



DETEÇÃO E IDENTIFICAÇÃO DE DANO EM RODAS DE VEÍCULOS FERROVIÁRIOS BASEADA NA RESPOSTA DINÂMICA INDUZIDA PELO VEÍCULO NA VIA

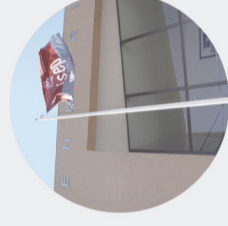
ANTÓNIO MIGUEL CARVALHO GUEDES

novembro de 2022

isep

INSTITUTO SUPERIOR DE ENGENHARIA DO PORTO
MESTRADO EM ENGENHARIA CIVIL

INSTITUTO SUPERIOR DE
ENGENHARIA DO PORTO



isep

isep Instituto Superior de
Engenharia do Porto

Deteção e Identificação de Dano em Rodas de Veículos Ferroviários Baseada na Resposta Dinâmica Induzida pelo Veículo na Via

Deteção e Identificação de Dano em Rodas de Veículos
Ferroviários Baseada na Resposta Dinâmica Induzida pelo Veículo na Via

ANTÓNIO MIGUEL CARVALHO GUEDES
Outubro de 2022

Instituto Superior de Engenharia do Porto • Rua Dr. António Bernardino de Almeida, 431 • 4249-015 Porto
Tel. +351 228 340 500 • Fax +351 228 321 159 • mail@isep.iupp.pt • www.isep.iupp.pt

POLITÉCNICO
DO PORTO

ANTÓNIO MIGUEL CARVALHO GUEDES
Outubro de 2022



**DETEÇÃO E IDENTIFICAÇÃO DE DANO EM RODAS DE VEÍCULOS
FERROVIÁRIOS BASEADA NA RESPOSTA DINÂMICA INDUZIDA PELO
VEÍCULO NA VIA**

ANTÓNIO MIGUEL CARVALHO GUEDES

Dissertação submetida para satisfação parcial dos requisitos do grau de

MESTRE EM ENGENHARIA CIVIL – RAMO DE ESTRUTURAS

Orientador: Prof. Dr. Diogo Rodrigo Ferreira Ribeiro

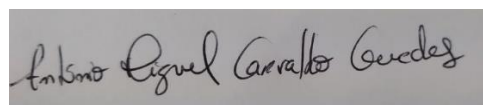
Co-Orientador: Prof. Dr. Pedro Aires Moreira Montenegro e Almeida (Faculdade de Engenharia da Universidade do Porto – FEUP)

Co-Orientador: Dra. Andreia Gomes Meixedo (Faculdade de Engenharia da Universidade do Porto – FEUP)

OUTUBRO DE 2022

Eu, António Miguel Carvalho Guedes, estudante nº1090119, do Mestrado em Engenharia Civil do Instituto Superior de Engenharia do Porto, declaro que não fiz plágio nem auto-plágio, pelo que o trabalho intitulado “Detecção e Identificação de Dano em Rodas de Veículos Ferroviários Baseado na Resposta Dinâmica Induzida pelo Veículo na Via” é original e da minha autoria, não tendo sido usado previamente para qualquer outro fim. Mais declaro que todas as fontes usadas estão citadas, no texto e na bibliografia final, segundo as regras de referência adotadas na instituição.

Porto e ISEP, 2022/10/12

A rectangular box containing a handwritten signature in black ink. The signature reads "António Miguel Carvalho Guedes" in a cursive script.

ÍNDICE GERAL

Índice Geral.....	iii
Resumo.....	v
Abstract.....	vii
Agradecimentos	ix
Índice de Texto xi	
Índice de Figuras.....	xiii
Índice de Tabelas.....	xix
CAPÍTULO 1 Introdução.....	1
CAPÍTULO 2 Estado da Arte.....	7
CAPÍTULO 3 Caso de Estudo: Modelação Dinâmica do Sistema Veículo-Via	61
CAPÍTULO 4 Metodologia de Detecção e Identificação de Poligonização em Rodas Baseado nas Respostas Induzidas por Tráfego.....	73
CAPÍTULO 5 Conclusões e Desenvolvimentos Futuros	103
Referências Bibliográficas	107

RESUMO

A presente dissertação foca-se no desenvolvimento e aplicação de uma metodologia de detecção e identificação de danos nas rodas de um veículo ferroviário de mercadorias do tipo Laagrss, baseada em respostas dinâmicas induzidas por este na via. Foi adotado o sistema de monitorização *Wayside* composto por um conjunto de acelerómetros instalados nos carris da via-férrea, em que a identificação do dano nas rodas estabelece-se por um processo indireto.

Foi dado especial ênfase à detecção e identificação de anomalias relacionadas com imperfeições na circularidade das rodas, denominadas de poligonização. O conjunto de dados representativo das condições das rodas foi adquirido com o recurso a modelos numéricos de interação entre o veículo e a via considerando diferentes cenários.

Assente num método não supervisionado e remoto, foi aplicado neste trabalho uma metodologia de monitorização da condição das rodas do veículo ferroviário, com recurso a técnicas de análise e tratamento de dados multivariados baseadas em inteligência artificial. Foi realizada a extração de indicadores sensíveis ao efeito da poligonização nas rodas com recurso a modelos autorregressivos (AR) e autorregressivos com entradas exógenas (ARX), análises de componentes principais (PCA) e transformadas wavelet (CWT).

Posteriormente, foi utilizado técnicas de normalização de dados em relação a fatores ambientais e operacionais (baseados em PCA). Finalmente, foi desenvolvido e aplicado técnicas de classificação de dados capazes de distinguir estados com e sem dano baseadas em análises Outliers e análise de Clusters para identificação da severidade do dano. A metodologia prova ser eficaz na detecção do dano com resultados bastante satisfatórios, relativamente à identificação da severidade são verificadas algumas falhas.

Palavras-chave: Detecção e Identificação de danos; veículo ferroviário; Laagrss; respostas dinâmicas; sensores; sistema de monitorização *Wayside*; poligonização nas rodas; réplicas digitais numéricas; tratamento de dados multivariados; inteligência artificial; extração de indicadores; modelos autorregressivos (AR); modelos autorregressivos com entradas exógenas (ARX); análises de componentes principais (PCA); transformadas wavelet (CWT); análises Outliers; análise de Clusters.

ABSTRACT

This dissertation focuses on the development and application of a methodology for wheel damage detection and identification of a Laagrss type rail freight vehicle, based on dynamic responses induced by it on the track. The Wayside monitoring system was adopted, consisting of a set of accelerometers installed on the track rails, where wheel damage identification is established by an indirect process.

Special emphasis was given to the detection and identification of anomalies related to imperfections in the circularity of the wheels, called polygonisation. The data set representative of the wheel conditions was acquired with numerical models of interaction between the vehicle and the track considering different scenarios.

Based on an unsupervised and remote method, a methodology for monitoring the condition of the railway vehicle wheels was applied in this work, using multivariate data analysis and processing techniques based on artificial intelligence. The extraction of features sensitive to the effect of wheel polygonization was performed using autoregressive (AR) and autoregressive models with exogenous inputs (ARX), principal component analysis (PCA) and wavelet transforms (CWT).

Subsequently, data normalisation techniques were used in relation to environmental and operational factors (based on PCA). Finally, data classification techniques capable of distinguishing states with and without damage based on Outlier analysis and Cluster analysis were developed and applied to identify damage severity. The methodology proves to be effective in detecting the damage with very satisfactory results. Regarding the identification of the severity, some flaws are verified.

Keywords: Damage detection and identification; railway vehicle; Laagrss; dynamic responses; sensors; Wayside monitoring system; wheel polygonization; numerical digital replicas; multivariate data processing; artificial intelligence; features extraction; autoregressive models (AR); autoregressive models with exogenous inputs (ARX); principal component analysis (PCA); wavelet transforms (CWT); outlier analysis; cluster analysis.

AGRADECIMENTOS

Este espaço reserva-se a agradecer a todos aqueles que de alguma forma contribuíram para a realização do presente trabalho de dissertação. A todos expresso com amizade e admiração os meus sinceros agradecimentos.

Em primeiro lugar ao Prof. Doutor Diogo Ribeiro, fundamental em todas as etapas do trabalho, desde o incentivo para assumir vias mais desafiadoras como pela sua disponibilidade em todos os momentos colocando ao dispor as ferramentas necessárias para a elaboração do trabalho. Agradeço o positivismo e entusiasmos com que orientou o meu trabalho de dissertação, sem ele este trabalho não seria possível.

Aos meus orientados, Prof. Doutor Pedro Montenegro e Dra. Andreia Meixedo, pelo auxílio ao longo de todo o trabalho, especialmente na transmissão de conhecimentos técnicos, imprescindíveis para a resolução do mesmo. Tanto ou mais importante pela boa disposição e bom ambiente proporcionado.

Gostaria de agradecer a todos os membros da equipa WAY4SAFERAIL pelo agradável tempo passado em conjunto, especialmente ao Rúben Silva e Araliya Mosleh pelos conhecimentos partilhados, quer na interpretação e formulação de códigos como na troca de ideias em todas as fases do projeto.

Aos meus amigos de curso e do ISEP, Bruno Pereira, Cristiano Barroso, Felipe Simões, Gabriel Saramago, José Aleixo, Miguel Marques, Ricardo Mendes e Sérgio Ramos, pelos bons momentos partilhados dentro e fora do ISEP.

Por último, uma nota de carinho e afeto aos meus pais, avós, tios e primos.

ÍNDICE DE TEXTO

CAPÍTULO 1	Introdução.....	1
1.1	Enquadramento.....	1
1.2	Motivação.....	3
1.3	Objetivos.....	4
1.4	Estrutura da Tese.....	5
CAPÍTULO 2	Estado da Arte.....	7
2.1	Considerações Iniciais.....	7
2.2	Sistemas <i>Wayside</i> para Detecção de Danos.....	8
2.2.1	Sistemas Reativos.....	9
2.2.2	Sistemas Preditivos.....	14
2.3	Defeitos nas Rodas.....	26
2.3.1	Lisos nas Rodas.....	27
2.3.2	Poligonização nas Rodas.....	30
2.4	Técnicas Baseadas em IA de Detecção e Identificação de Danos.....	40
2.4.1	Levantamento de Metodologias Desenvolvidas na Literatura.....	41
2.4.2	Extração de Indicadores.....	43
2.4.3	Modelação de Indicadores – Métodos Regressivos e Métodos das Variáveis Latentes.....	48
2.4.4	Fusão de Dados.....	51
2.4.5	Discriminação de Indicadores – <i>Outlier analysis</i>	53
2.4.6	Classificação de Indicadores – <i>Cluster-based</i>	54
CAPÍTULO 3	Caso de Estudo: Modelação Dinâmica do Sistema Veículo-Via.....	61

ÍNDICE DE TEXTO

3.1	Descrição do Modelo Proposto.....	61
3.2	Modelação do Veículo - Laagrss.....	61
3.3	Modelação da Via.....	65
3.4	Modelação do Perfil de Irregularidade da Via	67
3.5	Modelação do Perfil de Irregularidade das Rodas	68
3.6	Interação Dinâmica Veículo-Via	69
CAPÍTULO 4 Metodologia de Detecção e Identificação de Poligonização em Rodas Baseado nas Respostas Induzidas por Tráfego.....		
4.1	Descrição da Metodologia	73
4.2	Simulações de Cenários de Base e de Dano.....	75
4.2.1	Cenários de Base.....	75
4.2.2	Cenários de Dano – Poligonização.....	78
4.2.3	Simulação Numérica	79
4.3	Detecção Automática de Poligonização nas Rodas	82
4.3.1	Extração de Indicadores.....	82
4.3.2	Modelação de Indicadores – Normalização (ACP).....	85
4.3.3	Fusão de Dados.....	87
4.3.4	Discriminação de Indicadores – Análise de <i>Outliers</i>	91
4.4	Estudo de Efetividade para Diferentes Configurações de Sensores	93
4.4.1	24 sensores	93
4.4.2	12 sensores	94
4.4.3	6 sensores	96
4.5	Identificação do Dano	97
CAPÍTULO 5 Conclusões e Desenvolvimentos Futuros		
5.1	Conclusões	103
5.2	Desenvolvimentos Futuros	106
Referências Bibliográficas.....		107

ÍNDICE DE FIGURAS

Figura 1.1 – Ciclo de Monitorização da Integridade Estrutural e suas vantagens, (Meixedo, 2021).	3
Figura 2.1 – Sistemas de monitorização a) embarcados e b) wayside (Ngigi et al.,2012).	8
Figura 2.2 – Detetor de equipamento de arrasto constituído por acelerómetros, (voestalpine, 2022). ...	11
Figura 2.3 – Sistema de deteção da temperatura nos rolamentos e rodas, (revistaitransporte, 2016)....	12
Figura 2.4 – Processo para identificar a roda e o rolamento do eixo, (Deilamsalehy et al., 2016).	13
Figura 2.5 – Visualização dos descritores de recursos HOG: a) roda normal; b) roda deslizante (Deilamsalehy et al., 2016).....	14
Figura 2.6 – Representação esquemática da abordagem proposta (Mosleh et al., 2019).	18
Figura 2.7 – Identificação da zona de influência (Barke e Chiu, 2005).	19
Figura 2.8 – Sistema de monitorização proposto por Mosleh et al. (2020).....	20
Figura 2.9 – Estrutura desenvolvida e aplicada por Mosleh et al. (2020).....	21
Figura 2.10 – Fluxograma da metodologia de deteção de lisos nas rodas, (Mosleh et al., 2022).	23
Figura 2.11 – Detetor do perfil da roda (wabteccorp, 2022).	24
Figura 2.12 – Resultante das componentes horizontais da força de reação: a) roda centrada; b) roda deslocada à direita (https://www.youtube.com/watch?v=KxU3tJDItxw).....	25
Figura 2.13 – EN 15313-2016: a) Acumulação de metal; b) Cavidade; c) Reentrância do piso; d) Fragmentação; e) Danos no chanfro; f) Defeito profundo no piso.....	26
Figura 2.14 – EN 15313-2016: Exemplos de rodas com lisos.	27
Figura 2.15 – Análises comparativas entre tensões quase-estáticas e tensões induzidas pelo efeito dinâmico de um liso na roda com L=60 mm (Wu e Chi, 2016).	28
Figura 2.16 – Desenho esquemático do efeito plano num rodado (Cao et al., 2020).	29
Figura 2.17 – Defeito periódico: (a) diagrama polar; (b) distribuição harmónica, (Liu e Zhai,2013).	31

Figura 2.18 – Defeito não periódico: (a) diagrama polar; (b) distribuição harmónica, (Liu e Zhai,2013). .	31
Figura 2.19 – (a) Ondulação com comprimentos de onda entre 50-70, (b) poligonização com comprimentos de onda entre 315mm e 630mm, (c) poligonização do rodado com três harmónicos, (d) poligonização com 20 harmónicos, (Tao et al., 2020).	33
Figura 2.20 – Ondulação na roda com um comprimento de onda aproximadamente igual a 30 mm (Tao et al., 2020).	34
Figura 2.21 – Poligonização na roda (Liao, 2020).	34
Figura 2.22 - Medições típicas de rodas com poligonização apresentando (a) 18 harmónicos, (b) 19 harmónicos, e (c) 24 harmónicos (Tao et al., 2020).	35
Figura 2.23 – Resultado de medições típicas de roda poligonal em comboios de alta velocidade na China descritas em coordenadas polares: (a) CHR2 MEU, (b) CRH3 MEU, e (c) CRH5 MEU com diâmetros nominais de 860 mm, 920 mm e 890 mm, respetivamente e amplitudes de desgaste iguais a 0,4mm (Tao et al., 2020).	35
Figura 2.24 – Processo de formação do desgaste poligonal na roda (Tao et al., 2020).	37
Figura 2.25 – Imperfeições circulares: excentricidade radial (Δr), (Müller et al., 2013).	37
Figura 2.26 – Esboço da roda e das variáveis de medição. Perfil radial R_x , raio médio da roda R_0 , distância circunferencial x e o ângulo correspondente φ , (Liao, 2020).	39
Figura 2.27 – Fluxograma da metodologia de deteção de danos (Meixedo et al., 2021a).	43
Figura 2.28 – Definição da ordem do modelo: a) função média AIC para vinte e dois modelos ARX (na, nb) independentes, de ordem crescente utilizando séries temporais de 100 cenários de base, b) precisão do modelo de acordo com a ordem do modelo ARX, (Meixedo, 2021).	47
Figura 2.29 – Distâncias maximizadas e minimizadas num processo <i>k-means clustering</i> (Bouzenad et al., 2019).	55
Figura 2.30 – Dissemelhanças matriciais obtidas a partir: a) condições de base, b) condições com e sem dano (azul-escuro – indicadores idênticos, amarelo – os mais diferentes), (Meixedo et al., 2021b). 56	
Figura 2.31 – Alocação de indicadores sensíveis a dano em diferentes <i>clusters</i> : a) índice de silhueta (SIL), b) centroides de <i>clusters</i> , c) <i>clusters</i> definidos para todas as condições estruturais, (Meixedo et al., 2021b).	57
Figura 2.32 – Fluxograma do procedimento de deteção de dano por via remota baseado em janelas móveis (Meixedo et al., 2021b).	59
Figura 3.1 –Visão geral do vagão de carga Laagrss, (Bragança et al.,2021).	62

