mas nenhuma instrução foi especificamente desenvolvida para rodar com aceleração de processamento.

O algoritmo foi implementado em plataforma Matlab (2013a) 64bits utilizando a toolbox de processamento de imagens (*Image Processing Toolbox*). A escolha do Matlab para a implementação deu-se pela facilidade de manipulação, depuração e prototipagem do algoritmo.

As imagens disponíveis e que foram utilizadas para o desenvolvimento do algoritmo são provenientes de dois bancos de imagens reais obtidos em momentos diferentes, ou seja, foram obtidas em viagens diferentes do veículo ferroviário. Isso foi planejado para adquirir imagens em diferentes condições de iluminação natural e de condições do equipamento. Isto tanto é verdade que se pode notar a diferença de iluminação entre imagens dos dois conjuntos de imagens na Figura 63. No primeiro conjunto há imagens de três tamanhos padrões (geralmente com um, dois ou quatro dormentes) distribuídos aleatoriamente. Os defeitos recorrentes de faixas verticais escuras são comuns a todas as imagens. Em particular na imagem do segundo conjunto, a região da ROI 4 é ligeiramente mais escura que as demais ROIs pois há deficiência na iluminação natural (está ao entardecer) e na iluminação artificial (foi obtida meses depois que o primeiro conjunto de imagens e o sistema de iluminação estava defeituoso).

Figura 63 – Exemplos de imagens dos dois conjuntos de dados



Fonte: elaborado pelo autor

As características dos bancos de imagens estão listadas na Tabela 6.

Tabela 6 – Características dos conjuntos de imagens

Banco de dados	Tamanho das imagens	Quantidade de imagens	Quantidade de dormentes	% dorm. de Madeira	% dorm. de Aço
Conjunto 1		2.882	3.981	71%	29%
	256 x 576	67%	1/imagem	66%	34%
	512 x 576	30%	2/imagem	79%	21%
	1024 x 576	3%	4/imagem	65%	35%
Conjunto 2	1024 x 576	7.234	28.936	17%	83%

Fonte: elaborado pelo autor

O Conjunto 1 foi utilizado para desenvolver e testar o algoritmo. Este foi o conjunto disponível desde o início do projeto. O segundo conjunto foi obtido alguns meses depois, continham imagens sequenciais e que se dispostas uma após a outra comporiam, sem qualquer lacuna, a via férrea completa. Esse conjunto foi utilizado apenas para o teste final do algoritmo. Os dois conjuntos contêm imagens submetidas

a iluminações diferentes pois foram obtidos em momentos do dia distintos e também porque no segundo conjunto parte do sistema de iluminação artificial estava avariado, causando iluminação diferenciada na ROI 4 (seção à direita do trilho direito).

É essencial haver dois conjuntos de dados separados para desenvolvimento e testes. Pois assim evita-se o efeito de *overfitting* (sobreajuste) dos dados ao modelo. Caso contrário, o modelo ou algoritmo só responderia bem aos mesmos conjuntos de dados. Quando fosse submetido a dados distintos poderia não obter uma resposta satisfatória.

A avaliação de desempenho do algoritmo se dará nas duas funcionalidades propostas: identificar o tipo do dormente da imagem e se há defeito no dormente. A identificação do tipo de dormente é bem clara, mesmo para leigos, devido às experiências pregressas e a forma esperada dos dormentes. Além disso, como as imagens com um mesmo tipo de dormente estão agrupadas numa sequência ao longo da via (na maior parte das vezes), é fácil separar o conjunto de imagens pelo tipo de dormente, mesmo para um conjunto de 3.000 ou 7.000 imagens. No entanto, a identificação dos defeitos é definida por um público especialista que, com base em experiência, determina a ausência ou presença de defeitos e sua gravidade. Principalmente por causa dessa avaliação especializada não é possível avaliar todo o conjunto de dados para determinar a assertividade do algoritmo. Para tanto, é preciso determinar o número de amostras aleatórias a serem avaliadas e que poderão indicar o desempenho do sucesso do algoritmo.

Para determinar a quantidade de amostras, é preciso caracterizar a população, o conjunto de imagens disponíveis. O aspecto a ser avaliado é presença de defeito ou não, portanto um atributo (ou variável categórica, ao contrário de uma variável quantitativa). A população é formada por dados não-pareados, que não são dados sucessivos ou apresentam a evolução de uma situação (antes e depois, por exemplo). A proporção p da presença de defeitos é uma importante informação e é diferente nos dois conjuntos de dados, porque além de depender do tipo de dormente (o motivo já foi apresentado no capítulo anterior) é também uma questão situacional e não irá se comportar de forma semelhante em qualquer outro conjunto de dados. Está intimamente ligado ao nível de manutenção da via, exposição a intempéries e ocorrência de acidentes. Para exemplificar, o primeiro conjunto de dados possui, à primeira vista (segundo o algoritmo ao avaliar todos os dois conjuntos de imagens), 74% das imagens com dormentes de madeira com defeito; O segundo conjunto

apresenta 96% dos dormentes de madeira defeituosos. A resposta do algoritmo é uma boa estimativa para a proporção populacional \hat{p} . Para estimar utilizando o pior caso, pode-se tomar $\hat{p} = 50\%$, na ausência de dados a priori.

Enfim, tomando como base a Equação (13) para determinar o tamanho da amostra considerando a estimativa da proporção populacional (WEYNE, 2004) e considerando ainda que a população é finita (e realmente é) e que o erro máximo dado pela amostragem será de 10% têm-se:

$$n = \frac{N \cdot \hat{p} \cdot \hat{q} \cdot (Z_{\alpha/2})^2}{\hat{p} \cdot \hat{q} \cdot (Z_{\alpha/2})^2 + (N - 1) \cdot E^2} \quad (13)$$

Onde

n : Número de amostras da população

N : Número de elementos da população

\hat{p} : Proporção populacional do atributo

\hat{q} : Proporção populacional do não – atributo. $\hat{q} = (1 - \hat{p})$

$Z_{\alpha/2}$: Valor crítico do grau de confiança. 1,96 para 95% de confiança

E : Erro máximo de estimativa.

Tomando o erro máximo de estimativa como a diferença entre a proporção amostral e populacional igual a 10% significa dizer que a diferença entre o atributo procurado na amostra e na população será no máximo de 10% com um grau de confiança de 95%. Portanto os parâmetros para estimativa do tamanho do conjunto de amostras para cada um dos conjuntos são apresentados na Tabela 7.

Tabela 7 – Estimativa do número de amostras

Banco de dados	N	\hat{p}	$Z_{\alpha/2}$	E	n
Conjunto 1	2.862	74%	1,96	10%	73
Conjunto 2	4.912	96%	1,96	10%	16

Fonte: elaborado pelo autor

Para o Conjunto 2, como quase 96%, em uma estimativa inicial, são dormentes de madeira defeituosos, bastavam 16 dormentes para avaliar como amostra. No entanto, para aumentar a chance de se observar também dormentes sem defeito na amostra, optou-se por considerar a proporção de 50% (que era um número estimado inicialmente) de dormentes de madeira com defeitos. Dessa forma o número de amostras passa a ser 94 amostras. Claro que se trata de 73 e 94 amostras de dormentes de madeira em uma população que possui dormentes de madeira e de aço. Portanto é preciso tomar mais amostras aleatoriamente no universo disponível para alcançar o número de amostras desejadas de dormentes de madeira. Essa quantidade de amostras foi definida para avaliar a classificação de defeitos em dormentes de madeira. No entanto, também será utilizada para avaliar a classificação do tipo de dormente, que é menos restritiva que a classificação de defeitos, que ocorre apenas nos dormentes de madeira. Na verdade, por motivo que será apresentado a frente, será possível apresentar também a classificação do tipo de dormente em todos os dois conjuntos de imagens.

Portanto, para alcançar a quantidade necessária de amostras de dormente de madeira (73 e 94), respectivamente, nos Conjuntos 1 e 2 de imagens foi preciso avaliar 69 e 157 imagens com dormentes de madeira e aço. Na Tabela 8 são apresentados os perfis das amostras selecionadas aleatoriamente.