Figura 3.2 – Modelo dinâmico do vagão de carga <i>Laagrss</i> (adaptado de: Mosleh et al.,2022).	62
Figura 3.3 – Modelo numérico do vagão de carga <i>Laagrss</i> (Bragança et al.,2021).	63
Figura 3.4 –Mola em lâminas de aço utilizada na suspensão do vagão: (a) desenho técnico; (b) pormenorização do conjunto com a caixa de eixos, (Bragança et al.,2021).....	65
Figura 3.5 – Modelo numérico da via: (a) representação estratificada, (b) modelo EF (Mosleh et al., 2022).	66
Figura 3.6 – Amostra dos perfis de irregularidade da via (lado direito): a) transversal; b) vertical.....	68
Figura 3.7 – Perfis de irregularidades da roda: a) 4-7 harmónicos; b) 10-13 harmónicos; c) 17-20 harmónicos.....	69
Figura 3.8 – Modelo de interação dinâmica veículo-via, (adaptado de Bragança et al., 2021).....	70
Figura 3.9 – Possíveis cenários de soluções válidas na procura do ponto de contacto, (Montenegro et al., 2022).	71
Figura 4.1 – Fluxograma das diferentes técnicas implementadas na estratégia de aprendizagem de máquina para a deteção e identificação de danos poligonais nas rodas dos veículos.....	74
Figura 4.2 – Cenários de base (referência) considerados (113 no total): a) Diferentes tipo de cargas uniformemente distribuídas, b) Desequilíbrio de cargas abaixo do limite.....	76
Figura 4.3 – Diferentes esquemas de carga (uniformemente distribuídos) considerados: a) carga total, b) ½ carga, c) vazio.	77
Figura 4.4 – Diferentes esquemas de desequilíbrio de cargas abaixo do limite considerados: a), b) desequilíbrio longitudinal (DES.1 e 2), c) desequilíbrio transversal (DES.3).....	77
Figura 4.5 – Esquema de localização do dano.....	78
Figura 4.6 – 90 cenários de dano considerados.	78
Figura 4.7 – Sistema de monitorização virtual - do lado da via.	79
Figura 4.8 – Séries temporais de acelerações no sensor 1 considerando o cenário de base, 5% de ruído e corte de frequência nos 500Hz: a) influência da velocidade, b) influência dos perfis de irregularidades da via, c) influência da carga.....	80
Figura 4.9 – Séries temporais de acelerações no sensor 1 considerando cenário de base e cenário com dano poligonal na roda do 1ºvagão com 5% de ruído e corte de frequência nos 500Hz: a) Todos os registos da passagem do veículo, b) pormenorização.....	81

Figura 4.10 – Séries temporais de acelerações no sensor 1 para diferentes severidades de dano poligonal na roda do 1ºvagão com 5% de ruído e corte de frequência nos 500Hz: a) Todos os registos da passagem do veículo, b) pormenorização.....	81
Figura 4.11 – Ordem do modelo AR/ARX: baseado em todos os cenários de base.....	82
Figura 4.12 – Extração de indicadores para todos os 113 cenários de base e cenários de dano – sensor 1: a) método autorregressivo AR, b) método autorregressivo ARX, c) transformadas contínuas wavelet CWT, d) análise de componentes principais PCA.....	85
Figura 4.13 – Normalização de indicadores para todos os 113 cenários de base e cenários de dano – sensor 1: a) método autorregressivo AR, b) método autorregressivo ARX, c) transformadas contínuas wavelet CWT, d) análise de componentes principais PCA.	87
Figura 4.14 – Fusão de indicadores para todos os 113 cenários de base e cenários de dano – sensor 12: a) método autorregressivo AR, b) método autorregressivo ARX, c) transformadas contínuas wavelet CWT, d) análise de componentes principais PCA.....	89
Figura 4.15 – Fusão de indicadores e de todos os sensores para os 113 cenários de base e cenários de dano: a) método autorregressivo AR, b) método autorregressivo ARX, c) transformadas contínuas wavelet CWT, d) análise de componentes principais PCA.	90
Figura 4.16 – Detecção automática de dano para todos os 113 cenários de base e cenários de dano baseada em indicadores: a) método autorregressivo AR, b) método autorregressivo ARX, c) transformadas contínuas wavelet CWT, d) análise de componentes principais PCA.	92
Figura 4.17 – Detecção automática de dano considerando 24 sensores para todos os 113 cenários de base e cenários de dano: a) baseado na técnica ARX; b) baseado na técnica CWT; c) baseado na técnica PCA.	94
Figura 4.18 – Detecção automática de dano considerando 12 sensores para todos os 113 cenários de base e cenários de dano: a) baseado na técnica ARX; b) baseado na técnica CWT; c) baseado na técnica PCA.	95
Figura 4.19 – Detecção automática de dano considerando 6 sensores para todos os 113 cenários de base e cenários de dano: a) baseado na técnica ARX; b) baseado na técnica CWT; c) baseado na técnica PCA.	97
Figura 4.20 – Severidade do dano para todos os 113 cenários de base e cenários de dano na roda do 1º vagão (lado direito): a) baseado na técnica AR; b) baseado na técnica ARX; c) baseado na técnica CWT; d) baseado na técnica PCA.	100
Figura 4.21 – Sistema de monitorização virtual – sensores intercalados.	100

Figura 4.22 – Severidade do dano para todos os 113 cenários de base e cenários de dano na roda do 1º vagão (lado direito) baseado na técnica CWT considerando sensores intercalados: 5 no lado esquerdo e 6 no lado direito..... 101

ÍNDICE DE TABELAS

Tabela 2-1 – Limite de comprimentos dos defeitos nas superfícies das rodas (EN 15313, 2016).....	29
Tabela 2-2 – Distinção entre poligonização e ondulação, (Peng, 2020).	32
Tabela 2-3 – Classificação de mecanismos de formação do efeito poligonal e ondulação nas rodas (Tao et al., 2020).....	36
Tabela 2-4 – Anexo G, EN 15313:2016 Valores admissíveis para o efeito de falta de arredondamento Δr_{mm}	38
Tabela 2-5 - Tipos de rodas com efeito poligonal (Song e Sun, 2018).	38
Tabela 3-1 – Propriedades geométricas e mecânicas do modelo numérico do vagão <i>Laagrss</i> (Bragança et al., 2021).....	64
Tabela 3-2 – Propriedades mecânicas da via (Mosleh et al., 2021).	66
Tabela 3-3 – Parâmetro de rugosidade para as classes da via FRA (Administração Ferroviária Federal)..	67
Tabela 3-4 – Coeficiente para a densidade espectral de potência (Administração Ferroviária Federal). .	67

CAPÍTULO 1

INTRODUÇÃO

1.1 ENQUADRAMENTO

Desde o seu surgimento até aos dias de hoje, o transporte ferroviário demonstra desempenhar um papel muito importante nas sociedades, inicialmente foi um componente fundamental na Revolução Industrial e atualmente tem vindo a ocupar um papel cada vez mais relevante na sociedade. É um meio de transporte eficaz e eficiente tanto para o transporte de passageiros como para o transporte de mercadorias, de pequenas e grandes quantidades de cargas, assim como em curtas e longas distâncias, (Langneböck, 2007). Num mundo cada vez mais interconectado, o transporte ferroviário desempenha um papel fundamental para a prestação de serviços, contribuindo expressivamente para o melhoramento das condições de vida das sociedades. Também é um meio de transporte sustentável do ponto de vista ecológico com emissões de gases com efeito de estufa reduzidas comparativamente com outros meios de transporte.

Apesar de ter havido um grande desenvolvimento nos veículos ferroviários desde as primeiras locomotivas a carvão, atualmente, com exceção dos comboios de levitação magnética, as rodas dos veículos ferroviários de passageiros e mercadorias continuam a ser materializadas em aço circulando sobre carris também em aço. Esta interface de contacto roda-carril estabelece um papel muito importante nos sistemas ferroviários, sendo neste ponto de contacto que se estabelecem forças dinâmicas de interação roda-carril possibilitando a aquisição de informações relevantes sobre variados fatores inerentes às condições de circulação, (Langneböck, 2007).

Portanto, a maioria dos sistemas de monitorização dos componentes do sistema ferroviária foca-se no controlo das condições da roda e carril, pois para além destes componentes representarem um elevado custo de manutenção, podem-se evitar graves acidentes associados a elevados prejuízos económicos e possíveis lesões humanas.

As rodas dos veículos ferroviários são parte integrante do sistema de circulação, desempenhando um papel preponderante na qualidade dos serviços do transporte ferroviários, passageiros e mercadorias. As rodas deterioram-se ao longo do tempo devido ao desgaste e fadiga, podendo apresentar diversas

imperfeições, tais como, poligonizações, lisos e descasques, alterando as características de contacto roda-carril e, conseqüentemente causar grandes forças de impacto, (Nielsen e Johansson, 2000).

Do ponto de vista da segurança ferroviária os defeitos nos rodados são uma das principais causas de acidentes, (Chong et al.,2010). Estes defeitos promovem efeitos negativos tanto no veículo como na via, aumentando os custos de manutenção. Falhas não previstas nas rodas podem levar à interrupção do normal funcionamento dos sistemas de transporte ferroviário, reduzindo a confiabilidade nesta modalidade de transporte.

De forma a serem atempadamente detetadas falhas nestes componentes, promovendo a minimização de danos causados por estes fenómenos de imperfeições circulares nas rodas e, conseqüentemente aumentar a vida útil das estruturas em funcionamento por via de sucessivas inspeções e operações de manutenção, é imprescindível a implementação de um sistema integrado de monitorização estrutural.

Face ao constante avanço tecnológico é possível desenvolver e implementar metodologias automáticas de deteção e identificação de dano nos sistemas ferroviários. Com a aplicação destas técnicas inteligentes não se pretende a total substituição das inspeções visuais já utilizadas há largas décadas, mas sim, a criação de um procedimento compatibilizado. Estas técnicas tradicionais de inspeção visual e controlo são dispendiosas, ocorrem de forma espaçada no tempo e estão sujeitas a erros, motivando a larga aplicação de sistemas de Monitorização da Integridade Estrutural (MIE), especialmente em infraestruturas recentes ou em sistemas que representam grande valor para a sociedade, como é o caso dos sistemas ferroviários, (Meixedo, 2021).

O controlo remoto dos sistemas, tendo por base a Inteligência Artificial (IA), é concebido de forma a serem emitidos alertas que identifiquem um possível dano no sistema inerente a um comportamento anormal do mesmo. A Figura 1.1 ilustra o ciclo de MIE e suas vantagens, no qual é definida a localização para instalação dos instrumentos de monitorização estrategicamente localizados, de forma a captar uma elevada magnitude de solicitações, possibilitando uma boa caracterização do comportamento do sistema. Posteriormente, com os dados adquiridos, processa-se o desenvolvimento das técnicas de identificação de dano.

Com recurso a metodologias de classificação automática de danos baseadas em ferramentas de análise de dados apoiadas numa estratégia de aprendizagem de máquina, estudos anteriores demonstram bons resultados na deteção de danos em rodas de veículos ferroviários, nomeadamente na deteção de lisos nas rodas, (Mosleh et al., 2022). Os estudos levados a cabo relativos à deteção automática de imperfeições circulares das rodas são maioritariamente relativos à deteção de defeitos não periódicos. Os elevados impactos induzidos pelas imperfeições são refletidos nas grandes amplitudes de oscilações de acelerações e extensões medidas, relativamente a rodas com e sem dano.

Torna-se assim cada vez mais fundamental que os sistemas de monitorização consigam ser o mais abrangentes possível, cobrindo a deteção e identificação do maior número de danos que possam ocorrer. Portanto, dentro deste objetivo, será da maior importância avaliar o efeito de outros tipos de imperfeições circulares nas rodas, nomeadamente a poligonização. A poligonização apesar de gerar impactos na via inferiores aos dos causados pelos defeitos não periódicos, como por exemplo os lisos nas rodas (Tao et al., 2020), devido à excitação promovida pelo fenómeno, pode originar danos severos tanto na via como no veículo. Sendo justificável uma especial atenção a este fenómeno. Além disso, o fenómeno da poligonização nas rodas carece de poucos estudos até agora, pelo que é vantajoso um estudo que avalie quais as ferramentas de análise e tratamento de dados multivariados com base em inteligência artificial que melhor se adequam para a deteção e identificação automática deste defeito, contribuindo assim para uma aplicação mais alargada das metodologias de monitorização remotas e não supervisionadas.

1.3 OBJETIVOS

Este trabalho enquadra-se no âmbito do projeto WAY4SAFERAIL – WAYside monitoring system FOR SAFE RAIL transportation, onde o principal objetivo é o desenvolvimento de ferramentas de monitorização da condição das rodas, contribuindo para a melhoria da segurança do transporte ferroviário. Alinhado com os objetivos do projeto, este trabalho pretende o desenvolvimento de uma ferramenta baseada numa metodologia numérica de IA para a deteção e identificação automática, com precisão, de anomalias existentes nas rodas do veículo ferroviário com base nos registos de acelerações medidos na via-férrea para a passagem do tráfego – sistema de monitorização *Wayside*. Os danos que se pretendem especificamente detetar no presente trabalho designam-se por poligonização nas rodas e, caracterizam-se geometricamente por irregularidades circulares e periódicas.

1.4 ESTRUTURA DA TESE

Esta dissertação encontra-se dividida em cinco capítulos, sendo que no presente capítulo é realizado um enquadramento do tema no meio alargado em que se insere, apresentação das motivações e objetivos principais de estudo e de desenvolvimento.

No Capítulo 2 é apresentado o estado da arte, sendo a secção 2.1 destinada a um enquadramento geral do que é tratado nas secções que compõem o capítulo; a secção 2.2 apresenta vários sistemas de monitorização de deteção de vários tipos de danos e fenómenos, desde os tradicionais ao mais recentes, considerando os aparelhos de medição instalados na via – sistemas de monitorização do lado da via, estando dividida em dois grandes grupos, designados por sistemas reativos e preditivos; a secção 2.3 aborda os defeitos nas rodas dos veículos ferroviários, predominantemente aqueles que são passíveis de serem geometricamente caracterizados; a secção 2.4 apresenta as variadas técnicas de identificação de danos utilizadas em contextos de aprendizagem de máquina. Será abordado os fundamentos teóricos de cada técnica e suas funcionalidades.

No Capítulo 3 são apresentadas as ferramentas numéricas utilizadas para a aquisição de dados indicativos do comportamento do sistema veículo-via, tratando-se concretamente de medições de acelerações na via, a secção 3.1 apresenta e justifica a metodologia numérica utilizada para a aquisição de dados, a secção 3.2 trata da modelação do veículo em estudo, primeiro é realizada uma descrição do veículo utilizado no estudo - vagão do tipo Laagrss, de seguida é apresentado o modelo numérico do vagão realizado no programa ANSYS®, destacando os elementos e métodos utilizados de forma a simular o real comportamento de cada componente principal do veículo, nomeadamente suspensões, massa e elementos de ligação dos componentes; a secção 3.3 retrata a modelação numérica da via, também com recurso ao programa de elementos finitos ANSYS®, com especial foco nos elementos de representação do solo de fundação, balastro, travessas e carris; a secção 3.4 e 3.5 tratam da modelação com recurso ao programa MATLAB® dos perfis de irregularidades da via e das rodas, respetivamente, definindo os tipos de irregularidades consideradas e seus pressupostos, nomeadamente qualidade da via e ordem dos harmónicos considerados na caracterização geométrica do dano nas rodas dos veículos; a secção 3.6 demonstra a ferramenta utilizada na formulação do problema de interação dinâmica do sistema veículo-via (VSI) resolvido em MATLAB®, tendo como principal função ligar todos os modelos numéricos do sistema veículo-via resolvendo o problema dinâmico em ordem a adquirir respostas (acelerações) nos pontos de controlo.

No Capítulo 4 é desenvolvida a metodologia de deteção automática de dano, concretamente de poligonização nas rodas dos veículos dos vagões, a secção 4.1 descreve a metodologia adotada, desde aquisição de dados às fases de classificação e identificação de dados; a secção 4.2 compreende as simulações dos cenários de base, constituindo a referência para uma linha de treino na abordagem de

CAPÍTULO 1

aprendizagem de máquina e as simulações dos vários cenários de dano, os principais parâmetros considerados nas análises têm que ver com a velocidade, tipo de cargas, irregularidades da via e irregularidades das rodas, também é analisado os resultados das análises e estabelecida a influência de cada um dos parâmetros considerados nos cenários adotados; na secção 4.3 é demonstrado os resultados das diferentes técnicas utilizadas nas etapas que constituem a metodologia de detecção automática de danos, tais como, a extração de indicadores, utilizando diferentes abordagens, a normalização de indicadores a efeitos ambientais e operacionais, a fusão de dados e classificação de dados; na secção 4.4 é efetuado um estudo de efetividade para um número reduzido de sensores e na secção 4.5 é demonstrado resultados quanto à fase de identificação automática do dano, baseada na classificação de dados em diferentes níveis de severidade.

Por último, no Capítulo 5, são apresentadas as conclusões e desenvolvimentos futuros.

CAPÍTULO 2

ESTADO DA ARTE

2.1 CONSIDERAÇÕES INICIAIS

Conceber uma metodologia de Monitorização da Integridade Estrutural (MIE) remota, isto é, contínua no tempo e automática, passa pelo conhecimento de quais os sistemas de identificação de danos que melhor se adequam ao caso prático em estudo, tanto na ótica de proporcionar condições de base para o desenvolvimento de metodologias eficientes e eficazes minimizando a propensão a erros; melhoramento de segurança e conforto, como na otimização económica sem comprometer a qualidade final do produto.

Outro desafio de grande importância, prende-se com o facto de que todos os processos inerentes à metodologia sejam obrigatoriamente automáticos e generalistas, eliminando-se assim a necessidade de uma intervenção pelo utilizador. Simultaneamente, ser adequado ao maior número de eventos possíveis que possam ocorrer sobre o sistema a monitorizar, quer de origem externa - efeitos das variações ambientais e operacionais, nomeadamente, mudanças de velocidade, ações da temperatura e da chuva e/ou inerentes a anomalias no próprio sistema.

Este capítulo tem como principal objetivo a constituição de uma base teórica, em consolidação com os trabalhos experimentais e numéricos desenvolvidos na arte para o desenvolvimento do trabalho proposto. Inicialmente aborda-se os diferentes sistemas de monitorização *Wayside*, os seus aspetos importantes relativamente aos diferentes campos de aplicação e funcionamentos, dividindo-se a secção entre dois grandes grupos de sistemas, reativos e preditivos. De seguida, são apresentados os defeitos nas rodas, no qual se destacam dois tipos de irregularidades superficiais circulares, lisos nas rodas e poligonização, a normativa associada a esta problemática e a caracterização geométrica de cada dano.

Por fim são apresentadas as técnicas que compõem todas as etapas de análise e tratamento de dados medidos. Abordam-se processos de extração de indicadores sensíveis a danos com recurso às respostas dinâmicas da estrutura, nomeadamente os baseados em modelos autorregressivos (AR) e autorregressivos com entradas exógenas (ARX), análise de componentes principais (PCA) e transformadas contínuas *wavelet* (CWT), desenvolvimento de técnicas de normalização de dados em relação a fatores

ambientais e operacionais, desenvolvimento de técnicas de classificação de dados capazes de distinguir estados com e sem dano no sistema/componente e classificação do dano quanto à sua severidade.

2.2 SISTEMAS *WAYSIDE* PARA DETECÇÃO DE DANOS

Os sistemas de monitorização do veículo são normalmente designados por sistemas do lado da via (*wayside*) e do lado do veículo (*on-board*), diferenciando-os a localização dos instrumentos/aparelhos de medição, na estrutura/via e no veículo, respetivamente, tal como ilustra a Figura 2.1.




Figura 2.1 – Sistemas de monitorização a) embarcados e b) *wayside* (Ngigi et al.,2012).

A monitorização do veículo através da aplicação de instrumentos de medição e sensores na estrutura é a metodologia frequentemente adotada para a deteção de defeitos no veículo causados pelas forças dinâmicas de interação veículo-via. Os defeitos nas rodas são uma das principais causas de aumento das forças de impacto. As rodas podem apresentar imperfeições discretas ou contínuas, tal como lisos e poligonização, respetivamente, (Neto, 2021). Estes problemas podem trazer consequências negativas não só à via, tais como fraturas nas travessas, danos na cabeça do carril, como também ao nível do próprio veículo, nomeadamente anomalias nas suspensões devido a cargas elevadas de impacto, sendo que num cenário extremo pode mesmo levar ao descarrilamento do veículo. Por estas razões é da maior importância usar técnicas inovadoras baseadas em metodologias de deteção de danos robustas capazes de detetar os defeitos em estágios precoces, evitando interrupções no normal funcionamento dos sistemas de transportes ferroviários. Assim como, possibilitar uma acertada e otimizada programação dos trabalhos de manutenção por parte dos gestores das infraestruturas, reduzindo os custos nas operações. Em suma para dotar a infraestrutura de maior segurança e conforto assim como evitar custos excessivos

relacionados com operações de manutenção volumosas, (Nielsen e Johansson, 2000). Também, de acordo com a revisão elaborada por Barke e Chiu (2005), salienta-se que a aplicação de sistemas de monitorização do lado da via é fundamental para identificar, em estágios precoces, diferentes cenários que promovem uma progressiva degradação do sistema via-veículo, nomeadamente rolamentos sobreaquecidos, fraturas nas rodas, tubos dos travões partidos, deslizamento das rodas e o impacto das rodas.

A aplicação de sensores na via permite a extração de um vasto leque de dados relativamente a todos os veículos que sobre ela circulam, dotando uma metodologia capaz de monitorizar as várias gamas de veículos com um número reduzido de sensores. O objetivo destes sistemas de monitorização é limitar os danos e perdas de capital. Focam-se maioritariamente na deteção de danos nos componentes dos rodados e bogies, pois têm um maior impacto no desempenho do veículo e representam a maior percentagem dos custos de manutenção. Evidencia-se pelos bons resultados em campanhas de inspeção e rácio benefício-custo muito superior ao sistema em que os aparelhos de monitorização estão aplicados no lado do veículo. De acordo com Langneböck (2007), os sistemas embarcados em veículos para deteção de danos no próprio veículo são bastante onerosos, devido ao facto de ser necessário instalar sensores em todos os veículos tornando o método economicamente inviável uma vez que os custos seriam superiores em relação ao custo de manutenção ou reparação causada pelos danos que se pretendem antever, nesta relação descarta-se eventuais cenários que possam colocar a segurança ferroviária em risco. Para além de originar um elevado custo de instalação, o grande número de veículos existentes representa um grande desafio de organização e manutenção da tecnologia para deteção de danos em cada um deles.

De acordo com Langneböck (2007), os sistemas de monitorização são classificados em reativos ou preditivos, sendo o tempo de intervalo entre o alerta e a intervenção um dos principais fatores que os distinguem. Os sistemas reativos transmitem informação para intervenções imediatas, por outro lado os sistemas preditivos tendem a acompanhar o desenvolvimento do desempenho dos componentes do sistema veículo-via ao longo do tempo.

Nas próximas secções serão abordados alguns exemplos de sistemas reativos e preditivos, nas quais será dado uma maior ênfase aos sistemas preditivos por se enquadrar no âmbito da presente dissertação.

2.2.1 Sistemas Reativos

Existem falhas ou anomalias que não passíveis de serem previstas, pelo que para estas situações os sistemas reativos são significativamente importantes. Estes sistemas usam os dados adquiridos de forma a emitir alertas para atuação imediata por parte dos operadores. Apesar dos dados poderem ter características que permitam o seu uso de forma preditiva, estes sistemas apenas são concebidos para

uma atuação reativa, (Langneböck, 2007). Alguns exemplos de sistemas e tecnologias de detecção de danos utilizadas de uma forma reativa são:

- Detetor de Equipamento de Arrasto,
- Detetor de Caixa Quente e Detetor de Roda Quente/Fria,
- Detetor de Roda Deslizante.

2.2.1.1 Detetor de Equipamento de Arrasto

Os detetores de equipamento de arrasto são implantados para detetar e alertar em tempo real os controladores de tráfego ou maquinistas sobre objetos que se arrastam por baixo do veículo durante a circulação. Ao desvincularem-se parcialmente ou totalmente dos seus sistemas, os equipamentos de arrasto podem danificar a via-férrea e outros veículos.

A detecção de equipamento de arrasto pode ser realizada tanto por simples mecanismos mecânicos como recorrendo a alternativas tecnologicamente mais avançadas. Os sistemas fornecem informações relativas ao posicionamento do equipamento de arrasto no comboio, nomeadamente o lado do impacto e a sua magnitude. Os detetores mecânicos são constituídos por placas dispostas entre e para além dos carris. As placas admitem uma determinada deslocação durante o impacto de forma a transferir parte da energia de choque em movimento preservando a integridade do material constituinte, após uma ocorrência as placas reposicionam-se estando aptas para futuras detecções. O sistema é conectado a um sistema de rádio emitindo um alerta ao maquinista/operador sempre que as placas se movimentem, (Barke e Chiu, 2005).

Além dos mecanismos tradicionais, são também usados sistemas constituídos por sensores de detecção de impacto instalados em caixas de aço sobre as travessas entre os carris e foras destes, tal como ilustrado na Figura 2.2. As caixas são resistentes o suficiente ao impacto de equipamentos permitindo a detecção de consecutivas ocorrências, (Barke e Chiu, 2005).



Figura 2.2 – Detetor de equipamento de arrasto constituído por acelerómetros, (voestalpine, 2022).

Técnicas de deteção por imagem também podem ser adotadas, em que as imagens capturadas na passagem dos veículos são comparadas com os perfis esperados para a deteção de possíveis desvios entre os perfis espectados e o perfil fotografado, (Barke e Chiu, 2005).

2.2.1.2 Detetor de Caixa Quente e Detetor de Roda Quente/Fria

Os sistemas de deteção de caixa quente e de roda quente/fria (Figura 2.3) são sistemas similares, usados desde a década de 1960 foram concebidos para detetar o sobreaquecimento nos rolamentos dos eixos assim como baixas e altas temperaturas nas rodas, estes efeitos representam um grande perigo para a segurança no transporte ferroviário, podendo levar ao descarrilamento. A falta de lubrificação dos rolamentos ou mau funcionamento mecânico originam um aumento de fricção interna nas peças causando um significativo aumento da temperatura. Os rolamentos podem apresentar defeitos e não apresentar uma grande variação de temperatura, porém quando estão prestes a emperrar sucede-se um grande aumento da temperatura tornando o tempo de deteção até ao estado de completa falha bastante curto, cerca de 30-60 segundos, (Barke e Chiu, 2005; Langneböck, 2007). Problemas nos travões também podem levar ao sobreaquecimento da roda. Quando os sistemas de travagem funcionam corretamente a velocidade do veículo é controlada sem que as rodas parem de rolar. Porém, em situações de mau funcionamento dos travões, as rodas podem ficar bloqueadas. Estas situações promovem à ocorrência de deslizamento da roda ao longo da via e, conseqüente sobreaquecimento na parte inferior da roda, no ponto de contacto com a via. Por outro lado, um mau funcionamento no mecanismo de travagem e fraco desempenho dos travões, pode originar uma baixa de temperatura nas rodas, (Langneböck, 2007).




Figura 2.3 – Sistema de detecção da temperatura nos rolamentos e rodas, (revistaitransporte, 2016).

Inicialmente, os detetores de caixa quente eram baseados num sistema constituído por resistores térmico responsivos no qual mediam a radiação infravermelha proveniente dos rolamentos ou roda. Evidenciando-se serem mais confiáveis, os sistemas de sensores piroelétricos foram substituindo os anteriores sistemas, (Barke e Chiu, 2005).

Barke e Chiu (2005) refere que um fabricante produziu um detetor de caixa quente baseado num aparelho de captação de fotões de alta velocidade, tornando a resposta do dispositivo bastante mais rápida do que os anteriores sistemas, possibilitando inspecionar veículos a operar em velocidades até 360 km/h.

De acordo com estudo de Tarawneh et al. (2019), os detetores de caixa quente não são eficazes quando instalados na via-férrea. A medição unicamente da temperatura não se evidenciou um bom indicador, pois em muitas situações o sistema de deteção não diferenciava rolamentos com e sem defeito. Porém, as investigações mostraram resultados com maior confiabilidade quando os sistemas são aplicados diretamente nas caixas dos rolamentos.

2.2.1.3 Detetor de Roda Deslizante

Tal como referido na secção anterior, as falhas nos sistemas de travagem, o mau funcionamento dos travões e os erros operacionais podem levar à derrapagem das rodas, aumentando a temperatura da roda na zona de contacto roda-carril. A temperatura pode ser usada como indicador de desempenho do veículo sendo que já foram mencionados atrás vários sistemas de deteção baseados nessa análise. Os autores Barke e Chiu (2005) e Langnebäck (2007) apontam que o efeito de roda deslizante origina lisos nas rodas, promovendo consequentemente elevadas cargas de impacto e insegurança na condução que, em situações limite podem levar ao descarrilamento.

De acordo com Barke e Chiu (2005) o processamento digital de imagens óticas pode ser utilizado para detetar o efeito de roda deslizando, o método consiste em equipar as rodas com pontos de identificação, como por exemplo pontos brancos, uniformemente espaçados e verificar se as rodas estão a rolar normalmente de acordo com a sequência de leituras das posições dos pontos. Se entre duas leituras o mesmo ponto alterar de posição a roda está a rolar, por outro lado se não houver mudanças de posição é sinal que está a deslizar. A leitura da posição dos pontos brancos em função da velocidade do veículo é considerada também para analisar ou prever se as rodas estão a rolar normalmente, parcialmente ou a deslizar.

Uma outra forma de avaliar o movimento das rodas é através de um método mecânico. O método de deteção consiste em colocar um rolamento em contacto com flange das rodas, sendo o ângulo de rotação do rolamento medido por um codificador ótico e, pela direção do movimento do rolamento prevê-se se a roda está a rolar normalmente ou a deslizar. Caso o rolamento rolar no sentido contrário à roda é indicativo de que a roda está a rolar normalmente se o rolamento rolar no sentido do movimento do veículo a roda estará a deslizar, (Barke e Chiu, 2005).

Os estudos realizados por Deilamsalehy et al. (2016) propõem um sistema de deteção do efeito da temperatura nas componentes do veículo desenvolvendo um método de leitura computacional. Para tal, instalam-se câmaras térmicas na via de forma a monitorizar o aquecimento das rodas como também nos eixos dos rolamentos. Numa primeira fase, a partir das imagens térmicas, o algoritmo seleciona as partes do veículo a monitorizar de forma a não haver interferências de outras componentes incorporadas nos sistemas mecânicos. A Figura 2.4 mostra um exemplo de segmentação do processo, (Neto, 2021).




Figura 2.4 – Processo para identificar a roda e o rolamento do eixo, (Deilamsalehy et al., 2016).

De seguida, baseado na estratégia de aprendizagem de máquina supervisionado chamado vetor de suporte de máquina (SVM), o algoritmo responde de uma forma binária ao problema de deteção de dano, identificando se há ou não dano. Considerando dois cenários, com e sem dano, os autores utilizam o método do gradiente orientado por histograma (HOG) para a extração de indicadores sensíveis ao dano. Após a fase de aprendizagem o método é capaz de padronizar os diferentes estados e os resultados novos são enquadrados num dos dois grupos. Foi concluído pelos autores que o método é 100% eficaz tanto na fase de ensinamento do processo como para a fase de testes experimentais, (Neto, 2021). A Figura 2.5 mostra dois exemplos de imagens térmicas com a visualização dos descritores de indicadores HOG.




Figura 2.5 – Visualização dos descritores de recursos HOG: a) roda normal; b) roda deslizando (Deilamsalehy et al., 2016).

2.2.2 Sistemas Preditivos

Devido à transmissão da informação necessária sobre o real desempenho do sistema veículo-via, os sistemas preditivos apresentam grandes vantagens. A utilização destes sistemas promove o melhoramento da conceção de um plano de atividades de manutenção ajustando-o às necessidades, assim como permite uma eficiente utilização e reparação dos equipamentos. Contudo, as instalações destes sistemas, em comparação com os reativos, podem ser 7,5 vezes superiores, (Ouyang et al., 2009). Porém, a indústria ferroviária representa um papel muito importante na economia justificando-se a sua implementação e contínuo melhoramento destes sistemas, não sendo sistemas de alarme é desnecessário instalar os dispositivos de deteção ao longo de todo o troço da via-férrea, mas em locais estratégicos de passagem do maior número de veículos possíveis de diferentes modelos e categorias possibilitando a aquisição de um largo conjunto de dados. Também de notar, que apesar destes sistemas serem mais onerosos relativamente à sua aquisição e implementação justificam-se a prazo, promovem deteções e identificações de falhas em estágios iniciais no sistema conduzindo a um melhoramento da segurança do sistema ferroviário e a ganhos económicos futuros face aos custos iniciais, resultantes de um melhor planeamento de manutenção e intervenções atempadamente realizadas. Assim como um aumento da prevenção de fenómenos de descarrilamento, mesmo raros, caso ocorram podem representar incalculáveis perdas humanas e prejuízos económicos bastante elevados.