Tabela 8 – Características das amostras aleatórias

Banco de dados	Tamanho das imagens	Quantidade de imagens	Quantidade de dormentes	Prop. dorm. de Madeira	Prop dorm. de Aço
Conjunto 1		69	102	72% (73)	28% (29)
	256 x 576	58%	1/imagem	53% (21)	47% (19)
	512 x 576	39%	2/imagem	89% (48)	11% (6)
	1024 x 576	3%	4/imagem	50% (4)	50% (4)
Conjunto 2		157	551	17% (94)	83% (457)
	1024 x 576	49%	3/imagem	8% (18)	92% (213)
	1024 x 576	51%	4/imagem	24% (76)	76% (244)

Fonte: elaborado pelo autor

As métricas mais comuns para a avaliação do desempenho de classificadores são Acurácia, Sensitividade, Especificidade e Precisão. Tomando-se os conceitos emprestados das pesquisas da área médica, a explicação será simplificada por se tratar de termos que todos convivem habitualmente. Por exemplo, imagine que o objetivo da classificação é ter conhecimento se uma doença atinge determinada população e deseja-se medir o desempenho de um teste clínico para identificar a proporção de indivíduos da população que são doentes. Portanto, os casos em que os indivíduos são realmente doentes e o teste indica que positivamente são doentes dá-se o nome de verdadeiro-positivo (VP). Os casos que os indivíduos são realmente doentes, mas o teste não indica doença (resultado negativo para a doença) são chamados de falso-negativo (FN). Os casos em que os indivíduos não são acometidos pela doença, mas o teste indica que a doença positivamente está presente são indicados por falso-positivo (FP). Por fim os casos em que os indivíduos realmente não possuem traços da doença e o algoritmo também concorda, indicando negativo para a doença, são indicados como verdadeiro-negativo (VN).

Portanto a matriz de confusão, que compila os resultados dessas avaliações, de forma genérica, pode ser apresentada conforme a Tabela 9.

Tabela 9 – Matriz de confusão genérica

		Classe predita pelo algoritmo	
		Doente	Não doente
Classe real	Doente	Verdadeiro positivo (VP)	Falso negativo (FN)
	Não doente	Falso positivo (FP)	Verdadeiro negativo (VN)

Fonte: elaborado pelo autor

As métricas já citadas são definidas conforme as Equações (14) a (18).

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (14)$$

$$Sensitividade (recall) = \frac{VP}{VP + FN} \quad (15)$$

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (16)$$

$$\text{Precisão (Valor preditivo positivo)} = \frac{VP}{VP + FP} \quad (17)$$

$$\text{Valor preditivo negativo} = \frac{VN}{VN + FN} \quad (18)$$

O significado de cada uma dessas métricas é melhor entendido voltando-se ao exemplo hipotético de teste clínico da doença. A acurácia indica a proporção de quanto o teste acertou entre indicações corretas de indivíduos com doença e indivíduos sem a doença dentre todos os indivíduos analisados. No entanto, suponha que se trata de uma doença muito rara e que é esperado que apenas 0,1% da população possua tal doença. Portanto qualquer teste que responda que todos os indivíduos são sadios, independentemente de suas características, terão acurácia de 99,9%. Ou seja, para populações não-balanceadas, que apresentem uma disparidade muito grande entre a quantidade de indivíduos de cada classe, a acurácia pode não ser uma métrica suficiente para avaliar o desempenho do teste.

Imagine que apesar de rara, a doença deva ser descoberta em todos os indivíduos doentes e não se deve de maneira nenhuma indicar que um indivíduo é sadio quando na verdade ele possui a doença, pois ela é extremamente mortal nos casos de não tratamento no início da evolução da doença, por exemplo. A métrica que pode fornecer esta indicação é a Sensitividade. Também chamada de *recall* nas disciplinas de recuperação de informação, ela indica a proporção de todos os indivíduos indicados pelo teste como doente e que verdadeiramente são doentes dentre todos os indivíduos que realmente são doentes. A métrica diametralmente oposta a Sensitividade é a Especificidade pois avalia a proporção de casos indicados como negativos e que realmente o são por todos os casos que realmente são negativos.

Outra métrica importante é a Precisão. Esta indica a proporção de indivíduos realmente doentes indicados com a doença sobre o total de indivíduos que o teste indicou que possuem a doença. Este é o caso de testes que precisam informar de forma rápida, ainda que com confiabilidade mediana, sobre a presença de uma característica. Tome como exemplo os primeiros testes de gravidez de farmácia que surgiram. Ele era um indicativo rápido de gravidez que deveria ser confirmado posteriormente com exames de sangue e exame clínico. É o caso de quando o teste

aceita alguns casos de não doentes como indicados como doentes, a serem confirmado por testes posteriores minuciosos e mais caros. A métrica diametralmente oposta é o valor preditivo negativo, que avalia a proporção de verdadeiros negativos diante de todos os casos indicados pelo classificador como negativos.

Dados os conceitos dessas métricas de avaliação serão apresentados a seguir o desempenho do algoritmo nos dois conjuntos de dados (Conjunto 1 e Conjunto 2) e em duas situações-testes distintas (teste do tipo de dormente e teste de defeitos de dormente). O resultado do algoritmo para a classificação do tipo de dormente está compilado na forma de Matriz de confusão nas Tabela 10 e Tabela 11.

Tabela 10 – Matriz de confusão para o tipo de dormente para o Conjunto 1

Tipo de dormente		Classe predita pelo algoritmo	
		Madeira	Aço
Amostras do Conjunto 1			
Classe real	Madeira	73	0
	Aço	1	28

Fonte: elaborado pelo autor

Tabela 11 – Matriz de confusão para o tipo de dormente para o Conjunto 2

Tipo de dormente		Classe predita pelo algoritmo	
		Madeira	Aço
Amostras do Conjunto 2			
Classe real	Madeira	90	4
	Aço	18	439

Fonte: elaborado pelo autor

Para apresentar as métricas comumente utilizadas na avaliação de desempenho e estas serem melhor compreendidas, pode-se supor uma pergunta-hipótese, definida da seguinte forma: “Os dormentes da imagem são de madeira? ”. Assim a classe positiva corresponde a madeira e conseqüentemente a classe negativa corresponde a aço. Apesar disso, há casos em que, na imagem, todos os dormentes estão oclusos por brita, inclusive as almofadas. No entanto o algoritmo escolhe entre uma das classes e isto é comparado com a resposta real, e esta sim, possui mais

informações do que apenas as informações contidas na imagem atual. A avaliação real do tipo de imagem pode considerar também os tipos de dormentes nas imagens adjacentes ou outros elementos da imagem que não foram explorados no algoritmo. Neste caso, a avaliação real certamente se sobreporá sobre a resolução do algoritmo, que acertará ao acaso. No entanto, como pode ser verificado na Tabela 12, o algoritmo atinge patamares relevantes de desempenho.

Tabela 12 – Desempenho do teste de tipo de dormente

	Acurácia	Sensitividade	Especificidade	Precisão	Valor pred. Neg.
Amostras do Conjunto 1	99%	100%	97%	99%	100%
Amostras do Conjunto 2	96%	96%	96%	83%	99%
Todo o Conjunto 1	96%	97%	94%	98%	93%
Todo o Conjunto 2	97%	98%	96%	84%	100%

Fonte: elaborado pelo autor

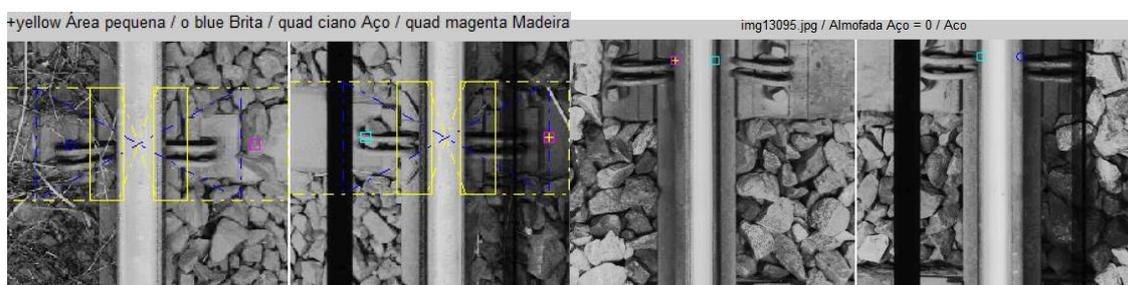
Além do conjunto de amostras de 102 e 551 dormentes, respectivamente, dos Conjuntos 1 e 2, foi possível avaliar o desempenho do algoritmo para todo o Conjunto 1 e 2. Isso porque os dormentes do mesmo tipo estavam agrupados em longos seguimentos da ferrovia e as transições entre diferentes tipos de dormentes ocorreram poucas vezes ao longo dos conjuntos, permitindo classificar cada imagem com o seu respectivo tipo de dormente real. O Conjunto 1 teve 14 transições com seções com quantidades de imagens variando entre 2 e 830 imagens. O Conjunto 2 teve 18 transições de tipo de dormente com segmentos que continham entre 1 e 1943 imagens. Como a dificuldade de classificação de todas as imagens não era muito alta foi possível avaliar o desempenho para todas as imagens.

Nota-se pelos índices da Tabela 12 que o desempenho do algoritmo para a classificação do tipo de dormente é bem satisfatório, com grande parte dos índices maiores ou iguais a 96%. Para o Conjunto 1, um dos mais baixos índices foi 94% para

Especificidade quando avaliado no conjunto inteiro. Isto indica que, neste conjunto, o algoritmo indicou que 94% dos casos que eram verdadeiramente de aço foram marcados pelo algoritmo como aço, os demais foram marcados como madeira. Isto, em particular, ocorre nos casos em que o dormente apesar de ser de aço está obstruído pela brita ou outros elementos de forma que a textura aparente é confundida com os esperados nós de madeira. Além disso, a almofada também está obstruída pela brita, impedindo que seja verificada a almofada característica de dormentes de aço.

Um exemplo de tal situação é apresentada na primeira imagem da Figura 64. Na imagem, a ROI 1 está obstruída com vegetação e é indicado assim pelo algoritmo (círculo azul). A ROI 2 está obstruída parcialmente com duas pedras grandes, mas é indicada como se fosse madeira (quadrado magenta) por causa da prevalência de sombra majoritariamente horizontal. A ROI 3 é avaliada corretamente como aço (quadrado ciano), mesmo com a faixa escura sobre a imagem. Por fim, a ROI 4 não é considerada porque a região a ser avaliada é considerada muito pequena. Logo, como boa parte das almofadas estão envoltas por vegetação ou brita, estas não são identificadas como almofadas presentes nos dormentes de aço e, portanto, não influenciaram na decisão do tipo de dormente. Então a decisão de desempatar entre madeira (ROI 2) e aço (ROI 3) é dado à ROI 2, a região geralmente com melhor iluminação e área visível. Por isso a avaliação foi equivocada nesta imagem.

Figura 64 – Exemplos de erros de classificação do tipo de dormente no Conjunto 1



Fonte: elaborado pelo autor.

O outro índice que chama atenção no Conjunto 1 é o valor de predição negativa. Indica que 93% dos casos indicados como aço pelo algoritmo realmente são aço, os demais são madeira. Um exemplo deste caso é apresentado na segunda imagem da Figura 64. Neste caso o dormente é realmente de madeira (confirmado pelo tipo de

placa de fixação), recebeu as avaliações parciais de textura, respectivamente para as ROIs 1 a 4, como área pequena para avaliar, aço, aço e brita. O algoritmo indicou aço quando deveria ser madeira pois a textura da superfície é tão lisa e sem nós de madeira que houve confusão com aço. A almofada, quando presente, é indicativo de dormente de aço. O contrário não é verdade. Quando ausente, não significa dormente de madeira, pois a visão suficiente da almofada pode estar apenas obstruída por outros elementos.

No Conjunto 2, o menor índice foi na métrica de Precisão (84% a 83%) tanto na quantidade reduzida de amostras quanto no conjunto inteiro de imagens. Esta métrica indica, como já explicado anteriormente, a proporção de dormentes que foram indicados como madeira e realmente o são dentre todos os dormentes que o algoritmo indicou como madeira. Ou seja, cerca de 16% dos dormentes indicados como madeira, na verdade são de aço. Os motivos são os mesmos apresentados anteriormente para exemplificar a primeira imagem da Figura 64. No entanto, como a proporção de dormentes de aço é maior neste conjunto de imagens a frequência de ocorrência é maior. Soma-se isso ao fato de que este conjunto de imagens possui mais deficiência na iluminação (sistema de iluminação avariado) que o Conjunto 1 de imagens. As tentativas de equalização e melhoria da imagem criam muitos artefatos, que acabam prejudicando o algoritmo de decisão do tipo de dormente, conforme pode ser comparado com os resultados do Conjunto 1 e observado na Figura 65. A brita sobre os dormentes e sobre as almofadas dificultam a identificação dos dormentes. A primeira imagem é a imagem original e a segunda é a imagem melhorada e com a classificação, indicando prevalência de dormente de madeira.

Figura 65 – Exemplos de erros de classificação do tipo de dormente no Conjunto 2

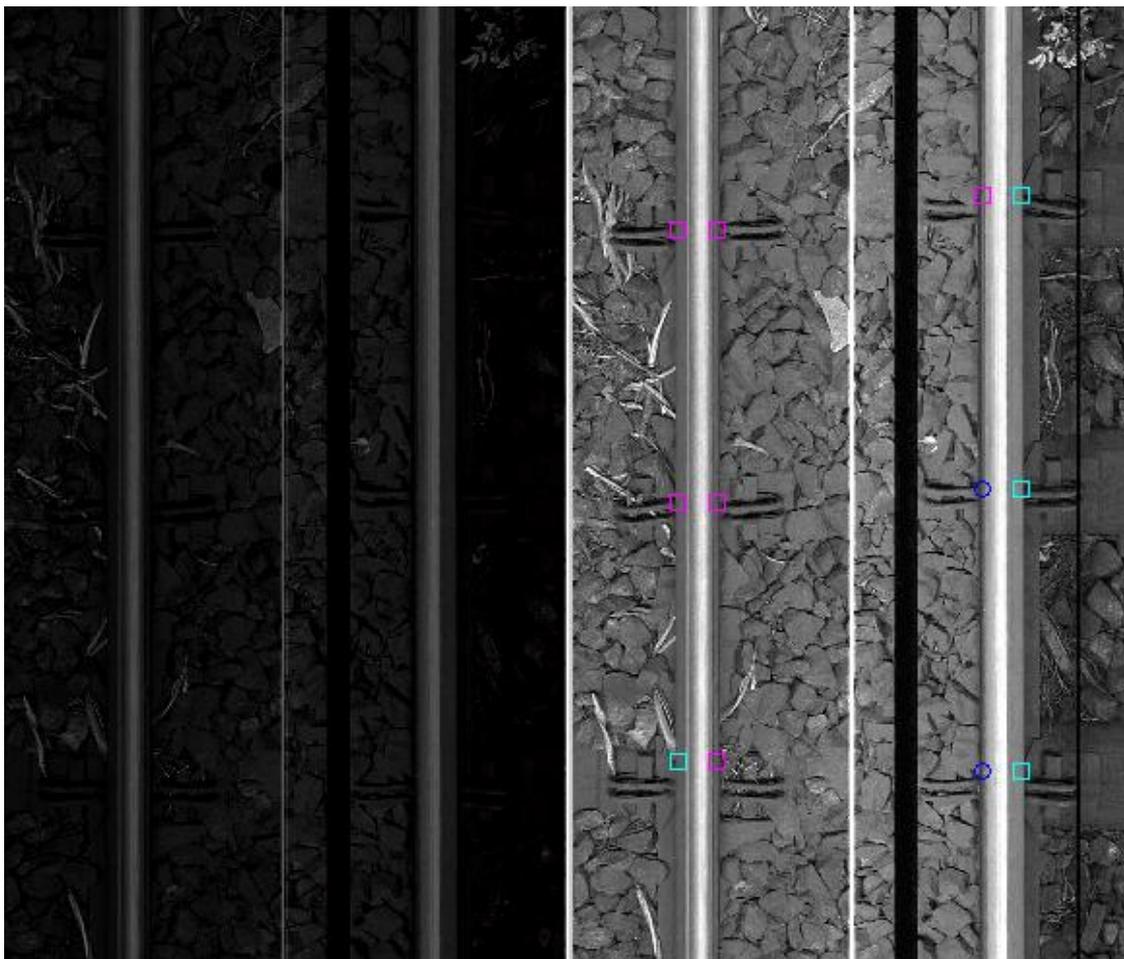


Imagem original e imagem alterada para melhorar o contraste da imagem (histograma equalizado). Os itens marcados com quadrado magenta indicam dormente de madeira. Os quadrados de azul (ciano) indicam dormente de aço. Os círculos azuis indicam presença de brita ou outros elementos. Fonte: elaborado pelo autor.

Apesar dos erros apontados, o desempenho do algoritmo foi bem satisfatório, com acurácia superior a 96% e a maioria dos demais índices acima de 93%. Geralmente para avaliação de testes de classificação não balanceados as métricas de Sensitividade, Especificidade e Precisão são as mais empregadas. No entanto, como tanto a classe positiva (madeira) quanto a classe negativa (aço) possuem informações igualmente relevantes, foi preciso também utilizar a métrica de valor preditivo negativo, para balancear a comparação do desempenho entre madeira e aço. Diferente da avaliação de defeitos em dormente que se seguirá adiante, onde a informação requerida está apenas na classe de dormentes que possuem defeitos, fazendo um paralelo a toda a explanação anterior sobre testes de doenças e onde os

significados dos termos de Sensitividade, Especificidade e Precisão voltam a fazer sentido.

Na avaliação do desempenho do algoritmo para a detecção de defeitos foram utilizadas apenas amostras aleatórias de dormentes de madeira. Como já foi apresentado anteriormente, nos dormentes de aço não foram encontrados defeitos aparentes em quantidade razoável (apenas uma única imagem havia aparentado defeito). As matrizes de confusão nas Tabela 13 e Tabela 14 representam, respectivamente, as amostras do Conjunto 1 e do Conjunto 2.