Com o avanço tecnológico torna-se possível a extração, processamento e tratamento de um maior número de dados do sistema veículo-via. A simulação numérica de interação veículo-via com recurso a ferramentas computacionais permite a adoção de sistemas de monitorização preditivos cada vez mais precisos e eficazes; estes sistemas recolhem informação necessária de forma a ser entendido o real desempenho das componentes da via e veículo ao longo do tempo, contrastando com os sistemas reativos muito usados até aos dias de hoje em que o alerta é dado em fases de inoperação iminente. Alguns exemplos de sistemas e tecnologias de deteção de danos utilizadas de forma preditiva são:

- Detetor Acústico de Rolamentos com Dano,
- Carga em Movimento,
- Detetor de Carga de Impacto da Roda,
- Detetor do Perfil da Roda,
- Detetor do Efeito de Lacete.

2.2.2.1 Detetor Acústico de Rolamentos com Dano

De acordo com a revisão elaborado por Barke e Chiu (2005), os métodos de deteção de defeitos nos rolamentos pela indicação acústica surgiram com o intuito de se desenvolverem sistemas de monitorização mais preditivos em relação aos existentes. Com o intuito de serem ultrapassadas as limitações dos sistemas reativos de deteção, nomeadamente os detetores de caixa quente, no qual a indicação de dano ocorre numa fase muito avançado, tal como descrito na secção 2.2.1.2. Estes sistemas de monitorização podem ser usados de forma a acompanhar o desenvolvimento do desempenho dos rolamentos do eixo permitindo determinar a altura adequada para realizar intervenções de manutenção.

Em cenários de danos, relacionado com a geometria do defeito, as vibrações produzidas nessas frequências originam a emissão de sons passíveis de ser caracterizados. O contacto entre o defeito no rolamento e as componentes internas produzem um certo ruído. Barke e Chiu (2005) referem que o sistema de monitorização acústico permite determinar a resposta do rolamento ao longo das passagens sem necessidade de remover a componente do sistema.

No mercado existem vários produtos que permitem a deteção de defeitos nos rolamentos do eixo de veículos que passam ao longo da via gravando os sons produzidos por cada rolamento, nos quais as gravações são feitas por microfones instalados na via. A fim de tornar a metodologia mais robusta e precisa são usados filtros de forma a remover os ruídos externos aos causados pelo evento do dano, (Barke e Chiu, 2005). Em Langneböck (2007) são descritos dois exemplos destes sistemas acústicos, *TADSTM* e *RailBAMTM*, ambos os produtos foram adotados nas vias ferroviárias Norte Americanas e Australianas apresentando resultados com boas avaliações.

A tecnologia não permite detetar todos os defeitos nos rolamentos, porém possibilita a previsão de certos danos o que representa uma melhoria face aos sistemas de deteção de caixa quente em que é medido um aumento de temperatura numa fase avançada de degeneração das componentes internas. Em Langnebäck (2007) foi concluído que estes sistemas reduzem o número de falhas dos rolamentos em serviço.

Uma abordagem idêntica foi utilizada em Amini et al. (2016) para deteção de danos nos rolamentos do eixo. Com recurso à análise de espectros temporais kurtosis (TSK) sobre os dados brutos extraídos elimina-se o ruído causado pelos motores, interação roda-carril, acelerações e desacelerações. Os autores concluíram que este método de análise pode melhorar a deteção de defeitos nos rolamentos do eixo, porém existe a possibilidade de indicações de falsos positivos, principalmente quando as amplitudes dos valores kurtosis são próximos dos sinais captados pelos ruídos. Na secção 2.4 aborda-se com maior pormenorização a técnica kurtosis e seus fundamentos teóricos.

2.2.2.2 Pesagem em Movimento

A pesagem da carga transmitida pelo veículo à via durante o movimento apresenta enormíssimas vantagens pois permite o controlo das cargas transmitidas sem que haja necessidade de interrupções da circulação contrastando com os métodos tradicionais de pesagem, possibilitando um planeamento do fluxo ferroviário sem grandes constrangimentos e significativos ganhos económicos.

A pesagem da carga em movimento pode ser obtida com recurso tanto a medidores de tensão como a acelerómetros, sendo comumente aceite que o sistema de pesagem constituído por medidores de tensão é mais vantajoso, uma vez que fenómenos de tensões de corte e momentos fletores são consequências diretas da carga aplicada, tal como mencionado em Mosleh et al. (2019). Um dos desafios da medição da carga estática enquanto o veículo move-se prende-se com o facto de não ser possível extrair diretamente a carga estática do veículo, devendo-se a que uma percentagem da carga transmitida pelo veículo à via é produzida pelos efeitos de inércia desenvolvidos pela massa do veículo em movimento – carga dinâmica. A resolução do problema passa pela adoção de abordagens estatísticas sobre os dados obtidos das medições dinâmicas por forma a obter-se a carga estática, esta abordagem foi proposta em Mosleh et al. (2019). Os resultados do trabalho mostraram ser satisfatórios, no entanto a metodologia proposta ainda carece de validação experimental. A Figura 2.6 representa esquematicamente a abordagem proposta.

- i. São calculados o valor das cargas de cada rodado (P_{dyn_w}) utilizando dados experimentais da passagem de um comboio. Também são identificadas as massas não suspensas de cada um dos conjuntos dos rodados (M_w).
- ii. São obtidas as cargas dinâmicas de um conjunto de rodados para 100 perfis de irregularidades. Foi arbitrado um valor de massa (M_s) e de carga (Q_s) de um conjunto de rodados conhecido, 2003 kg e 195000 N, respetivamente.
- iii. É gerado a distribuição das cargas dinâmicas considerando a passagem de um único rodado e 100 perfis de irregularidades (Q_i s). É calculado o valor médio (Q_i_mean) e o desvio padrão ($StdQ_i$).
- iv. É calculado o efeito da carga dinâmica (P_{dyn_s}) para um conjunto de rodas conhecido que passa por 100 perfis de irregularidades. O valor de P_{dyn_s} pode ser obtido pela subtração da carga estática (Q_s) ao valor médio das cargas dinâmicas (Q_i_mean).
- v. Quando passa um veículo a carga estática é estimada retirando-se a componente dinâmica da carga (P_{dyn_w}). Este passo é realizado pela subtração do valor da carga dinâmica conhecida (P_{dyn_s}) ao valor total da carga do veículo, afetado por um fator de correção que corresponde ao rácio entre as massas do conjunto de rodados do veículo (M_w) e a massa do conjunto das rodas conhecido (M_s).
- vi. É definido o intervalo de confiança e calculado a gama de valores da carga estática da seguinte forma:

$$Q_{w_min} = P_{dyn_w} - \frac{M_w}{M_s} \times (|P_{dyn_s} - Std_{Q_i} \times coef. |)$$

$$Q_{w_max} = P_{dyn_w} + \frac{M_w}{M_s} \times (|P_{dyn_s} - Std_{Q_i} \times coef. |)$$
(2.1)

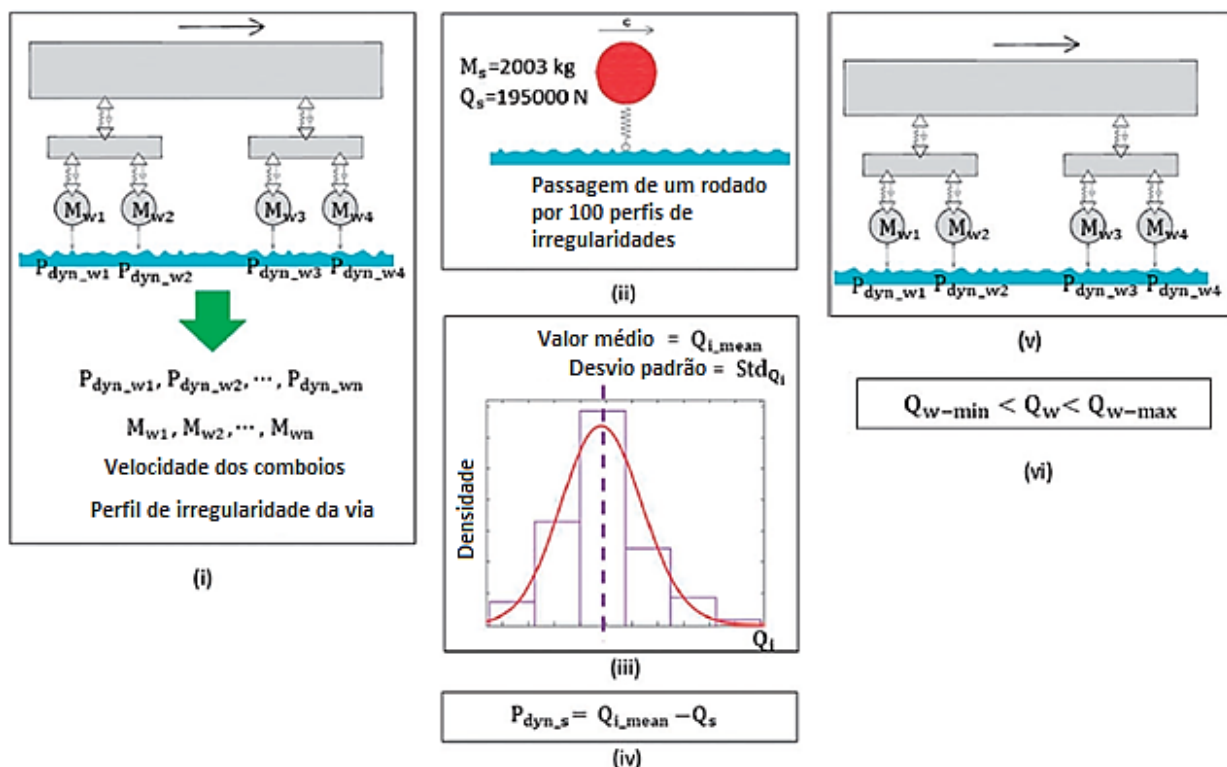


Figura 2.6 – Representação esquemática da abordagem proposta (Mosleh et al., 2019).

Tal como mencionado em Langneböck (2007), uma outra aplicação da metodologia baseada em medidores de tensão é a extração do peso exercido pelo veículo nos rodados/bogies em pontos de diferentes lados, estabelecendo-se a comparação entre os diferentes lados, assim como em rodados pertencentes a diferentes eixos, pode-se concluir se existe desequilíbrio de cargas no veículo tanto na direção transversal como na direção longitudinal.

2.2.2.3 Detetor da Carga de Impacto da Roda

Uma outra forma de avaliar o estado de conservação das rodas passa por estabelecer-se uma comparação entre a magnitude da carga de impacto da roda com valores limites, sendo estes valores referentes a forças dinâmicas de interação roda-carril quando a roda não apresenta defeitos. Em Ngigi et al. (2012) são apresentados vários sistemas disponíveis no mercado. É possível avaliar o estado das rodas quantificando a carga de impacto da roda entre duas travessas aplicada sobre o carril por dois métodos.

No primeiro método são usados medidores de tensão, cujo sensores podem estar aplicados entre duas travessas localizados no banzo inferior ou alma do carril. Durante a rotação da roda medem as forças dinâmicas de impacto induzidas pelo veículo na via assim como as forças estáticas, com recurso à avaliação da flexão do carril originada pelas forças de impacto. Os autores Barke e Chiu (2005), referem que devido ao facto de conceptualmente representar uma ligação direta entre a carga aplicada e o dano,

este método é transversalmente aplicado. No entanto, este método também apresenta algumas desvantagens. Uma vez que os dados obtidos não expressam a medição da passagem completa da roda, apenas podem ser considerados válidos os valores dentro das zonas de influência, isto é, entre dois extensómetros, tal como é retratado na Figura 2.7. Para além disso, o método de análise dos dados extraídos passa por calcular a carga nominal pela média dos valores sem considerar tanto o valor mais alto como o mais baixo. O rácio entre a carga de pico e a carga nominal pode ser utilizado para a deteção de defeitos nas rodas. Também, o rácio entre as cargas de pico de rodas relativas a diferentes bogies podem ser usadas para a deteção de falta de arredondamento nas rodas, (Nielsen e Johansson, 2001).




Figura 2.7 – Identificação da zona de influência (Barke e Chiu, 2005).

De acordo com levantamento realizado em Langneäck (2007), estes sistemas são amplamente utilizados na Austrália e Suécia, mostrando resultados bastantes confiáveis. De forma a cobrir a passagem completa de uma roda usam-se, no mínimo, uma série de pontos de medição ao longo de uma distância equivalente ao perímetro da roda.

No segundo método de análise são utilizados acelerómetros cuja função é medir a aceleração da vibração causada pela excitação dinâmica do veículo na via. Este método tem a vantagem de cobrir toda a via entre duas travessas, torna-se possível obter a leitura de dados relativamente à passagem da totalidade da roda. No entanto, os autores Barke e Chiu (2005) apontam a desvantagem de não existir relação direta entre a força instalada e os dados extraídos pelos sensores.

De acordo com Papaalias et al. (2014a) e Papaalias et al. (2014b), foi implementado um sistema de análise integrado e personalizado da vibração para detetar danos artificiais induzidos experimentalmente nas rodas. A severidade dos danos não é estabelecida com os dados brutos, sendo necessário um tratamento dos dados para tornar a metodologia mais robusta. Para além de que, a comparação dos danos só será válida quando as velocidades do veículo forem idênticas à testada experimentalmente.

Em Mosleh et al. (2020) com recurso a uma série de 12 extensómetros, tal como demonstrado na Figura 2.8, foi proposto uma metodologia diferente das retratados nas secções atrás. A metodologia tem como objetivo a deteção de defeitos nas rodas; concretamente lisos nas rodas. Os lisos nas rodas são superfícies planas originadas por efeitos de desgaste no ponto de contacto roda-carril.




Figura 2.8 – Sistema de monitorização proposto por Mosleh et al. (2020).

Os autores optaram por uma análise de espectro de envelope para deteção de lisos nas rodas, assim como testar, comentar e analisar a sensibilidade da abordagem relativamente às irregularidades da via, a posição aleatória do impacto provocado pelo liso da roda, diferentes intensidades de ruído e severidade do dano. Para tal, os autores realizaram simulações numéricas de interação veículo-via considerando diferentes velocidades e diferentes geometrias nos perfis de irregularidade da roda. O estudo conclui que uma simples transformação das respostas no domínio do tempo para o domínio da frequência é insuficiente para a deteção do defeito na roda por comparação com uma roda sem defeito. No entanto, quando aplicado o método proposto, verifica-se uma clara diferença nas amplitudes entre os valores do espectro de envelope no cenário de dano, tal não ocorre em cenários de rodas sem defeito. Prova-se assim a eficácia do método na deteção do liso na roda. A Figura 2.9 retrata a estrutura da implementação da metodologia de análise de espectro de envelope para deteção de lisos nas rodas. No qual, segundo o autor Randall, 2011, para realizar o espectro de envelope devem ser seguidos os seguintes passos:

- i. São consideradas as séries temporais de corte em cada extensómetro i , com uma frequência de amostragem (F_s) de 2000 Hz.
- ii. É realizada uma demodulação complexa do sinal, multiplicando o sinal pelo seguinte fator:

$$Y(t) = X(t)\exp(2\pi i f_0 t) \tag{2.2}$$

onde f_0 é a frequência central da banda.

- iii. É suavizado a série $Y(t)$ utilizando um filtro passa-baixo da seguinte forma:

$$W_x^L(t) = \sum_{u=-L}^L a_u Y(t+u) \tag{2.3}$$

onde $W_x^L(t)$ é a demodulação complexa do sinal no instante t . $\{a_u\}, u = -L, 0, L$ São os coeficientes não nulos do filtro passa-baixo. Além disso, uma vez que $W_x^L(t)$ é um valor complexo, a equação (2.6) torna-se em:

$$W_x^L(t) = |W_x^L(t)|\exp\{-i\vartheta_x^L(t)\} \tag{2.4}$$

onde $|W_x^L(t)|$ é a amplitude e $\vartheta_x^L(t)$ é a fase.

- iv. É calculado o valor do sinal do envelope como o dobro do valor absoluto do sinal analítico. Além disso, o enviesamento DC do envelope deve ser removido.
- v. É calculado o espectro de envelope utilizando o FFT.
- vi. A detecção de lisos nas rodas é avaliada com base num critério visual em que as respostas obtidas em cada um dos extensómetros do sistema são comparadas. Caso as respostas forem coincidentes em todos os extensómetros significa que não há lisos nas rodas, por outro lado na presença de lisos nas rodas as respostas apresentam amplitudes diferentes.