Tabela 13 – Matriz de confusão para defeito em dormente para o Conjunto 1

Detecção de defeito		Classe predita pelo algoritmo	
		Defeito	Sem defeito
Amostras do Conjunto 1			
Classe real	Defeito	44	11
	Sem defeito	29	204

Fonte: elaborado pelo autor

Tabela 14 – Matriz de confusão para defeito em dormente para o Conjunto 2

Detecção de defeito		Classe predita pelo algoritmo	
		Defeito	Sem defeito
Amostras do Conjunto 2			
Classe real	Defeito	49	4
	Sem defeito	24	299

Fonte: elaborado pelo autor

As métricas já citadas assumem os valores apresentados na Tabela 15.

Tabela 15 – Desempenho de detecção de defeitos em dormentes

	Acurácia	Sensitividade	Especificidade	Precisão	Valor pred. Neg.
Amostras do Conjunto 1	86%	80%	88%	60%	95%
Amostras do Conjunto 2	93%	92%	93%	67%	99%

Fonte: elaborado pelo autor

A Acurácia fica acima de 86% nos dois conjuntos, mas assim como o teste anterior, as classes são desbalanceadas e, portanto, esta não é a melhor métrica. A Sensitividade, que avalia o quanto o algoritmo acertou dentre os dormentes que realmente possuíam defeito, ficou entre 80% e 92%. A Especificidade, que traz a porcentagem de acerto dentre os dormentes verdadeiramente sem defeito, alcançou índices de 88% e 93%, respectivamente para os Conjuntos 1 e 2. Ou seja, quando há defeitos reais, a taxa de acerto é alta. A métrica de Precisão, que representa a proporção entre as respostas corretas de todos os dormentes que o algoritmo apontou com defeito foi de 60% e 67%, respectivamente. Este indicador, quando apresenta valor baixo indica que o algoritmo está indicando defeitos onde realmente não há. Apesar de ser o indicador com o menor valor, há de se considerar que parte da confusão da resposta ocorre quando há outros materiais (como brita e vegetação) dispostos de forma aleatória sobre os dormentes de madeira, causando sombras que se assemelham às rachaduras na madeira, ocasionando os erros.

Neste algoritmo não cabe uma análise de curva ROC (*Receiver Operating Characteristic Curve*), tão utilizada para avaliar o desempenho de diferentes algoritmos de classificação, principalmente os baseados em classificação supervisionada, pois nesta proposta não há possibilidade de variar algum parâmetro (como número de características) para avaliar o balanço de parâmetros de desempenho. Apenas há um único ponto onde a tupla de métricas se encontra. Por exemplo, é comum avaliar a curva ROC entre os parâmetros de Sensitividade (taxa de verdadeiros positivos) por 1-Especificidade (taxa de falsos positivos), onde o classificador ideal está posicionado no ponto (1 ; 0). Este algoritmo está, na média dos dois conjuntos, no ponto (0,98 ; 0,05) para o algoritmo de classificação do tipo de dormente e no ponto (0,80 ; 0,12) para o algoritmo de detecção de defeitos.

Na literatura não há muitos artigos que apresentam implementações de detecção automática de defeitos em dormentes e também publiquem os seus resultados de desempenho. Dos artigos encontrados, apenas as publicações do Prof. Yella apresentavam o desempenho em termos de acurácia (YELLA; GUPTA; DOUGHERTY, 2007; YELLA et al., 2008; YELLA; GHIAMATI; DOUGHERTY, 2009; YELLA; RAHMAN; DOUGHERTY, 2010). Os artigos dizem respeito a mesma base de dados, mas em fases diferentes da implementação. O conjunto de amostras são 200 dormentes de madeira, sendo 144 dormentes em bom estado e 56 em estado ruim (apresentavam defeitos). Da base de dados, 150 foram separados para o conjunto de treinamento e 50 foram utilizados no conjunto de testes. Foram testadas, para as implementações de aprendizagem de máquina, técnicas de *support vector machine* (SVM), *multi-layer perceptron* (MLP), *radial basis function neural networks* (RBFNN), *gaussian mixture models* (GMM), *learning vector quantisation* (LVQ). Para a extração de características das amostras foram utilizadas imagens dos dormentes, usando técnicas de detecção de borda, conectividade e binarização de imagens; e para a resposta acústica ao golpear os dormentes com um martelo instrumentado, utilizando *short-time Fourier transform* (STFT) e *discrete wavelets transform* (DWT) para analisar o sinal acústico.

Cada um dos artigos mencionados apenas expõem o desempenho em termos de acurácia. No entanto, pelo já discutido anteriormente, esta métrica é importante, mas é preciso também avaliar à luz de outras métricas. Para alguns artigos foi possível estimar o resultado das implementações nas outras métricas porque foram indicados, além da acurácia, o número de erros em cada classe. Serão apresentados apenas os resultados finais de cada implementação de cada artigo. Outros resultados (em várias fases de implementação) de cada artigo são apresentados no Apêndice A. Os resultados finais de cada implementação são apresentados na Tabela 16.

Tabela 16 – Métricas de desempenho das versões finais dos algoritmos de identificação de defeitos em dormentes por ano de publicação

Ano artigo	Acurácia	Sensitividade	Especificidade	Precisão	Valor pred. Neg.
2007	88%	-	-	-	-
2008	92%	71%	100%	100%	90%
2009	84%	43%	100%	100%	82%
2010	86%	57%	97%	89%	85%

Fonte: elaborado pelo autor

A indicação do artigo por ano fez-se necessário para simplificar a apresentação da tabela. O artigo do ano 2007 (YELLA; GUPTA; DOUGHERTY, 2007) refere-se a fusão dos resultados da avaliação de impacto acústico e da avaliação de visão computacional. O artigo do ano 2008 (YELLA et al., 2008) apresenta o resultado da fusão de vários classificadores considerando apenas características obtidas com visão computacional. O artigo de 2009 (YELLA; GHAMATI; DOUGHERTY, 2009) expõe a fusão de vários classificadores considerando apenas características do sinal acústico. O artigo do ano 2010 (YELLA; RAHMAN; DOUGHERTY, 2010) exhibe o resultado final depois de combinar o processamento das características da imagem com características do sinal acústico dos lados esquerdo e direito dos dormentes combinados.

A comparação do desempenho destes artigos com o desempenho da implementação proposta nesta dissertação (Tabela 15) pode ser feita, mas com reservas. O primeiro dos motivos é que a base de dados usada nos artigos citados não está disponível para utilização por outros trabalhos. Além disso, nos artigos deve-se considerar fragilidades como, por exemplo indicado pelos próprios autores, o número limitado de amostras (150 dormentes) para treinar sobre 218 características e validar em um conjunto de testes de 50 dormentes; e que, ao final, a resposta a cada lado do dormente é combinada em uma única resposta.

Mesmo abonando estes aspectos, o desempenho dos artigos apresentados na literatura não são muito aquém. A acurácia dos artigos fica entre 84% e 92% enquanto a proposta dessa dissertação alcança valores entre 86% e 93%. O algoritmo apresentado na literatura possui sensitividade entre 43 e 71% enquanto o desta

dissertação assume valores de 80% e 92%. Este é um parâmetro importante, uma vez que indica a taxa de defeitos indicada pelo algoritmo entre todos os itens que realmente possuíam defeitos, direciona a ação das ferrovias para evitar eventos catastróficos. Por outro lado, a Precisão, que indica a taxa de acerto de todos os itens que o algoritmo indicou como possuindo defeito, é apenas custoso, mas não catastrófico, uma vez que levaria a indicação de defeitos em dormentes que na verdade não são defeituosos. Isso no máximo, levaria a troca (ou a inspeção humana) desnecessária de dormentes em bom estado. Neste caso, o algoritmo da literatura assumiu valores de 89% a 100% enquanto o algoritmo desta dissertação assumiu valores de 60% e 67%. Da mesma forma, especificidade e valor preditivo negativo são custosos, mas não catastróficos. O artigo da literatura assumiu valores de 97% a 100% e 82% a 90%, respectivamente, enquanto a proposta desta dissertação foi de 88% e 93%, para a especificidade, e 95% e 99% para o valor preditivo negativo.

Não há garantia de que a indicação de dormente defeituoso considerada nos artigos é a mesma da aplicada nesta dissertação. Para os artigos relacionados, um dormente é considerado ruim quando ambas as extremidades do dormente (direita e esquerda) apresentam defeitos. Além disso, pelas imagens apresentadas, para que um dormente seja considerado inservível a condição visual das estruturas físicas do material aparentemente deve se apresentar fatigada ao extremo. Para a avaliação de defeitos apresentada nesta dissertação cada uma das quatro regiões (ROIs) do dormente é avaliada separadamente. A resposta do algoritmo para cada ROI é comparada com a resposta para cada uma das quatro regiões dado pelos especialistas. Além disso, são apresentados alguns níveis de defeitos detectados, assim como ocorre na classificação por seres humanos que conseguem distinguir os defeitos em graus de severidade. Ao final, também não é possível determinar comparativamente o desempenho do algoritmo proposto porque o banco de dados não está disponível para testes.