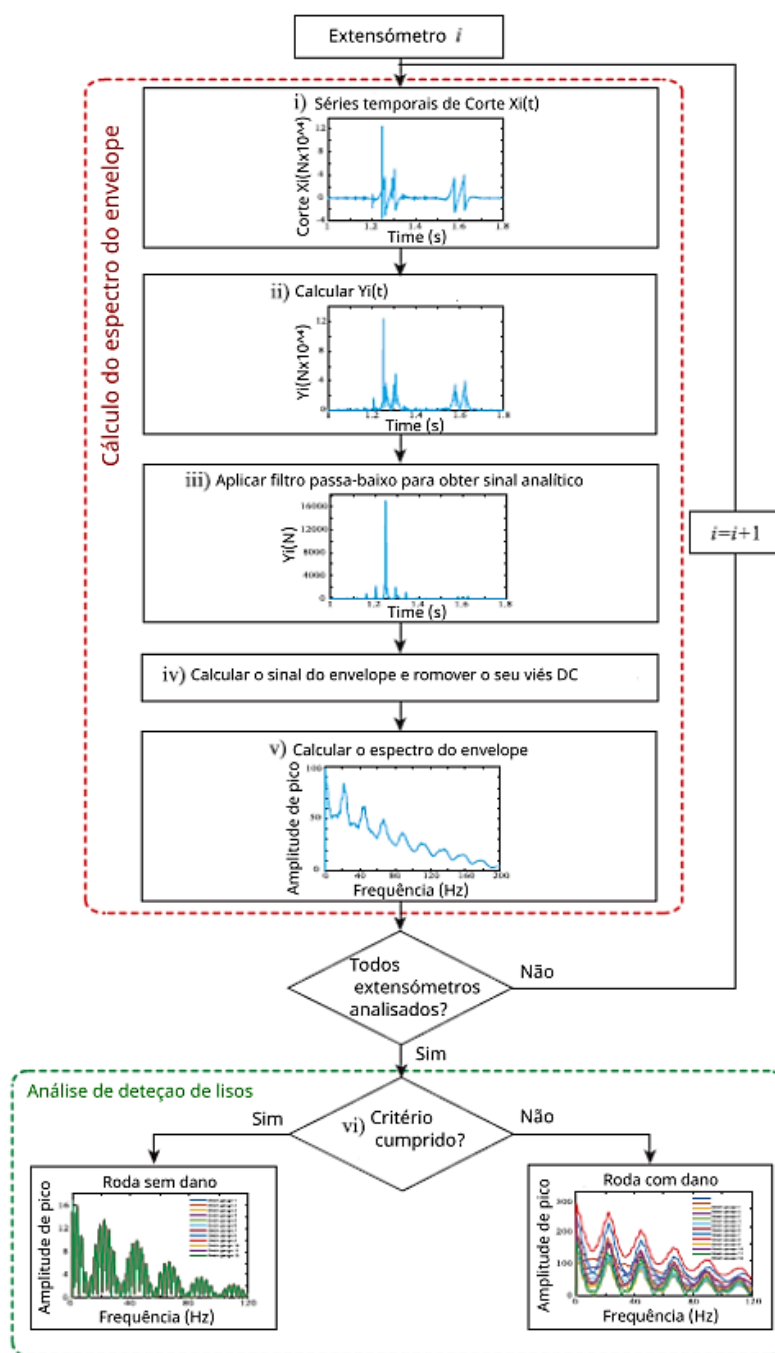


Figura 2.9 – Estrutura desenvolvida e aplicada por Mosleh et al. (2020).

Em Mosleh et al. (2022) foi desenvolvido uma metodologia remota e não supervisionada de detecção de lisos nas rodas, cujo objetivo é a detecção do dano estágios precoces. A metodologia é baseada nos dados das respostas das acelerações e extensões medidos por sensores instalados na via. Neste estudo também foram utilizadas simulações numéricas de interação veículo-via para a aquisição de dados (i). Para tal, utilizaram-se diferentes cenários de condições de operabilidade e de dano. Foram desenvolvidas ferramentas de detecção de lisos nas rodas baseadas em IA. Para tal, os autores recorreram à extração de indicadores sensíveis ao dano baseando-se em transformadas contínua *wavelet* (ii), à normalização dos dados aos efeitos de variações ambientais e operacionais com recurso à Análise de Componentes Principais (PCA) (iii), assim como a técnicas de fusão de dados utilizando a distância de Mahalanobis (iv) e classificação de indicadores por uma abordagem baseada numa distribuição probabilística por forma a distinguir uma roda com e sem lisos (v). Apenas considerando um sensor, foi concluído que a metodologia é eficaz na distinção entre uma roda com e sem lisos, permitindo minimizar os custos de instalação do sistema de monitorização. Independentemente da velocidade dos veículos, tipos e irregularidades, a metodologia evidenciou-se ser eficaz, sem a ocorrência de falsas deteções, na deteção do dano. Porém, a metodologia não foi validada experimentalmente. Na secção 2.4 apresentam-se os fundamentos teóricos das técnicas de tratamento de dados multivariados utilizadas. A Figura 2.10 ilustra o fluxograma da metodologia desenvolvida pelos autores.

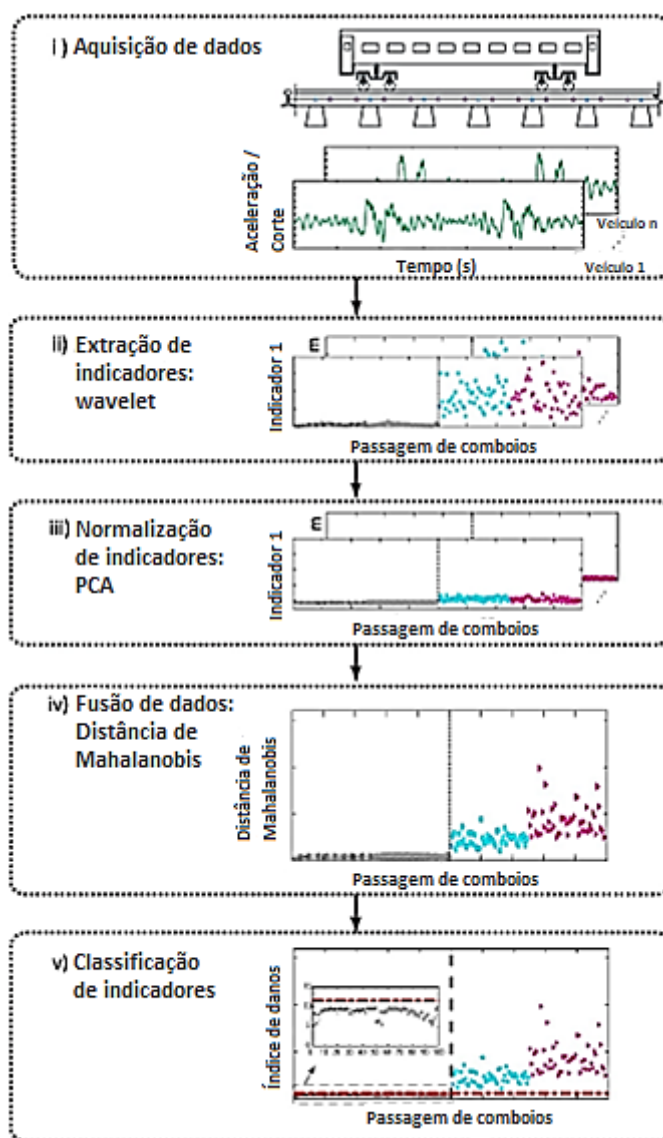


Figura 2.10 – Fluxograma da metodologia de detecção de lisos nas rodas, (Mosleh et al., 2022).

2.2.2.4 Detetor do Perfil da Roda

A monitorização do perfil da roda permite assegurar a estabilidade da circulação do veículo, verificar a taxa de desgaste e a resistência da roda e do carril, (Barke e Chiu, 2005). A monitorização do perfil da roda tem como objetivo captar informação necessária para uma correta ação de manutenção das rodas de cada veículo.

O sistema de monitorização mecânico baseado num mecanismo de contacto é utilizado para medir o perfil radial da roda. O sistema mecânico entra em contacto com a roda pressionando uma placa contra a flange da roda. Pressupondo-se que o verdugo da roda não apresenta desgaste ou dano, é possível a aquisição de indicadores de defeito ou desgaste da roda pela medição da altura relativa entre a superfície de contacto do sistema/flange da roda e a cabeça do carril, (Barke e Chiu, 2005).

Medições do perfil das rodas com tecnologias de lasers e câmaras são métodos sem contacto que determinam a condição das rodas. Para a definição do perfil da roda são capturadas imagens de uma câmara digital enquanto o laser serve como fonte de iluminação, aquando da passagem das rodas este sistema é ativado por meio de sensores. A filosofia passa por comparar o perfil da roda atual com o perfil padrão da roda sem dano, por forma a estabelecer-se uma comparação entre ambos e caso ocorra desvios, o mesmo seja reportado. Esta metodologia minimiza a necessidade de inspeções no local e permite a implementação de um planeamento de manutenção baseado na definição do perfil da roda gerado pela metodologia. Uma vez que os perfis das rodas gerados pelas imagens captadas estão distorcidos devido ao ângulo da câmara em relação à roda, antes da comparação entre o perfil da roda determinado e o perfil padrão é necessário efetuar-se um conjunto de correções. O mesmo procede-se quando a fonte de iluminação é a luz do ambiente natural. Após as correções é possível obter imagens tridimensionais das rodas onde são representadas as características principais das rodas, tais como, a altura do verdugo, a espessura do verdugo, espessura do aro, o diâmetro da roda e o ângulo de ataque, (Barke e Chiu, 2005). Com a aquisição das características geométricas das rodas ao longo do tempo é possível armazenar os dados, tornando possível traçar a tendência de desgaste das rodas e assim, prever a vida útil assim como danos futuros, (Neto, 2021). Na Figura 2.11 é demonstrado um exemplo dentro das muitas soluções comerciais existentes.



Figura 2.11 – Detetor do perfil da roda (wabteccorp, 2022).

2.2.2.5 Deteção do Efeito de Lacete

Devido à conicidade da roda, o veículo ferroviário apresenta um movimento ondulatório, denominado efeito de lacete. A conicidade da roda tem como principais funcionalidades corrigir o curso do veículo em relação ao centro do carril e promover a ação diferencial. A primeira funcionalidade permite corrigir

naturalmente a posição do veículo quando submetido a deslocamentos laterais provocados pelas diferentes solicitações a que as rodas estão sujeitas, dinâmicas e estáticas. O movimento ondulatório de correção natural deve-se à força autocentrada originada pela geometria cônica da roda, tal como observa-se na Figura 2.12 a), quando o ponto de contacto roda-carril está centrado as forças horizontais da força de reação anulam-se, porém quando ocorre um deslocamento horizontal para um dos lados a componente horizontal da força do lado para o qual ocorreu o deslocamento apresenta maior magnitude quando comparada com o seu par oposto, originando assim, um movimento de ambas as rodas na direção do centro do carril, Figura 2.12 b).




Figura 2.12 – Resultante das componentes horizontais da força de reação: a) roda centrada; b) roda deslocada à direita (<https://www.youtube.com/watch?v=KxU3tJDItxw>).

A segunda função da geometria cônica da roda é tornar possível que duas rodas ligadas por um mesmo eixo possam percorrer distâncias diferentes, tal como acontece em trechos curvos. Em trechos curvos as rodas tendem a deslizar na direção da curva, devido à sua forma cônica a roda que terá de percorrer uma maior distância apresentará também um maior perímetro de circulação da do seu par que terá de percorrer uma menor distância, assim para um mesmo ângulo de rotação torna-se possível que duas rodas ligadas por um mesmo eixo percorram distâncias diferentes obtendo-se a ação diferencial.

As forças laterais e verticais são registadas pelos medidores de tensão, o rácio entre as forças laterais e verticais (L/V) fornece uma indicação da probabilidade de descarrilamento, (Barke e Chiu, 2005). Torna-se possível a extração de informação das forças aplicadas na via direita e esquerda quando os medidores de tensão estão aplicados nos dois lados da via. Os sistemas de instabilidade nos bogies são manifestados por cargas dinâmicas de baixas frequências aplicadas pelo veículo sobre a via de circulação, (Barke e Chiu, 2005). Uma outra utilidade dos medidores de tensão é o de proporcionarem métodos de análise para a deteção de efeitos de instabilidade do veículo, nomeadamente o efeito de lacete e ângulo de ataque, sendo este último o ângulo gerado pelo alinhamento da roda em direção ao carril. Porém, os resultados

das forças extraídas pelos medidores de tensão são muito influenciados pela fricção entre a roda e o carril; coeficiente de fricção, sendo influenciado por diferentes fatores tais como, amplitudes térmicas, condições atmosféricas e sujidades ou contaminantes despojados na via, tal como folhas por exemplo.

Uma outra técnica para a deteção do efeito de lacete apontada pelos autores Blair e Barke (2003), consiste na determinação da posição de circulação das rodas e o ângulo de ataque com recurso a dispositivos óticos, para tal são usados lasers de localização de alcance direcionados para a superfície plana do lado da banda de rodagem, imediatamente acima do carril. Com estes dados obtém-se o ângulo da superfície plana da roda relativamente à cabeça do carril, pela comparação dos ângulos de ataque das rodas num bogie determina-se o alinhamento inter-axial, a deteção do efeito de lacete torna-se possível quando colocados dois destes sistemas óticos espaçados a uma curta distância.

2.3 DEFEITOS NAS RODAS

Existem variadas anomalias que podem surgir nas rodas, desde acumulação de metal, cavidades, reentrância do piso, fragmentação, sobreaquecimento, e muitas mais, abaixo na Figura 2.13 estão ilustrados alguns exemplos de defeitos.



a)



b)



c)



d)



e)



f)

Figura 2.13 – EN 15313-2016: a) Acumulação de metal; b) Cavidade; c) Reentrância do piso; d) Fragmentação; e) Danos no chanfro; f) Defeito profundo no piso.

Nesta secção serão abordados dois tipos de defeitos, lisos nas rodas e o efeito poligonal nas rodas. Estes tipos de danos podem ser caracterizados por expressões matemáticas, proceder à simulação numérica e

consequentemente incluir os perfis de falhas superficiais das rodas nas simulações de interação dinâmica do sistema veículo-via. Os resultados obtidos podem ser utilizados como dados de entrada num processo de aprendizagem de máquina, e assim conduzir ao desenvolvimento de uma metodologia de deteção automática de danos para identificação destes mesmos defeitos.

2.3.1 Lisos nas Rodas

Um plano na superfície de um rodado é designado por lisos nas rodas, conforme ilustra a Figura 2.14. Os mecanismos de formação de pontos planos nas rodas são causados pelo deslizamento da roda sobre o carril que podem ocorrer devido a vários fatores, tais como, sistemas de travagem com anomalias ou mal ajustados, elevadas forças de travagem em comparação com as forças de aderência entre o rodado-carril, defeitos no carril, objetos sobre o carril, por exemplo, folhas, assim como ações climáticas que promovam o aparecimento de gelo, neve ou geada sobre o carril.




Figura 2.14 – EN 15313-2016: Exemplos de rodas com lisos.

Em Wu e Chi (2016) foi conduzido um estudo em que se evidencia a diferença na tensão transmitida pela carga de impacto de uma roda com um liso. Com o comprimento do liso dado por $L_f=60\text{mm}$ e a velocidade de operação igual a 100km/h foram avaliados os estados de tensão em diferentes zonas dos rodados; pontos A,B,C,D e E. Quando comparado com uma carga quase-estática, pode ler-se na Figura 2.15 a diferença de tensões num sistema de coordenadas polares as significativas diferentes. Os pontos onde ocorrem as maiores flutuações de tensões são no ponto A e E, $23,2\text{ MPa}$ e $21,2\text{ MPa}$, respetivamente.

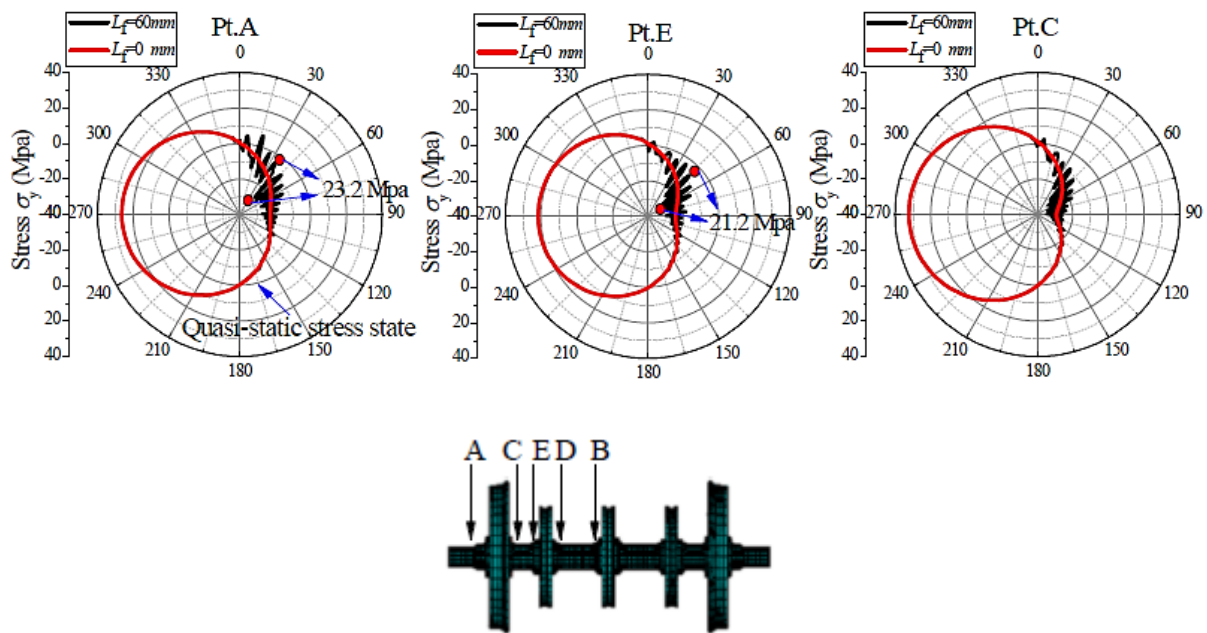


Figura 2.15 – Análises comparativas entre tensões quase-estáticas e tensões induzidas pelo efeito dinâmico de um liso na roda com $L=60$ mm (Wu e Chi, 2016).

2.3.1.1 Requisitos de Contratos de Uso e Normativos

De acordo com a *GCU – General Contract of Use for Wagons*, (2021), o comprimento plano máximo admissível de um rodado é de 60 mm para rodas com diâmetro igual a 840 mm. Geralmente os comprimentos planos considerados nas simulações numéricas dos sistemas de interação veículo-via variam entre 30-60 mm. Porém, de acordo com os estudos de Mosleh et al. (2022), comprimentos planos na ordem dos 20 mm já podem transmitir elevadas cargas de impacto implicando danos no sistema, pelo que é importante a detecção do efeito plano nas rodas em fases precoces.

De acordo com as ações normais e velocidades associadas à circulação, a norma EN 15313-2016 prevê um conjunto de valores limite relativamente aos comprimentos dos defeitos nas superfícies das rodas, constituindo um critério a adotar em operações de manutenção, nos quais os valores oscilam entre os 20-80 mm, conforme demonstra a Tabela 2-1.

Tabela 2-1 – Limite de comprimentos dos defeitos nas superfícies das rodas (EN 15313, 2016).

M		$M \leq 18$			$18 < M \leq 22,5$				$22,5 < M$		
V (km/h)		$V \leq 160$	$160 < V \leq 200$	$200 < V$	$V \leq 120$	$120 < V \leq 160$	$160 < V \leq 200$	$200 < V$	$V \leq 100$	$120 < V \leq 160$	$120 < V$
d	$1\ 000 < d$	80	60	40	80	60	50	35	X	X	X
	$840 < d \leq 1\ 000$	60	50	30	60	50	35	25	60	50	30
	$630 < d \leq 840$	40	30	25	40	30	25	20	40	X	X
	$550 < d \leq 630$	35	25	X	X	X	X	X	X	X	X
	$d < 550$	30	X	X	X	X	X	X	X	X	X

M : carga por eixo em toneladas (t).
 X reservado (não se conhece aplicação).
 d diâmetro da roda (mm).

2.3.1.2 Caracterização Geométrica

Na Figura 2.16 apresenta-se um esquema representativo das várias fases de desgaste até à formação de um liso no rodado completamente desgastado, em que numa fase intermédia da formação os cantos do liso não são arredondados apresentando a configuração de uma linha reta, contudo o contínuo desgaste da roda conduz à formação de cantos arredondados. Normalmente, a caracterização da forma dos cantos arredondados torna-se difícil, pelo que é usual adotar-se uma aproximação considerando os cantos não arredondados, tal como apresentado na fase intermédia de desgaste (linha tracejado a vermelho, Vale (2021)). Também, é possível visualizar as variáveis do efeito de liso nas rodas correlacionadas entre si, sendo d a espessura de desgaste, L_0 o comprimento inicial do desgaste e L o comprimento final do desgaste.




Figura 2.16 – Desenho esquemático do efeito plano num rodado (Cao et al., 2020).

Tal como expresso na Equação (2.5) em situações de não arredondamento nos cantos, a espessura de desgaste do defeito (d) é diretamente relacionada com o raio da roda (r) e o comprimento do liso (l). Resolvendo a equação em ordem à espessura do desgaste (d) obtém-se a seguinte equação.

$$r^2 = (r - d)^2 + \left(\frac{l}{2}\right)^2 \quad (2.5)$$

$$d = \frac{d^2}{2r} + \frac{L^2}{8r} = d \approx \frac{l^2}{8r} \quad (2.6)$$

A primeira parcela do segundo membro da equação pode ser desconsiderada devido à insignificância do valor de d , espessura de desgaste, em comparação com o valor de l , comprimento do liso na roda, originando uma aproximação comumente aceite.

Em situações onde não há desgaste a Equação (2.7) proposta por Wu e Thompson (2021) representa a caracterização geométrica do defeito:

$$x \approx d - \frac{1}{2r} \left(z - \frac{l}{2}\right)^2, \text{ se } 0 \leq z \leq l \quad (2.7)$$

Contudo em situações de circulação ferroviária reais as rodas têm desgaste ao longo do tempo e considerando uma aproximação desconsiderando a forma arredondada nos cantos, a equação abaixo, proposta por Wu e Thompson (2021), caracteriza a geometria do defeito:

$$x = \begin{cases} \bar{a}z^2 & , \text{ se } 0 \leq z \leq z_1 \\ d - \frac{1}{2r} (z - z_2)^2 & , \text{ se } z_1 \leq z \leq z_2 \end{cases} \quad (2.8)$$

Como proposto por alguns autores (Neves et al., 2014; Montenegro et al., 2015), os modelos numéricos de interação veículo-via definem a roda como sendo um ponto de contacto. Neste sentido é possível modelar o defeito na roda sobrepondo às irregularidades existentes na via, considerando que sobre ela circula uma roda sem defeito. A configuração do defeito da roda incluído na via é dada por

$$z = \frac{d}{2} \left(1 - \cos 2\pi \frac{x}{L}\right) H(x - (2\pi r_w - l)), 0 \leq x \leq 2\pi r_w \quad (2.9)$$

onde z e x representam a direção vertical e longitudinal da via e H representa uma função Heaviside.

2.3.2 Poligonização nas Rodas

A falta de arredondamento nas rodas corporiza um grupo de defeitos relacionados com a irregularidade circular na roda, em que os defeitos podem ser periódicos e não periódicos, além disso os defeitos periódicos subdividem-se em dois tipos; poligonais e ondulatórios, (Peng, 2020).

Os defeitos periódicos apresentam harmônicos com amplitudes muito similares, havendo pequenas irregularidades que podem ser desprezadas. Uma vez adotados valores aproximados das amplitudes e comprimentos de onda dominantes, estes efeitos são passíveis de serem caracterizados geometricamente possibilitando a sua modelação. Os defeitos não periódicos apresentam múltiplos comprimentos de onda com variadas amplitudes, nos quais apresentam irregularidades estocásticas de complexa caracterização. Na Figura 2.17 e Figura 2.18 estão representados os dois tipos de efeitos, no entanto na presente secção serão abordados com mais detalhe os defeitos com irregularidades periódicas.

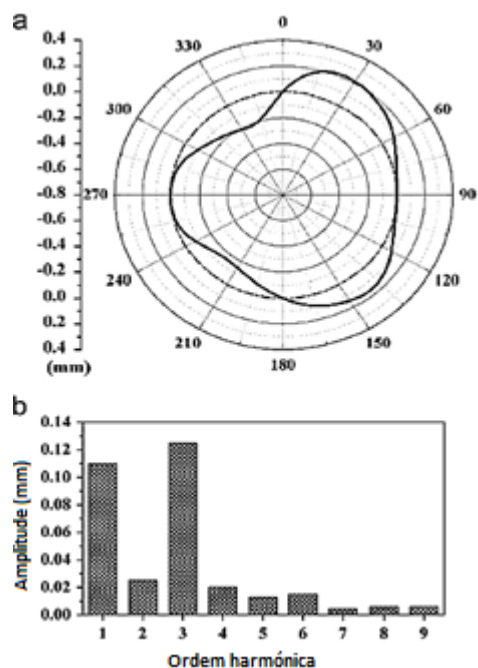


Figura 2.17 – Defeito periódico: (a) diagrama polar; (b) distribuição harmônica, (Liu e Zhai,2013).

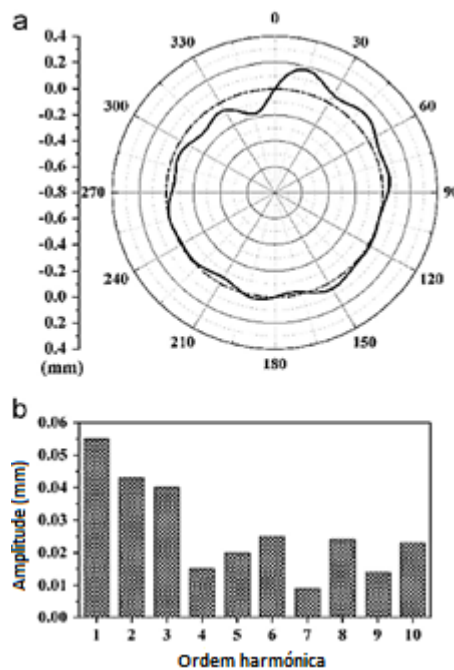


Figura 2.18 – Defeito não periódico: (a) diagrama polar; (b) distribuição harmônica, (Liu e Zhai,2013).

A poligonização e a ondulação nas rodas são defeitos com irregularidades circulares periódicas, distinguindo-os a frequência de ocorrência e danos provocados nos sistemas ferroviários. O defeito originado pela ondulação produz um menor impacto devido aos pequenos comprimentos de onda e amplitudes gerados, sendo este tipo o mais frequente. Uma das possíveis razões para a formação de cada um dos defeitos são apresentadas na Tabela 2-2, tal como os comprimentos de onda e amplitudes geralmente associados, (Peng, 2020).

Tabela 2-2 – Distinção entre poligonização e ondulação, (Peng, 2020).

Designação	Comprimento de onda	Amplitude	Possível causa
Ondulação	30-80 mm	10 μm	Travagem no piso da roda
Poligonização	140 mm - perímetro	>0,2 mm	Mecanismos de frequência fixa

O efeito poligonal é caracterizado pela alteração da forma da superfície do rodado, este originalmente apresenta a superfície de uma circunferência lisa. Sempre que acontece o fenômeno de desgaste que origina a ondulação nas rodas a mesma superfície começa a apresentar um formato ondulatorio, analogamente, pode-se assemelhar a uma corda quando começa a vibrar, apresentando determinadas características, tais como comprimentos de onda variados dependendo do número de harmônicos gerados e amplitudes. A Figura 2.19 demonstra medições típicas do efeito poligonal nas rodas associados a diferentes modelos de veículos ferroviários. Na Figura 2.19(a) são apresentados os valores do ruído originado pelo efeito ondulatorio em rodas da linha holandesa, cujos comprimentos de onda variam entre 50-70mm. A Figura 2.19(b) demonstra o efeito poligonal nas rodas, também ao nível do ruído gerado, com comprimentos de onda dominantes de 315mm e 630mm do comboio TRAXX medidos na Suíça e descrita em bandas de 1/3 de oitava. Na Figura 2.19(c) é apresentado um perfil de irregularidade circular da roda devido ao efeito poligonal com três harmônicos medidos no metro da Suécia e descrita no sistema de coordenadas Cartesianas. Também, na Figura 2.19(d) é retratada uma poligonização na roda de uma locomotiva com vinte harmônicos relativo a um comboio na África do Sul, descrita em coordenadas polares e espectro especial.

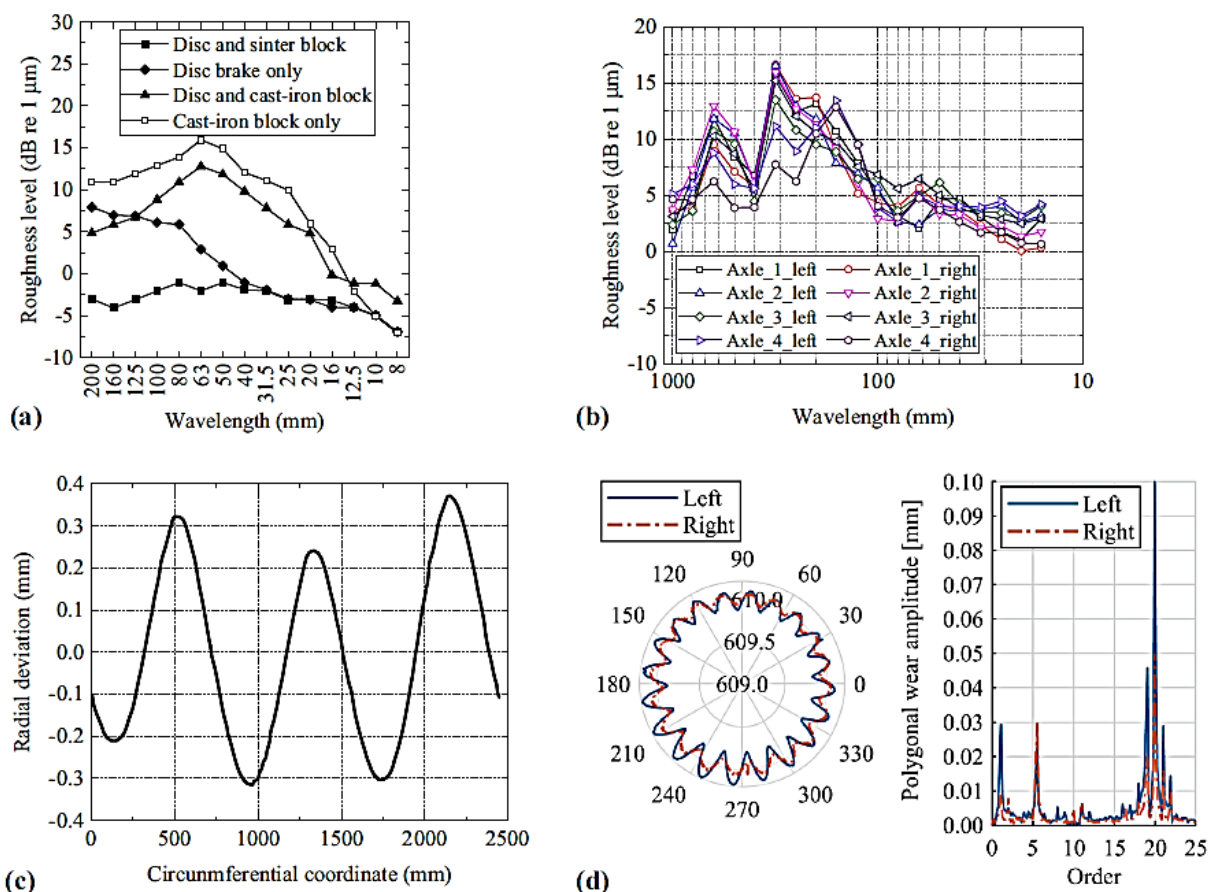


Figura 2.19 – (a) Ondulação com comprimentos de onda entre 50-70, (b) poligonização com comprimentos de onda entre 315mm e 630mm, (c) poligonização do rodado com três harmônicos, (d) poligonização com 20 harmônicos, (Tao et al., 2020).

Um dos grandes desafios a ultrapassar no campo da interação carril-roda é o efeito poligonal nas rodas, podem causar uma vibração devida ao impacto entre as rodas e carril assim como o aumento de ruído, resultando numa redução de segurança e conforto no transporte ferroviário. Porém este tipo de fenômenos ainda não são alvo de muitas pesquisas, pois não ocorrem com tanta frequência como por exemplo o efeito da ondulação no carril já mencionado. No entanto, quando ocorrem, potencializam danos graves no sistema veículo-via colocando em causa a segurança no transporte ferroviário. Sendo assim, perspectiva-se grande importância em dotar os sistemas de monitorização para a capacidade de detetar este tipo de danos. Na Figura 2.20 e Figura 2.21 é ilustrado cada um dos tipos de efeitos, ondulação e poligonização, respetivamente.



Figura 2.20 – Ondulação na roda com um comprimento de onda aproximadamente igual a 30 mm (Tao et al., 2020).



Figura 2.21 – Poligonização na roda (Liao, 2020).

Em veículos anteriores ao ano 2000 em que o sistema de travagem é de disco, foram observados defeitos nas rodas caracterizados como efeito poligonal ou falta de arredondamento, o comprimento de onda varia entre 14 cm a aproximadamente o comprimento da circunferência do rodado sendo a amplitude aproximadamente igual a 1 mm. No entanto, o efeito de ondulação geralmente ocorre em veículos com sistema de travagem em bloco, onde o comprimento de onda dos defeitos variam entre 30 mm a 60 mm, com uma amplitude aproximadamente igual a 10 μm , (Tao et al., 2020).