Por fim, para ilustrar como cada processo contribui de forma não linear para o resultado final do algoritmo, a Figura 66 apresenta entre parênteses a acurácia dos algoritmos de detecção da posição do dormente, do tipo de dormente e da detecção de defeitos e também de cada etapa separada do processo, sobre o diagrama já apresentado. O conjunto de dados apresentados diz respeito às amostras aleatórias do Conjunto 1 e a avaliação sobre os algoritmos de identificação do tipo de dormentes e de defeitos em dormentes de madeiras que foi apresentada ao longo desse capítulo.

A avaliação da posição dos dormentes foi feita, para todas as imagens, de forma visual ao se observar se a região está circundando um dormente, o centro do trilho ou uma ROI, ou quanto a textura identificada cobria um dormente. A única avaliação dicotômica (binária) ocorreu quando os elementos de fixação foram corretamente apontados.

Figura 66 – Diagrama com a acurácia de cada etapa

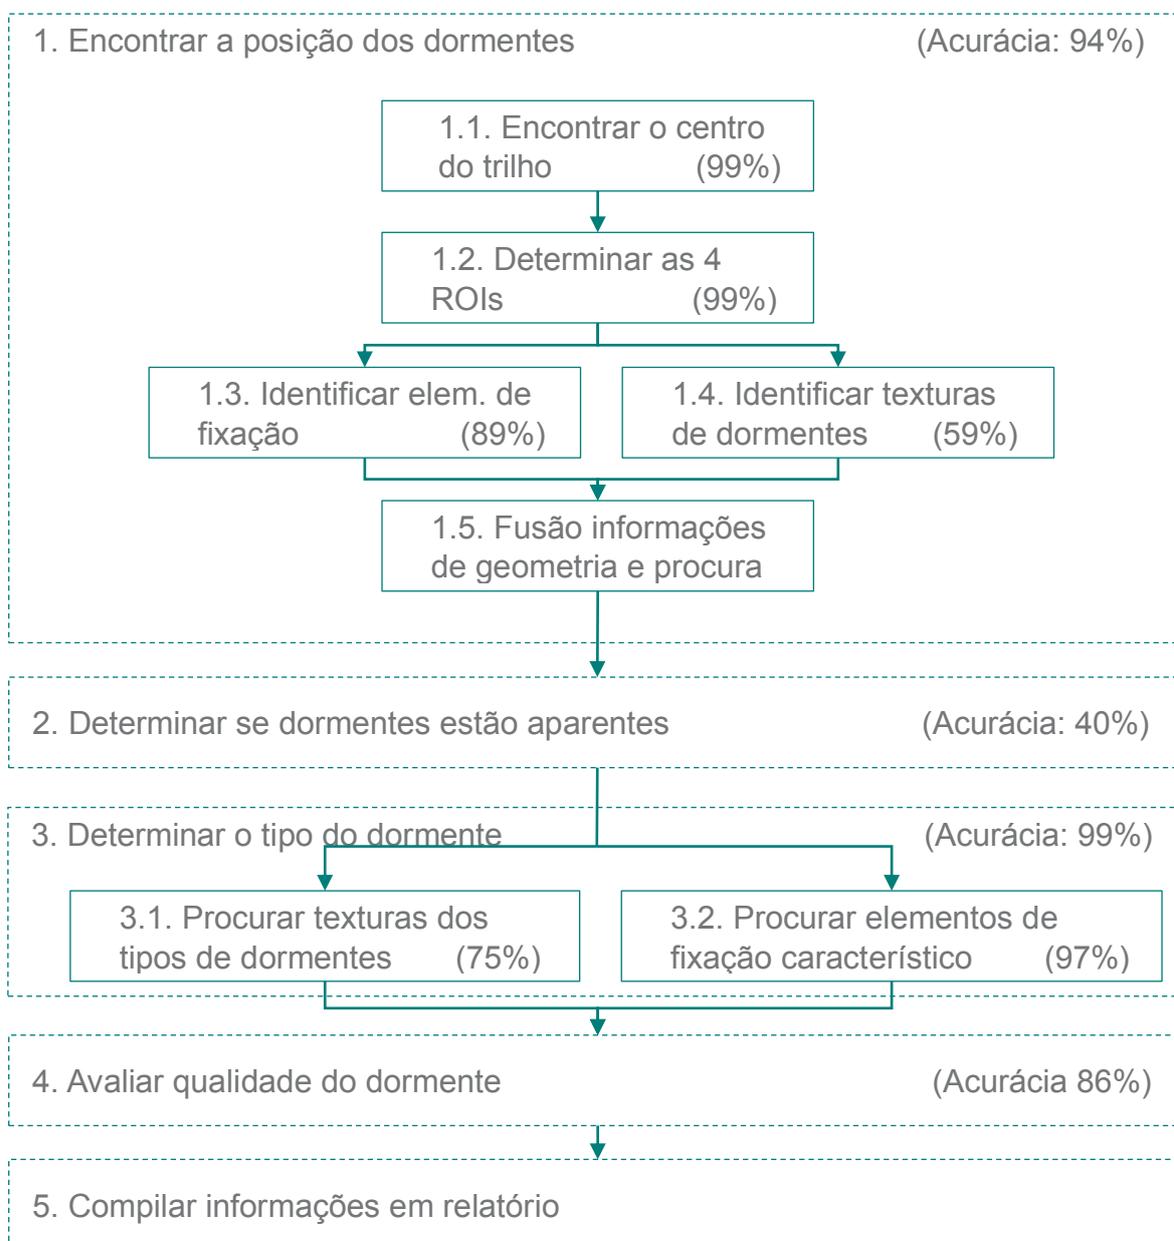


Diagrama com a acurácia de cada etapa para as amostras do Conjunto 1. Fonte: elaborado pelo autor.

Tome o exemplo do primeiro algoritmo, que objetiva detectar a posição dos dormentes. Apesar da acurácia de algumas etapas, quando avaliadas

separadamente, apresentarem valores menores que 90%, como é possível obter uma acurácia total do algoritmo de 94%? A resposta é que há muita redundância de informações. Quando não é possível identificar o elemento de fixação porque o elemento está ausente ou encoberto, sua acurácia é diminuída, e o algoritmo se apoia nas demais respostas para identificar a posição do dormente. Da mesma forma, quando a identificação de texturas não ocorre como se almejava, por exemplo, quando o dormente está encoberto, possui pouca área visível ou mesmo erra ao ser confundido por outros elementos, esse contribui para a baixa eficácia da etapa em particular. No entanto, indicações em posições próximas contribuem construtivamente enquanto os erros atuam isolados, geralmente não confirmando posições erradas. Isto adicionado a outras informações de topologia, geometria e distâncias esperadas, criam regras que adicionam não linearidades ao classificador de forma que o resultado final possui acurácia maior que o resultado isolado de cada etapa.

O algoritmo de detecção de dormente aparente, apesar de baixa acurácia (40%) serve apenas para reduzir os erros do algoritmo posterior, de detecção do tipo de dormente, evitando que alguns candidatos passem à próxima etapa de avaliação.

O alto índice de acurácia apresentado pelo algoritmo de detecção de dormente é, principalmente, devido à alta taxa de acerto da etapa de identificação de elementos de fixação, da exclusão de alguns candidatos, com o algoritmo anterior e novamente com a não-linearidade atribuída pelo sistema de votação de vários sensores.

A acurácia do último algoritmo, que identifica os defeitos nos dormentes de madeira, possui influência significativa da aleatoriedade de formas como os defeitos podem se apresentar, das numerosas formas naturais que outros elementos podem se apresentar e confundir o algoritmo e da quantidade finita de características selecionadas para identificar os defeitos. Ainda que, o algoritmo traga uma escala de fidelidade (três níveis de verossimilhança de defeitos reais), quantifica uma informação que até então era totalmente subjetiva e sujeita a erros de julgamento.

Em termos de tempo de processamento, com o hardware disponível e descrito no início desta seção, os valores ficaram sempre próximos do um valor médio, a depender apenas da altura da imagem a ser analisada (visto que a largura é sempre 576 *pixels*). Os valores médios são a média de tempo de processamento de todas as imagens do banco de dados (Conjunto 1 e Conjunto 2) e estão compilados na Tabela 17.

Tabela 17 – Tempo médio de processamento em segundos

Tamanho das imagens	Tempo total [s]	Tempo fixação [s]	Tempo dormentes [s]	Tempo escolha [s]	Tempo defeito [s]
Conjunto 1					
256 x 576	0,75	0,08	0,28	0,36	0,03
512 x 576	1,43	0,12	0,52	0,70	0,09
1024 x 576	2,87	0,26	0,95	1,42	0,24
Conjunto 2					
1024 x 576	2,25	0,25	0,78	1,14	0,08

Fonte: elaborado pelo autor

As colunas da Tabela 17 tem os seguintes significados:

1. Tempo total: tempo médio em segundos que todos os algoritmos levaram para processar imagens de tamanhos típicos;
2. Tempo fixação: tempo médio da etapa de procura e identificação da localização das fixações na imagem;
3. Tempo dormente: tempo médio de avaliação da textura do dormente
4. Tempo escolha: tempo médio da etapa de avaliação de todas as informações para identificação do tipo de dormente;
5. Tempo defeito: tempo médio de avaliação da presença de defeito nos dormentes.

A etapa de identificação de fixação é muito mais rápida que as demais etapas. Isso corrobora com a já conhecida rapidez do uso de imagens integrais e transformada de Haar para identificar características na imagem de uma só vez, sem precisar de mecanismos para varrer toda a imagem, como loops.

Sempre que possível, usou-se o recurso de funções e notação matricial otimizadas para o uso em Matlab para conferir agilidade na conclusão do algoritmo. No entanto, nem sempre é possível se desvencilhar do uso de expressões de “se-então” e de “*loops*” (laços e iterações). Estes recursos, quando utilizados, foram empregados com parcimônia e nunca na imagem toda, apenas avaliando parte limitada dela.

Apesar de não ter sido utilizado nenhum recurso voltado para o uso de GPU (*Graphics Processing Unit*, unidade de processamento gráfico) ou computação paralela, crê-se, baseado em outras experiências, que a mudança do algoritmo de uma plataforma de linguagem interpretada (Matlab) para uma linguagem compilada (C++, por exemplo) trará ganhos significativos em termos de tempo de processamento.

A solução, apesar de proposta como processamento *off-line* (após a aquisição das imagens), não é viável comercialmente com a plataforma desenvolvida com o atual tempo de processamento. Baseado no Conjunto 2 de imagens, seria preciso 4,5 horas para processar as 7.234 imagens do banco de dados. Estas imagens correspondem a apenas 20,5 minutos de uma viagem de 14 km do Carro Controle. No entanto, com uma implementação em C++, baseado na literatura e experiência própria, espera-se que o tempo de processamento seja compatível com um tempo para um processamento *on-line*.

4 CONCLUSÃO

Entende-se que os objetivos propostos foram atingidos. Foi possível identificar o tipo de dormente de cada imagem, foi possível identificar, na maior parte dos casos, os defeitos em dormente de madeira e com as informações disponíveis é possível entregar um relatório com dados úteis para priorizar e planejar a manutenção dos dormentes da ferrovia. Isto foi atingido, como premissa, utilizando apenas técnicas de processamento de imagens para se gerar uma classificação não supervisionada e sem aprendizagem de máquina. Estas duas premissas se fizeram necessárias pois o custo para pré-classificar o banco de dados de amostras é muito alto. Não foi possível dispor de avaliação especialista além das 226 imagens analisadas para validação. Apenas estas imagens não seriam suficientes para representar muitas das situações aleatórias que os dormentes poderiam estar submetidos em condições reais de operação. Este é outro aspecto que seria necessário no caso de se utilizar técnicas de aprendizagem de máquinas: a quantidade de imagens, apesar de ser um banco de quase 10 mil imagens, não conteriam a maior parte das configurações de cena (objetos e suas disposições sobre a imagem) possíveis.

O tipo de dormente foi estimado com uma acurácia superior a 96% e demais métricas com desempenhos igualmente interessantes (conforme Tabela 12). Isto num cenário sujeito a variabilidade de uma operação ferroviária real. Com condições de dormentes encobertos pelo lastro, vegetação, sujeira, ausência de fixação ou na presença de outros elementos da via permanente, como AMVs e travessões que mudam completamente os padrões de dormentes visualizados na imagem. Para uma avaliação humana, esses itens não representam qualquer empecilho, visto que a complexa máquina humana faria uso de muita informação disponível, inclusive experiências progressas e os trechos adjacentes da ferrovia, para identificar o tipo de dormente. Para o algoritmo desenvolvido, não foi implementado (mas poderia sem qualquer dificuldade) considerar a classificação da imagem do trecho anterior para identificar o tipo de dormente da imagem atual. Seria como estimar o estado atual, considerando informações do estado anterior e mais a interferência das entradas.

A identificação dos defeitos em dormentes ocorreu apenas nos dormentes de madeira. Nos dormentes de aço, pelos motivos que já foram descritos no Capítulo 2 (DESENVOLVIMENTO), não houve repetibilidade do defeito superficial que permitisse identificar suas características majoritárias. Havia apenas uma única

imagem em todo o conjunto de imagens. Para os dormentes de madeira foi possível obter, conforme a Tabela 15, acurácia superior a 86%. Por motivos já discutidos, a acurácia não é o melhor parâmetro para consideração de desempenho. Contudo, as demais métricas alcançaram valores entre 80% e 99%. A exceção foi a Precisão que assumiu valores entre 60% e 67%. Via de regra, Precisão significa a taxa de acerto de todos os itens que o algoritmo indicou como possuindo defeito. Ou seja, ele foi permissivo com o que era apontado como defeito, havia alguns que não eram realmente defeito. Por outro lado, a Sensitividade (*recall*), que indica a taxa de defeitos apontada pelo algoritmo entre todos os itens que realmente possuíam defeitos ficou entre 80% e 92%. Assim sendo, o algoritmo toleraria a indicação de alguns dormentes não defeituosos de verdade, mas não deixaria de indicar grande parte dos dormentes realmente defeituosos.

A indicação de defeitos de dormentes, que possui três gradações de confiabilidade de defeito (a depender de quais características de defeitos são atendidas), o tipo de dormente da imagem e a informação da posição na via a que se refere a imagem serão compiladas em um relatório que ajudará as equipes de manutenção da ferrovia em priorizar e planejar as atividades. Poderá ainda ser utilizado para cruzar dados com outros relatórios a fim de identificar problemas que afetam outras estruturas da ferrovia. Por exemplo, ausência de suporte nos dormentes podem causar mudança da geometria da via.

Para trabalhos futuros, em termos de objeto a ser avaliado, planeja-se adaptar o algoritmo também para analisar defeitos em dormentes de concreto. Estes dormentes apresentam fraturas na superfície, perdem massa ou fragmentam-se, principalmente devido a acidentes. Outros elementos podem ser também incluídos, como outros tipos de fixações e AMVs. Os AMVs, em particular, são estruturas que sofrem muito com o impacto e frequentemente devem passar por inspeções.

Em termos de técnicas e ferramentas, poderiam ser implementados algoritmos de aprendizagem de máquina com um banco de dados maior e com os objetos previamente classificados e rotulados. Talvez, a primeira indicação de classificação do banco de dados maior poderia originar-se do algoritmo proposto neste trabalho e apenas nos casos de dúvida (ou pouca certeza), recorrer à avaliação especialista. Assim seria possível implementar um algoritmo supervisionado e com aprendizagem de máquina.

Poderia também utilizar lógica Fuzzy para classificar as gradações de defeitos. A régua é bem definida por parâmetros quantitativos, mas assim como a avaliação subjetiva humana, a gradação simbólica da saída do algoritmo pode ser um conjunto de regras flexíveis. Ao menos manteria o objetivo deste algoritmo de quantificar o que hoje é avaliado de forma subjetiva pelo homem.

Por fim a implementação do código em C++ provavelmente, baseado em outras experiências, tornaria o tempo de processamento mais curto.

REFERÊNCIAS

AMÉRICA Latina Logística. **Especialização em engenharia ferroviária - ALL: 2.3** Falhas em trilhos. 02 mar. 2009, 27 jun. 2009. 60 p. ALL. Notas de aula.

ASSOCIAÇÃO NACIONAL DOS TRANSPORTADORES FERROVIÁRIOS. Informações gerais. **ANTF**. Brasília, on-line. [2016]. Disponível em: <<http://www.antf.org.br/informacoes-gerais/>>. Acesso em: 16 fev. 2017.

AMERICAN RAILWAY ENGINEERING AND MAINTENANCE-OF-WAY ASSOCIATION. **MANUAL FOR RAILWAY ENGINEERING**: Chapter 30 Ties. Landover, Maryland, USA: AREMA, 2009. v. 4.

PREVISÃO DA BALANÇA COMERCIAL PARA 2017 [da] Associação de Comércio Exterior do Brasil – AEB. Rio de Janeiro, 2017. Anual. Disponível em <http://www.aeb.org.br/noticias/downloads/1956_AEB%20-%20BALAN%C3%87A%20COMERCIAL%202017.pdf>. Acesso em: 09 jan. 2017.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 7511**: Dormentes de madeira — Requisitos e métodos de ensaio. 2 ed. Rio de Janeiro: ABNT, 2013. 24 p.