As características das ondas formadas pelos defeitos dependem do tipo de veículo e velocidades associadas. De acordo com a revisão efetuada em Tao et al. (2020), a investigação deste fenómeno começou na China desde 2008, reportando poligonizações nas rodas de comboios metropolitanos com 9 ordens de harmónicos em duas linhas, 5-8 harmónicos num outro comboio metropolitano cuja velocidade máxima é de 80 km/h, (Tao et al., 2019), 11-16 harmónicos num outro modelo em que a velocidade máxima também é de 80 km/h, (Yang et al., 2020) e num outro modelo em que a velocidade máxima é de 120 km/h foram identificados números de comprimentos de onda entre 12 a 14. Dois tipos de comboios de mercadorias produzidos pelo mesmo fabricante apresentaram severos defeitos de poligonização nas rodas, com comprimentos de onda compreendidos entre 160 mm e 315mm e harmónicos na ordem dos 18,19 e 24, e amplitudes de desgaste iguais a 0,6mm (Li et al., 2018), conforme se ilustra na Figura 2.22. Foram também identificados valores de harmónicos semelhantes em comboios de mercadorias produzidos por outro fabricante, nomeadamente na ordem dos 17-19 e 24, (Li et al., 2018).

Em estudos de comboios de alta velocidade, apesar de serem modelos distintos dos retratados atrás – comboios de mercadorias, os valores relativos às características dos defeitos observados são idênticos: os modelos CRH2 EMU e CRH3 MEU, a circular na linha Guiyang-Guangzhou apresentaram comprimentos de onda relativos aos defeitos de desgaste cujos valores variam entre 100-120 mm e 140-160mm, respetivamente e amplitudes de desgaste iguais a 0,4mm. Nos modelos CRH5 MEU a circular na via de alta velocidade Lanzhou-Urumqi evidenciaram-se comprimentos de onda na ordem dos 100 mm de comprimento em bandas de 1/3 de oitava, apresentando também uma amplitude de desgaste de 0,4mm. Na Figura 2.23 são demonstradas as medições realizadas nestes transportes de alta velocidade, de acordo com a revisão elaborado em Tao et al. (2020).




Figura 2.22 - Medições típicas de rodas com poligonização apresentando (a) 18 harmónicos, (b) 19 harmónicos, e (c) 24 harmónicos (Tao et al., 2020).




Figura 2.23 – Resultado de medições típicas de roda poligonal em comboios de alta velocidade na China descritas em coordenadas polares: (a) CHR2 MEU, (b) CRH3 MEU, e (c) CRH5 MEU com diâmetros nominais de 860 mm, 920 mm e 890 mm, respetivamente e amplitudes de desgaste iguais a 0,4mm (Tao et al., 2020).

2.3.2.1 Mecanismos de Formação

A poligonização nas rodas pode ser classificada de acordo com três mecanismos de formação: (1) Defeitos iniciais nas rodas, (2) vibração natural do sistema via-veículo, (3) instabilidade termoelástica. A Tabela 2-3 sumariza a categorização dos defeitos em questão, Tao et al. (2020).

Tabela 2-3 – Classificação de mecanismos de formação do efeito poligonal e ondulação nas rodas (Tao et al., 2020).

Categorização principal	Subcategorização
1. Defeitos iniciais nas rodas	(1) Perfilagem das rodas (2) Desequilíbrios estáticos e dinâmicos nos rodados (3) Propriedades não homogêneas dos materiais da roda
2. Vibração natural do sistema veículo-via	(1) Oscilações entre deslizamento e escorregamento do sistema de interação roda-carril (2) Ressonância P2 (3) Vibração de excitação própria do sistema de contacto rodado-via (4) Modos de flexão e torção dos rodados para vibrações de baixa frequência (5) Modos de vibração de flexão do carril ou via (6) Excitação de ressonância do bogie (7) Vibrações de outros componentes do bogie
3. Instabilidade termoelástica	

Investigações realizadas em veículos ferroviários de alta e média velocidade mostram que a poligonização das rodas é normalmente formada por mecanismos de desgaste. Depois de operações de reperfilamento das rodas é frequente a ocorrência de formações de efeitos de falta de arredondamento nas rodas. Tal deve-se ao facto de que neste processo são seleccionados três pontos equidistantes de fixação no verdugo originando uma deformação elástica radial que após o processo é restabelecida. Contudo podem ser geradas pequenas imperfeições que conduzem a um efeito de roda com falta de arredondamento em sucessivas operações de reperfilamento. A poligonização desenvolver-se-á rapidamente se a frequência de excitação das três primeiras imperfeições coincidir com a frequência natural dos rodados, (Tao et al., 2020). Além do exposto, a não homogeneização das propriedades dos materiais constituintes contribuem para a formação de defeitos nas rodas, nomeadamente de dois tipos, defeitos discretos e de falta de arredondamento não periódico, desequilíbrios estáticos e dinâmicos também podem promover para o aparecimento do efeito poligonal nas rodas.

A maioria das publicações científicas (Peng, 2020; Tao et al., 2020; Cai et al. 2022) apontam que a vibração induzida pelo sistema veículo-via promove o desgaste e efeito poligonal nas rodas. Tais como, fenómenos de “*stick-slip*” no sistema carril-rodado, ressonância P2, excitação induzida pela fricção de contacto entre a via e o veículo, flexão interior ou modos torsionais do rodado, modos de vibração da via, excitação de ressonância do bogie e vibração de outros componentes do bogie. Os mecanismos de comprimentos de

onda fixos, que de forma comum são ressonâncias entre o sistema veículo-via e mecanismos de defeitos, causam desgaste periódico nas rodas.

O efeito de ondulação nas rodas surge com muito mais frequência em veículos equipados com sistemas de travagem com blocos de ferro fundido, muito usados até ao final do séc. XX. Em veículos que se procedeu à troca dos sistemas de travagem por sistemas de disco resultou no desaparecimento da ondulação nas rodas, porém ainda são levantas questões quanto ao mecanismo de formação do efeito ondulatoria nas rodas, Tao et al. (2020).

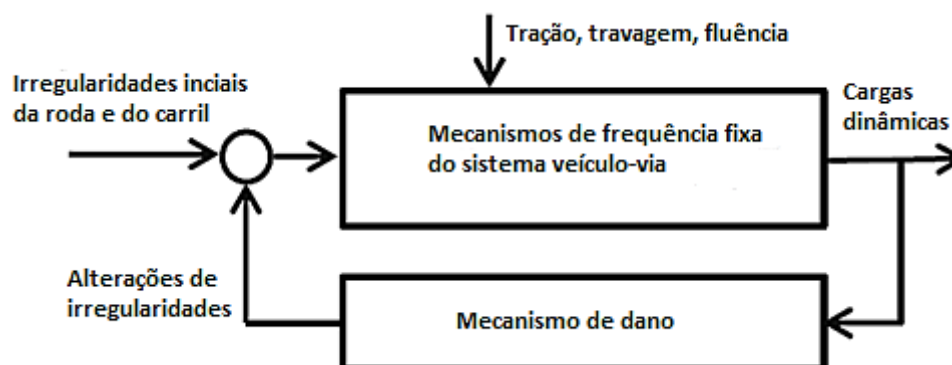


Figura 2.24 – Processo de formação do desgaste poligonal na roda (Tao et al., 2020).

2.3.2.2 Requisitos Normativos

Relativamente ao desgaste (Δr) (Figura 2.25) originado pelos defeitos de falta de arredondamento nas rodas a norma EN 15313-2016 (Anexo G) prevê uma série de valores limite a considerar, conforme se indica na Tabela 2-4. Os valores de Δr (mm) variam consoante o diâmetro das rodas e velocidades de circulação, todavia estes valores são indicativos não representando um requisito legal.




Figura 2.25 – Imperfeições circulares: excentricidade radial (Δr), (Müller et al., 2013).

Tabela 2-4 – Anexo G, EN 15313:2016 Valores admissíveis para o efeito de falta de arredondamento $\Delta r(mm)$.


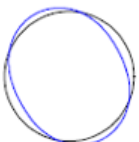
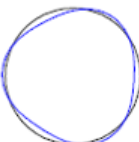
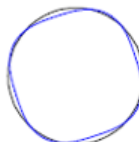

Intervalos de velocidades em função do diâmetro da roda	Defeitos circulatorios admissíveis (Δr)
$D > 840$ mm	
• $v_{max} \leq 60$ km/h	1,5
• $60 \text{ km/h} < v_{max} \leq 160$ km/h	1,0
• $160 \text{ km/h} < v_{max} \leq 200$ km/h	0,7
• $v_{max} > 200$ km/h	0,5
$380 \text{ mm} < D \leq 840$ mm	
• $v_{max} \leq 200$ km/h	0,7
• $v_{max} > 200$ km/h	0,5
$D \leq 380$ mm	0,3

Segundo a norma EN 15313:2016, os valores dos defeitos circulatorios admissíveis, (Δr), devem ser definidos no plano de manutenção.

2.3.2.3 Caracterização Geométrica

Os defeitos de poligonização nas rodas e as frequências de ressonância vertical do sistema via-veículo estão associados a mecanismos de comprimentos de onda fixos, cuja expressão é dada por, $\lambda_\theta = \frac{2\pi R}{\theta}$, $\theta = 1,2,3 \dots, n$, onde λ_θ representa o comprimento de onda, R o raio da roda e θ as ordens dos harmônicos. Em Song e Sun (2018), a estratégia de simulação dos defeitos nas rodas passa por adotar comprimentos de onda com valores compreendidos entre $0.105 - 2.64$ m, sendo o $R = 0,420$ m, os harmônicos considerados são desde ordem 1 a 25. Os diferentes tipos de severidades de defeitos relacionados com a poligonização podem ser caracterizados consoante a ordem harmônica associada, excêntrica, elíptica, triangular e quadrilateral nas quatro primeiras fases de formação e desgaste poligonal de ordem n para as restantes fases de desenvolvimento do dano, conforme ilustrado na Tabela 2-5.

Tabela 2-5 - Tipos de rodas com efeito poligonal (Song e Sun, 2018).

θ	1	2	3	4	n
Tipos	Excêntrico	Ovalização	Triangular	Quadrilateral	Poligonal
Forma					

O raio/profundidade de desgaste originado pelo efeito poligonal é dado pela diferença entre o raio do rodado medido desde o centro da circunferência à superfície e o denominado raio mínimo da roda desgastada. Este princípio de medição é ilustrado na Figura 2.26, onde $r(x) = R(x) - R_0$, Liao (2020).




Figura 2.26 – Esboço da roda e das variáveis de medição. Perfil radial $R(x)$, raio médio da roda R_0 , distância circunferencial x e o ângulo correspondente φ , (Liao, 2020).

A geometria do efeito poligonal em função do tempo pode ser caracterizado de acordo com a seguinte equação, proposta em Wu et al. (2017):

$$Z_0(t) = \sum_{i=1}^N A_i \sin \left(i \frac{v}{R} t + \varphi_i \right). \quad (2.10)$$

em que t é o tempo, A_i a amplitude da poligonal de ordem i , v a velocidade, R o raio do rodado, φ_i o ângulo de fase entre as forças do rodado/carril e a excitação poligonal, N é o número total de polígonos incluídos em $Z_0(\theta)$ (irregularidade entre o carril e o rodado), o índice i indica o polígono de ordem i .

Em estudos conduzidos por Joahansson e Andersson (2005), o perfil de irregularidade do defeito poligonal é caracterizado em função do espaço, podendo ser definido de acordo com a seguinte expressão:

$$w(x_w) = \sum_{\theta=1}^M a_{\theta} \sin \left(\frac{2\pi}{\lambda_{\theta}} x_w + \psi_{\theta} \right). \quad (2.11)$$

onde:

$w(x_w)$ – Perfil de irregularidade;

a_{θ} – Amplitude;

λ_θ – Comprimento de onda;

x_w – Distância percorrida pelo roda;

ψ_θ - ângulo de fase.

As rodas novas também apresentam níveis de irregularidades, porém baixos, assim como um largo espectro de comprimentos de onda. Os autores Joahansson e Andersson (2005) consideram o efeito das irregularidades iniciais nas simulações, para tal são adotados comprimentos de onda compreendidos entre 0.125-2.45m, sendo o valor de 2.45m igual ao perímetro da roda nova – sem nenhuma irregularidade, para os primeiros 20 harmônicos (M).

Para cada comprimento de onda a amplitude da função seno é dada pela seguinte expressão:

$$a_\theta = \sqrt{2} \cdot 10^{L_{w\theta}/20} \cdot w_{ref}. \quad (2.12)$$

em que $w_{ref} = 1\mu m$.

O espectro inicial do nível de irregularidade proposto por Joahansson e Andersson (2005) é obtido de uma forma empírica através dos dados medidos das rodas novas, conforme a seguinte equação:

$$L_{w\theta} = 24.7 \log(\lambda_\theta) + 8.47. \quad (2.13)$$

2.4 TÉCNICAS BASEADAS EM IA DE DETEÇÃO E IDENTIFICAÇÃO DE DANOS

As técnicas de monitorização da integridade estrutural (MIE) podem seguir a atualização de modelos numéricos ou abordagens baseadas em dados para a deteção de danos, (Meixedo et al., 2021). Estas técnicas apresentam resultados com elevada precisão, contudo a sua complexidade computacional inerente e a necessidade de análise por parte do utilizador fazem com que seja uma abordagem pouco atrativa num contexto de monitorização da integridade estrutural em tempo real. Porém, as abordagens orientadas por dados baseiam-se em técnicas de mineração de dados a fim de extrair informações significativas de séries temporais adquiridas no local. Devido à sua simplicidade computacional estas abordagens são mais atrativas e económicas quando aplicadas em metodologias de deteção remota do dano e em larga escala.

De acordo com a literatura, as estratégias de identificação do dano têm sido amplamente classificadas dentro de cinco níveis hierárquicos, (i) deteção do dano, (ii) localização, (iii) tipo, (iv) severidade e (v) previsão do tempo de vida útil.

2.4.1 Levantamento de Metodologias Desenvolvidas na Literatura

Para a aquisição de dados na maioria dos trabalhos de MIE é considerado as respostas estruturais devido a vibrações ambientais, vibrações forçadas ou a ações de temperatura e de efeitos estáticos induzidos por sobrecargas, porém recentes trabalhos têm considerado as respostas estruturais a cargas dinâmicas, tal como o tráfego nas pontes, de forma a tirar proveito da grande repetibilidade das ações, do seu conhecido comportamento e da sua grande magnitude. Em Cavadas et al. (2013), foi conduzido um estudo experimental em que foram adquiridos dados relativos a deslocamentos e rotações ao longo de uma viga devido a cargas dinâmicas desconhecidas. Após a extração foram utilizadas técnicas de Análise dos Componentes Principais e de Regressão Robusta para a redução do volume de dados. Apesar do método adotado detetar reduções de 20% na rigidez da viga, só foi ensaiado um tipo de carregamento dinâmico, sendo a velocidade da carga rolante reduzida equiparando-se assim a uma carga quase-estática, o comportamento de resposta da viga assemelha-se ao comportamento típico quando sujeita a cargas estáticas, que raramente acontece em pontes reais. Em Gonzalez e Karoumi (2015), foi desenvolvido um método de deteção de dano utilizando como dados de análise as medições das acelerações do piso e pesagem da carga em movimento sobre a ponte, cujo objetivo passa por treinar uma *machine learning*, com base em processos ANN e Gaussianos, capaz de classificar os dados como sendo indicativos de estados com e sem dano. Com base num modelo tridimensional de uma ponte o método foi posteriormente aprofundado por Neves et al. (2017). As variações ambientais e operacionais (VAO's) não foram consideradas no processo de deteção de dano evidenciando-se assim uma limitação na abordagem adotada. Em Nie et al. (2020), foi produzido um sistema de deteção de dano cuja configuração consiste na utilização de dois sensores localizados na viga de uma ponte sujeita a cargas móveis em que o índice de dano local é baseado na correlação entre as respostas medidas. Foi utilizado um protótipo laboratorial de uma viga simplesmente apoiada sujeita a cargas móveis de forma a simular e verificar a fiabilidade do método de deteção desenvolvido. Constatou-se a ocorrência de vários falsos positivos pelo que devem ser realizadas mais simulações numéricas para que num contexto prático a metodologia torne-se eficiente. Em Azim e Gül (2019), foi apresentado um método de análise de séries temporais utilizando dados operacionais tendo por base a utilização de sensores para a monitorização contínua de pontes ferroviárias em laje vigada. O processo de extração de indicadores relativos a danos estruturais baseou-se na aplicação de métodos autorregressivos de média móvel com entradas exógenas para analisar a resposta da ponte em vibração livre. Algumas limitações foram referenciadas pelos autores, tais como, a natureza linear dos métodos utilizados e a falta de consideração de variações nas ações ambientais no estudo efetuado.