AUER, Florian. Multi-function Track Recording Cars. **Rail Technology Review**, [S.l.]: DVV Media Group, v. 53, n. 3/4, p.32-36, Mar. 2013. Disponível em: <https://www.plassertheurer.com/pdf/publications/32_36_Auer.pdf>. Acesso em: 03 jan. 2015.

BABENKO, Pavel. **Visual inspection of railroad tracks**. 2009. 113 f. Tese (Doctor of Philosophy in the School of Electrical Engineering and Computer Science), College of Engineering and Computer Science, University of Central Florida, Orlando, Florida, 2009. Disponível em: <http://crcv.ucf.edu/papers/theses/Babenko_Pavel.pdf>. Acesso em: 20 dez. 2014.

BALLOU, Ronald H. **Logística Empresarial**: Transporte, administração de materiais, distribuição. São Paulo: Atlas, 1993. 388 p. ISBN 978-85-224-0874-0.

BRINA, Helvécio Lapertosa. **Estradas de ferro**: Via permanente. Rio de Janeiro: Livros Técnicos e Científicos Editora S.A., 1979. 260 v. ISBN 85-216-0011-9.

BUSTAMANTE, José de Carvalho. **Capacidade dos modos de transporte**. Rio de Janeiro: Instituto Militar de Engenharia, 1998. Notas de aula.

CAIXETA-FILHO, José Vicente; MARTINS, Ricardo Silveira. **Gestão Logística do Transporte de Cargas**. São Paulo: Atlas, 2007. 296 p.

CROW, Franklin C. Summed-Area Tables for Texture Mapping. **Acm Siggraph Computer Graphics**, Minneapolis, MN, USA, v. 18, n. 3, p.207-212, July 1984. Disponível em: <<http://www.florian-oeser.de/wordpress/wp-content/2012/10/crow-1984.pdf>>. Acesso em: 10 ago. 2014.

DEPARTAMENTO DE INFRAESTRUTURA DE TRANSPORTES. **PROCEDIMENTO DE INSPEÇÃO DE MATERIAL PIM-014: Dormente de Madeira para Via Férrea**. [S.l.:s.n.], 2016. 46 p. Disponível em: <<http://www.dnit.gov.br/ferrovias/instrucoes-e-procedimentos/procedimentos-para-inspecao/pim-014-dormente-de-madeira.pdf/view>>. Acesso em: 09 fev. 2016.

FEDERAÇÃO DAS INDÚSTRIAS DO ESTADO DE SÃO PAULO (São Paulo). Setor ferroviário encara desafios para transportar 35% da carga no Brasil. **Fiesp**. São Paulo, on-line. 09 mar. 2016. Disponível em: <<http://www.fiesp.com.br/noticias/setor-ferroviario-encara-desafios-para-transportar-35-da-carga-no-brasil/>>. Acesso em: 16 fev. 2017.

GIBERT, Xavier; PATEL, Vishal M.; CHELLAPPA, Rama. Robust Fastener Detection for Autonomous Visual Railway Track Inspection. **2015 IEEE Winter Conference on Applications of Computer Vision**, [S.l.], p.694-701, Jan. 2015. IEEE. <http://dx.doi.org/10.1109/wacv.2015.98>. Disponível em: <https://www.researchgate.net/publication/269337999_Robust_Fastener_Detection_for_Autonomous_Visual_Railway_Track_Inspection>. Acesso em: 16 mar. 2017.

GONZALEZ, Rafael C.; WOODS, Richard E. **Digital Image Processing**. 3rd ed. Upper Saddle River, New Jersey, EUA: Prentice Hall, 2007. 954 p.

INPI (Brasil). IAT Fixações Elásticas Ltda; Siegfried Alexander Ellwanger. **Almofada isolante para ferrovia**. BR nº PI 0901563-9 A2, 26 maio 2009, 25 jan. 2011. Revista da propriedade industrial, n. 2090, p. 38-38, 2011. Disponível em: <revistas.inpi.gov.br/pdf/PATENTES2090.pdf>. Acesso em: 16 mar. 2017.

LAM, Heung Fai; HU, Qin; WONG, Man Tat. The Bayesian methodology for the detection of railway ballast damage under a concrete sleeper. **Engineering Structures**, [S.l.], v. 81, p.289-301, Dec. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.engstruct.2014.08.035>. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0141029614005069>>. Acesso em: 16 mar. 2017.

MADASU, Vamsi Krishna; YARLAGADDA, Prasad. An in Depth Comparison of Four Texture Segmentation Methods. **9th Biennial Conference Of The Australian Pattern Recognition Society On Digital Image Computing Techniques And Applications (dicta 2007)**, Glenelg, South Australia, p.366-372, Dec. 2007. IEEE. <http://dx.doi.org/10.1109/dicta.2007.4426820>. Disponível em: <<http://eprints.qut.edu.au/12743/1/12743.pdf>>. Acesso em: 14 dez. 2016.

MINISTÉRIO DA INDÚSTRIA, COMÉRCIO EXTERIOR E SERVIÇOS (Brasil). **Balança comercial: Janeiro-dezembro 2016**. Exportação: 2016/2015. Produtos por Fator Agregado: acumulado. Brasília: MDIC. 2017. Anual. Disponível em <<http://www.mdic.gov.br/comercio-exterior/estatisticas-de-comercio-exterior/balanca-comercial-brasileira-acumulado-do-ano?layout=edit&id=2205>>. Acesso em: 09 jan. 2017.

MINISTÉRIO DOS TRANSPORTES (Brasil). Secretaria de política nacional de transportes. **Projeto de reavaliação de estimativas e metas do Plano Nacional de Logística e Transportes**. Brasília, 2012. 260 p. Disponível em: <<http://bibspi.planejamento.gov.br/bitstream/handle/iditem/559/arq1352743917.pdf?squence=1>>. Acesso em: 09 jan. 2017.

MONTEIRO Neto, Júlio Pacheco. **Ferrovias**. 09 ago. 2010, 07 dez. 2010. 67 p. Universidade Estadual do Oeste do Paraná. Notas de aula.

MOHAMMAD, Sajjad Pasha. **Machine Vision for Automating Visual Inspection of Wooden Railway Sleepers**. 2008. 51 f. Dissertação (Masters in Computer Science), Department Of Computer Science, Dalarna University, Borlange, Sweden, 2008. Disponível em: <<http://www.diva-portal.org/smash/get/diva2:518382/FULLTEXT01.pdf>>. Acesso em: 25 jan. 2015.

PAPAGEORGIU, Constantine P.; OREN, Michael; POGGIO, Tomaso. A general framework for object detection. **Sixth International Conference On Computer Vision (iecc Cat. No.98ch36271)**, Cambridge, MA, USA, p.555-562, Feb. 1998. Narosa Publishing House. <http://dx.doi.org/10.1109/iccv.1998.710772>. Disponível em: <https://www.researchgate.net/publication/3766402_General_framework_for_object_detection>. Acesso em: 10 ago. 2014.

RAIL Vision. **Tie (sleeper) grading**. Rail Vision Europe Ltd. [201-?]. Disponível em: <[http://www.rail-vision.co.uk/system/files/Tie Grading.pdf](http://www.rail-vision.co.uk/system/files/Tie%20Grading.pdf)>. Acesso em: 16 mar. 2017

PEREIRA, Olyntho Carmo. **Soluções de otimização da eficiência energética de uma ferrovia de carga**: o caso da estrada de ferro Carajás. 2009. 126 f. Dissertação (Mestrado em Engenharia Industrial), Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2009. Disponível em: <https://www.maxwell.vrac.puc-rio.br/Busca_etds.php?strSecao=resultado&nrSeq=14568@1>. Acesso em: 14 abr. 2017.

PLENGE, Michael; LAMMERING, Rolf. The Dynamics of Railway Track and Subgrade with Respect to Deteriorated Sleeper Support. In: POPP, Karl; SCHIEHLEN, Werner. **System Dynamics and Long-Term Behaviour of Railway Vehicles, Track and Subgrade**. Heidelberg, Berlin: Springer, 2003. p. 295-314. (Lecture Notes in Applied Mechanics, vol 6). DOI: http://dx.doi.org/10.1007/978-3-540-45476-2_18.

PROFILLIDIS, Vassilios A. **Railway Engineering**. 2nd ed. Wiltshire, UK: Antony Rowe Ltd, 2000. 291 p. ISBN-13: 9780754612797 ISBN: 0754612791.

RIBEIRO, Priscilla Cristina Cabral; FERREIRA, Karine Araújo. **Logística e transportes**: uma discussão sobre os modais de transporte e o panorama brasileiro. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 12., 2002, Curitiba. [Artigos completos]. Curitiba: ABEPRO, 2002. p. 1 - 8. Disponível em: <https://www.researchgate.net/publication/228780462_LOGISTICA_E_TRANSPORTES_UMA_DISCUSSAO_SOBRE_OS_MODALIS_DE_TRANSPORTE_EO_PANORAMA_BRASILEIRO>. Acesso em: 16 mar. 2017.

RUBINSZTEJN, Yohann. **Automatic Detection of Objects of Interest from Rail Track Image**. 2011. 110 f. Dissertação (Master of Science in the Faculty of Engineering and Physical Sciences), School of Computer Science, University of Manchester, [Manchester, UK], 2011. Disponível em: <https://studentnet.cs.manchester.ac.uk/resources/library/thesis_abstracts/MSc11/FuIIText/RubinszteinYohann-fulltext.pdf>. Acesso em: 09 jan. 2015.

SHAH, Mubarak. **Automated Visual Inspection/Detection of Railroad Track**. Orlando, Florida: [s.n.], 2010. 55 p. (8). Relatório final de projeto (University of Central Florida Contract No: BD550, RPWO #8). Disponível em: <https://ntl.bts.gov/lib/33000/33700/33758/FDOT_BD550-08_rpt.pdf>. Acesso em: 03 jan. 2015.

SOARES, Leonardo Souza. **Procedimentos para Determinação da Velocidade Máxima Autorizada**. 2006. 181 f. Monografia (Especialização) - Curso de Especialista em Transporte Ferroviário de Carga, Instituto Militar de Engenharia, Rio de Janeiro, 2006. Disponível em: <<http://transportes.ime.eb.br/etfc/monografias/MON027.pdf>>. Acesso em: 20 dez. 2014.

VALE. **Rotinas do inspetor de superestrutura de via permanente**. 08 ago. 2011, 12 ago. 2011. 207 p. VALE. Notas de aula.

VIOLA, Paul; JONES, Michael J.. Robust Real-Time Face Detection. **International Journal Of Computer Vision**, Hingham, MA, USA, v. 57, n. 2, p.137-154, May 2004. Springer Nature. <http://dx.doi.org/10.1023/b:visi.0000013087.49260.fb>. Disponível em: <<http://www.vision.caltech.edu/html-files/EE148-2005-Spring/pprs/viola04ijcv.pdf>>. Acesso em: 10 ago. 2014.

WANG, Longqi; ZHANG, Yao; LIE, Seng Tjhen. Detection of damaged supports under railway track based on frequency shift. **Journal of Sound and Vibration**, [S.l.], v. 392, p.142-153, Mar. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.jsv.2016.11.018>.

WEYNE, Gastão Rúbio de Sá. Determinação do tamanho da amostra em pesquisas experimentais na área da saúde. **Arquivos Médicos do Abc**, Santo André, Sp, v. 29, n. 2, p.87-90, jul. 2004. Semestral. ISSN 2358-0739. Disponível em: <<https://www.portalnepas.org.br/amabc/article/view/301/282>>. Acesso em: 20 dez. 2014.

YELLA, Siril et al. Classifier Fusion for condition monitoring of wooden railway sleepers. **Engineerit: Measurement & instrumentation**, [S.l.], n. 11, p.32-35, May 2008. Disponível em: <http://www.ee.co.za/wp-content/uploads/legacy/AutT_other.pdf>. Acesso em: 20 dez. 2014.

YELLA, Siril; GHIAMATI, Samira; DOUGHERTY, Mark. Condition monitoring of wooden railway sleepers using time-frequency techniques and pattern classification. **2009 Ieee International Conference On Systems, Man And Cybernetics**, [S.l.], p.4269-4274, Oct. 2009. DOI: 10.1109/ICSMC.2009.5346713. Disponível em: <<https://pdfs.semanticscholar.org/c3e8/b019332aa033cced325d6a3b0d42fddf1d04.pdf>>. Acesso em: 10 abr. 2017.

YELLA, Siril; GUPTA, Narendra K.; DOUGHERTY, Mark. Automating condition monitoring of wooden railway sleepers. **EngineerIT: Measurement & instrumentation**, [S.l.], n. 5, p.68-71, Oct. 2007. Disponível em: <http://www.ee.co.za/wp-content/uploads/legacy/MeasTech_Automating_condition.pdf>. Acesso em: 20 dez. 2014.

YELLA, Siril; RAHMAN, Asif Shaik; DOUGHERTY, Mark. Pattern recognition for classifying the condition of wooden railway sleepers. **2010 International Conference On Multimedia Computing And Information Technology (MCIT)**, [S.l.], p.61-64, Mar. 2010. IEEE. <http://dx.doi.org/10.1109/mcit.2010.5444850>.

APÊNDICE A – Métricas de desempenho na literatura

As métricas de desempenho na literatura que dizem respeito à avaliação de defeitos em dormentes e que puderam ser estimadas encontram-se em seguida, identificadas por cada artigo. Os classificadores utilizados são *support vector machine* (SVM), *multi-layer perceptron* (MLP), *radial basis function neural networks* (RBFNN), *gaussian mixture models* (GMM), *learning vector quantisation* (LQV) e serão identificados pelas siglas entre parêntesis.

Yella, Gupta e Dougherty (2007) apresenta apenas a acurácia da implementação para a avaliação de impacto acústico, visão computacional e a fusão destas duas implementações. Não foi possível determinar outras métricas por causa da ausência de mais informações publicadas no artigo.

Tabela 18 – Métricas de desempenho possíveis extraída de Yella, Gupta e Dougherty (2007)

Etapa do algoritmo	Classificador	Acurácia	Sensitividade	Especificidade	Precisão	Valor pred. Neg.
Classificadores de impacto acústico	SVM	76%	-	-	-	-
	MLP	74%	-	-	-	-
Classificadores de visão computacional	SVM	90%	-	-	-	-
	MLP	90%	-	-	-	-
Fusão dos resultados de impacto acústico e visão computacional	SVM	88%	-	-	-	-
	MLP	84%	-	-	-	-

Fonte: elaborado pelo autor

Yella et al. (2008) apresenta a classificação dos defeitos em dormentes para vários classificadores atuando sobre as características obtidas com visão computacional e o melhor destes classificadores (em termos de acurácia) foi combinado utilizando novamente um classificador em uma outra camada. O artigo apresenta a acurácia das implementações e com outras informações do artigo foi possível estimar as demais métricas.

Tabela 19 – Métricas de desempenho possíveis extraída de Yella et al. (2008)

Etapa do algoritmo	Classificador	Acurácia	Sensitividade	Especificidade	Precisão	Valor pred. Neg.
Classificadores de visão computacional (1ª camada)	MLP	90%	79%	94%	85%	92%
	RBFNN	86%	57%	97%	89%	85%
	GMM	88%	64%	97%	90%	88%
	LQV	86%	57%	97%	89%	85%
	SVM	90%	64%	100%	100%	88%
Combinação da resposta do Classificador MLP e SVM (2ª camada)	MLP	92%	71%	100%	100%	90%

Fonte: elaborado pelo autor

Yella, Ghiamati e Dougherty (2009) apresenta apenas o desempenho para a avaliação acústica da resposta dos dormentes a impactos. Para a extração de características utiliza-se dois métodos de transformada de sinais: *short-time Fourier transform* (STFT) e *discrete wavelets transform* (DWT).

Tabela 20 – Métricas de desempenho possíveis extraída de Yella, Ghiamati e Dougherty (2009) – 1º nível de classificação

Transformada	Classificador	Acurácia	Sensitividade	Especificidade	Precisão	Valor pred. Neg.
	MLP	82%	43%	97%	86%	81%
STFT	RBFFN	74%	21%	94%	60%	76%
	SVM	82%	43%	97%	86%	81%
	MLP	78%	36%	94%	71%	79%
DWT	RBFFN	74%	21%	94%	60%	76%
	SVM	72%	21%	92%	50%	75%

Fonte: elaborado pelo autor

Tabela 21 – Métricas de desempenho possíveis extraída de Yella, Ghiamati e Dougherty (2009) – 2º nível de classificação

Transformada	Classificador	Acurácia	Sensitividade	Especificidade	Precisão	Valor pred. Neg.
STFT (Respostas dos classificadores SVM e MLP anteriores)	SVM	84%	43%	100%	100%	82%
DWT (Respostas dos classificadores SVM e MLP anteriores)	SVM	78%	43%	92%	67%	80%

Fonte: elaborado pelo autor

Por fim, Yella, Rahman e Dougherty (2010) expõe o resultado final depois de combinar o processamento das características da imagem com características do sinal acústico obtido do impacto aos dormentes. São apresentados os resultados do classificador SVM para os lados esquerdo e direito, separadamente, e depois combinados em uma única resposta.

Tabela 22 – Métricas de desempenho possíveis extraída de Yella, Rahman e Dougherty (2010)

Transformada	Classificador	Acurácia	Sensitividade	Especificidade	Precisão	Valor pred. Neg.
Lado esquerdo	SVM	84%	43%	100%	100%	82%
Lado direito	SVM	82%	43%	97%	86%	81%
Fusão dos dois lados	SVM	86%	57%	97%	89%	85%

Fonte: elaborado pelo autor