Tal como referido em Meixedo et al. (2021), apesar da larga investigação neste campo, uma implementação bem-sucedida de uma MIE baseada em respostas de pontes a ações dinâmicas induzidas

pelo tráfego ferroviário ainda são escassas. Na maioria das metodologias de detecção de danos propostas, não são considerados os efeitos das VAO's no comportamento da resposta estrutural, as validações das metodologias são efetuadas tendo em conta simulações numéricas relativas a modelos simplistas de estruturas, pouco tipo de danos assumidos, as cargas de impacto consideradas são muito específicas tudo isto faz com que as metodologias não sejam passíveis de serem utilizadas em contextos reais. De forma a ultrapassar os problemas que se prendem com a escassez de variáveis consideradas e consequentemente criar condições para conceber uma metodologia passível de ser aplicada num contexto real, em Meixedo et al. (2021) foi desenvolvido e aplicado uma combinação de diferentes tipos de técnicas de *machine learning* para sinais transitórios. Para tal, foi utilizado um modelo numérico calibrado e validado, em que foram simulados diferentes tipos de cenários de forma a medir as respostas teóricas nos pontos considerados. A passagem de veículos ferroviários provoca uma grande magnitude de ações na estrutura assim como uma grande variabilidade de ações, pelo que determinadas medições de respostas estruturais a estas ações dinâmicas podem ser erradamente consideradas como sendo promovidas por uma situação de dano na estrutura. As técnicas adotadas têm como objetivo dotar a metodologia de capacidade para distinguir os efeitos medidos na estrutura pela passagem do veículo dos causados por um determinado dano estrutural.

De acordo com o trabalho desenvolvido em Meixedo et al. (2021), depois da aquisição das respostas induzidas pelas cargas dinâmicas do veículo ferroviário sobre a via, a etapa de detecção de dano compreende quatro principais operações, sendo: (i) extração de indicadores, (ii) modelação de indicadores / *feature modelling*, (iii) fusão de dados e (iv) discriminação de indicadores, a Figura 2.27 retrata as diferentes operações na fase do processo de detecção de danos. Baseado em Meixedo et al. (2021a), é apresentado abaixo os fundamentos teóricos de cada uma das técnicas utilizadas em cada uma das operações para a detecção do dano.

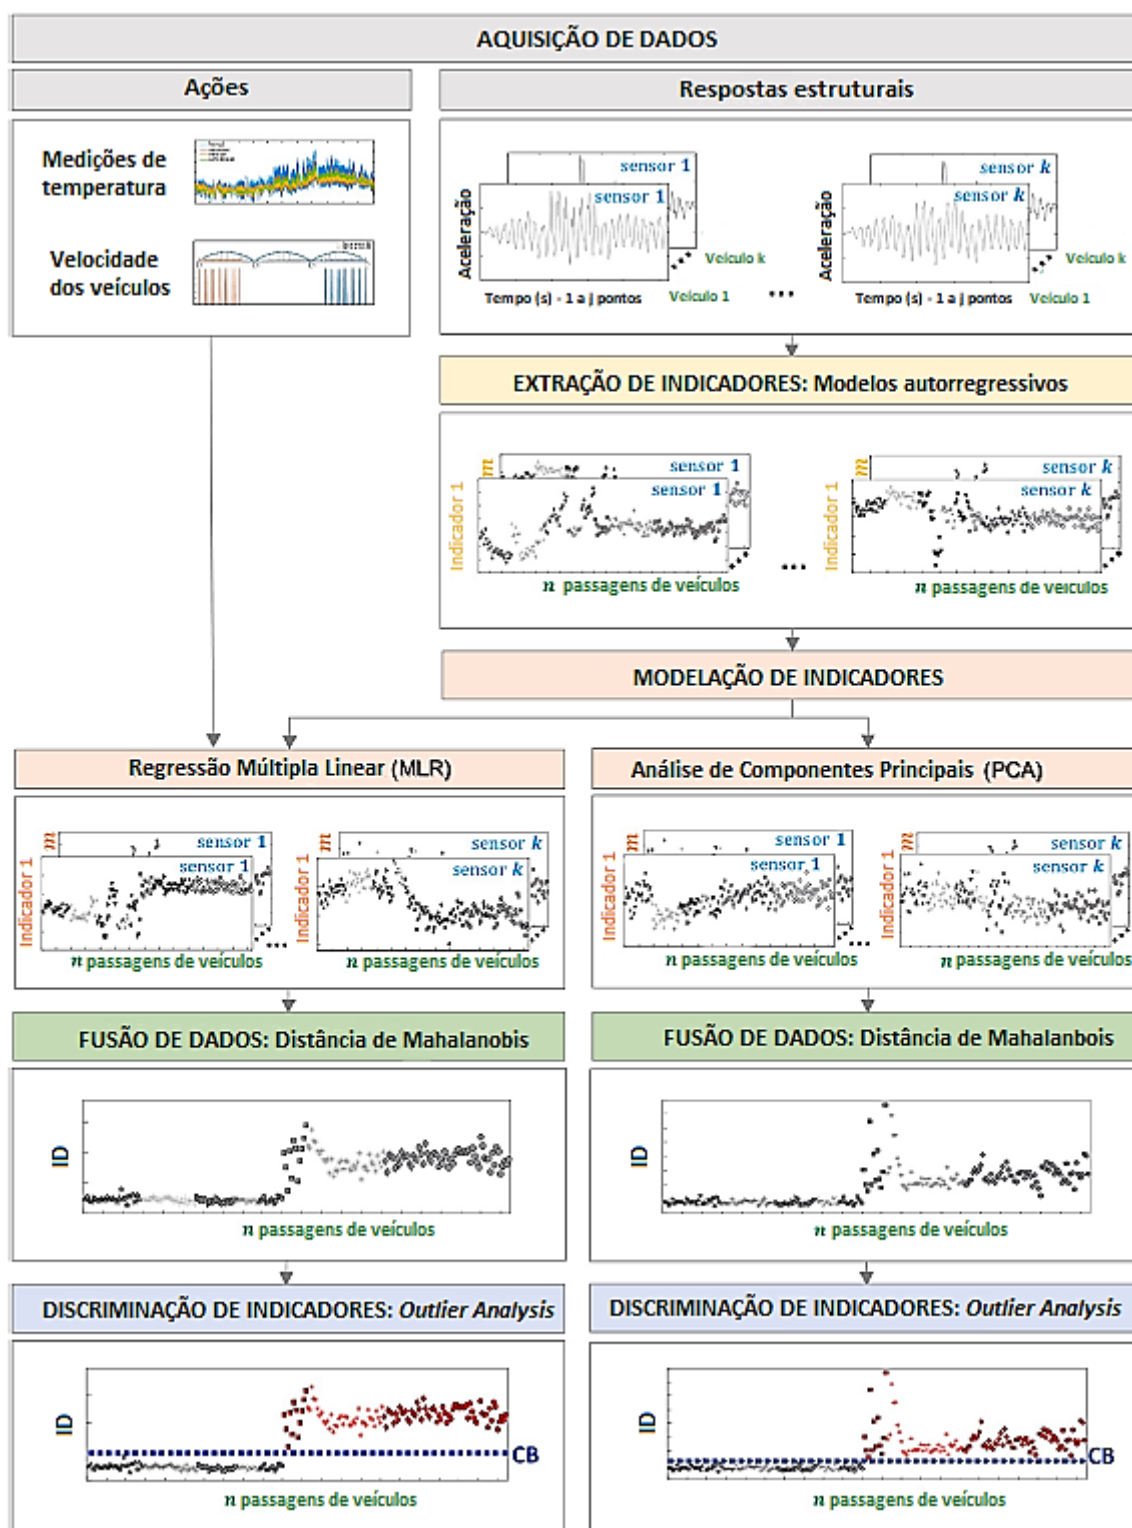


Figura 2.27 – Fluxograma da metodologia de detecção de danos (Meixedo et al., 2021a).

2.4.2 Extração de Indicadores

A extração de indicadores de desempenho é o processo de transformação dos dados adquiridos localmente em função do tempo em informação alternativa, na qual a correlação com o dano é mais

facilmente observada. Apoiado sobre a premissa que em caso de dano numa estrutura a sua massa e rigidez sofrem alterações, é comum encontrar-se na literatura (Yan e Kerochen, 2005; Alvandi e Cremona, 2006; Alves et al., 2015; Meixedo et al., 2016) uma ampla tendência para o uso de indicadores modais ou de base modal pois têm a vantagem de estar relacionados com a massa e, mais importante ainda, com a rigidez estrutural. Mais ainda, as quantidades modais também têm a vantagem de serem usadas para a conceção estrutural e para a avaliação da vulnerabilidade das estruturas a ações e perigos. No entanto, para além destas vantagens, também é necessário considerar que as informações baseadas em Operações de Análise Modal (OAM) podem não ser sensíveis a danos em estágios iniciais devido ao facto de ser necessário identificar modos de deformação de elevada ordem, tornando-se um grande desafio para uma eficaz monitorização de uma estrutura. Dados simbólicos, componentes *wavelet* e estatísticas básicas do sinal são exemplos de técnicas eficazes de extração de indicadores sensíveis a dano tanto para uma monitorização estática ou dinâmica. No entanto, em aplicações na qual a grandeza medida é a aceleração, os modelos autorregressivos (AR) têm sido amplamente divulgados devido a várias razões. A sua habilidade na extração de indicadores sensíveis ao dano, sendo a variação dos coeficientes dos modelos AR implementados refletido pelas variações de parâmetros físicos do sistema indicativos de dano, por exemplo a rigidez. São modelos de extração de indicadores que dependem unicamente da resposta sistema, sendo que os parâmetros do modelo refletem as propriedades do sistema independentemente das fontes de excitações e variações das mesmas, para além de que são modelos de fácil implementação computacional. Os modelos AR são ajustados à resposta ao sistema monitorizado no qual os seus parâmetros são extraídos. Consequentemente, o conjunto de dados multivariados obtidos pelo processamento da técnica AR é resultado tanto do número de parâmetros extraídos como do número de sensores utilizados.

2.4.2.1 Modelos autorregressivos AR e ARX

Dentro do domínio da MIE, a análise de séries temporais é uma ferramenta estatística que tenta adequar um modelo matemático aos dados das séries temporais de forma a extrair informação significativa. De entre os diferentes modelos de séries temporais, o modelo AR/ARX tem sido amplamente usado para extrair indicadores sensíveis a danos.

O modelo $AR(m)$, é definido a partir dos dados de respostas das séries-temporais x_1, x_2, \dots, x_n , em que n_a define a ordem ou o número dos parâmetros no modelo, a equação (2.14), abaixo apresentada, define uma das formas de caracterizar os valores das respostas:

$$x_j = \sum_{i=1}^{n_a} a_i x_{j-i} + \varepsilon_j \quad (2.14)$$

onde:

x_j – Valor atualizado da resposta;

a_i – Parâmetro constante de AR;

x_{j-1} – Resposta anterior;

ε_j – Erro aleatória não observável na resposta j .

Então, o valor da resposta atualizado, x_j , é definido como uma combinação linear entre os n_a valores das respostas anteriores multiplicados por um parâmetro AR de valor constante, a_i . O erro observável é a diferença entre as medições das séries temporais e as previstas pelo próprio modelo AR.

O modelo autorregressivo ARX considera o comportamento preditivo do sistema numa determinada localização atendendo o seu historial nesse mesmo ponto de medição e a resposta preditiva nos outros locais de medição face ao mesmo evento – entradas exógenas. Sendo uma variante da equação (2.15), o modelo ARX pode ser definido pela equação abaixo:

$$x_j = \sum_{i=1}^{n_a} a_i x_{j-i} + \sum_{k=1}^{n_b} b_k x_{j-k} + \varepsilon_j \quad (2.15)$$

em que a primeira parcela é referente ao historial de resposta no mesmo local (*inputs*) e a segunda parcela é referente às entradas exógenas (*outputs*), sendo que n_b e b_k representam as ordens e os parâmetros dos *outputs*.

Num sistema onde diferentes frequências de vibração ocorrem ao longo do tempo, os parâmetros a_i devem ser estimados tendo em conta que devem sofrer alterações entre os diferentes intervalos de tempo. O processo de extração dos parâmetros AR/ARX passa por adequar o modelo AR a cada resposta adquirida pelos diferentes sensores face às ocorrências de diferentes vibrações ao longo do tempo relativas a condições com e sem dano. Os vetores dos parâmetros do modelo respeitantes a condições de dano e sem dano são então utilizados como sendo indicadores de dano. O modelo AR pode ser representado num formato de matriz compreendendo o seguinte sistema de equações:

$$\begin{bmatrix} x_{m+1} \\ x_{m+2} \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} x_1 & x_1 & \dots & x_m \\ x_2 & x_2 & \dots & x_{m+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n-m} & x_{n-m+1} & \dots & x_{n-1} \end{bmatrix} \begin{bmatrix} a_m \\ a_{m-1} \\ \vdots \\ a_1 \end{bmatrix} + \begin{bmatrix} \varepsilon_{m+1} \\ \varepsilon_{m+2} \\ \vdots \\ \varepsilon_n \end{bmatrix} \quad (2.16)$$

Caracteristicamente as séries temporais conduzem a sistemas possíveis indeterminados (múltiplas soluções) que devem ser resolvidas para obter estimativas dos coeficientes AR/ARX. O cálculo dos coeficientes pode ser feito por vários métodos, nomeadamente o método Yule-Walker e método dos mínimos quadrados, (Meixedo et al., 2021).

A ordem do modelo AR/ARX deve ser racionalmente determinada em função das características dos dados, (Meixedo, 2021). Este é um ponto de grande importância, pois assumindo uma ordem do modelo superior, pode, eventualmente, corresponder a determinados dados, porém não ser suficientemente generalizado para cumprir os requisitos de outro tipo de conjuntos de dados. Por outro lado, escolhendo um modelo de baixa ordem, a resposta do sistema físico não é necessariamente captada, a informação será então escassa, (Farrar e Worden, 2013). Uma das técnicas possíveis de ser usadas para a otimização da ordem do modelo é o Critério de Informação Aaike (AIC), tendo sido reportado como uma das técnicas mais eficientes na otimização da ordem de modelos, (Figueiredo et al., 2010). O AIC é uma medida que consiste na qualidade de adequação de um modelo estatístico estimado baseando-se no compromisso entre a precisão de adaptação e o número de parâmetros estimados. No contexto dos modelos AR/ARX, AIC é dado por:

$$AIC = N_t \ln(\varepsilon) + 2N_p \quad (2.17)$$

onde N_p é o número de parâmetros estimados, N_t o número de pontos de dados previstos e $\varepsilon = SSR / N_t$, os erros da soma média dos resíduos quadráticos (SSR). Para descobrir uma ordem ideal, deve-se ensaiar uma vasta gama de ordens e escolher um número com o valor mínimo de AIC. Com este propósito, em Meixedo (2021) foram analisados os valores de AIC para vinte e dois modelos independentes ARX(n_a, n_b) de ordem crescente ($n_a = n_b = 1, 2, \dots, 50$). A Figura 2.28a, mostra a função média de AIC resultante das análises efetuadas nas 100 séries temporais de cenários de base. Como pode ser observado, a partir da ordem do modelo igual a 30 o valor de AIC tem tendência a estabilizar-se indicando que valores do modelo referentes a ordens acima de 30 não fornecem uma informação relevante para a construção do modelo matemático.

O valor do erro quadrático médio de raiz normalizada (NRMSE) também foi utilizado para quantificar a precisão do modelo de acordo com a ordem ARX definida, em que é dado por:

$$NRMSE = 1 - \frac{\sum_{j=1}^n (x_j - \hat{x}_j)^2}{\sum_{j=1}^n (x_j - \bar{x})^2} \quad (2.18)$$

em que, x_j são os dados medidos, \hat{x}_j são os dados simulados através do modelo ARX e \bar{x} é a média do conjunto de dados medidos. A Figura 2.28b, mostra os valores médios do $NRMSE$, no qual representam a diferença entre os dados reais e os previstos no modelo ARX. É possível observar que a precisão do modelo ARX aumenta consoante aumenta a ordem do modelo ARX, porém a partir da ordem 30 a qualidade do modelo mantém-se constante, conclui-se que a ordem ideal é 30.




Figura 2.28 – Definição da ordem do modelo: a) função média AIC para vinte e dois modelos ARX (n_a , n_b) independentes, de ordem crescente utilizando séries temporais de 100 cenários de base, b) precisão do modelo de acordo com a ordem do modelo ARX, (Meixedo, 2021).

2.4.2.2 Transformadas Contínuas *Wavelet*

Transformadas Contínuas *Wavelet* (CWT) têm sido desenvolvidas ao longo de décadas em diferentes disciplinas e aplicações diversas, por exemplo, astronomia, zoologia, mecânica quântica, monitorização da reação de um condutor assim como sedimentações de rios. Devido às suas propriedades melhoradas de localização por frequência temporal evidencia-se como uma poderosa ferramenta para caracterizar os indicadores locais de um sinal, (Addison, 2018). Apesar da transformação de Fourier, em que a função utilizada como base para a transformação integral de um sinal ser sempre uma onda sinusoidal, outras funções podem ser utilizadas para a forma *wavelet* de acordo com as propriedades do próprio sinal. A função básica na análise *wavelet* é definida por dois parâmetros: escala e translação. Estes indicadores apresentam várias resoluções de sinais não estacionários. O CWT (T) correspondente ao sinal $x(t)$ é definido como, (Addison, 2018):

$$T(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (2.19)$$

em que a e b são parâmetros de escala e de translação, respetivamente, e ψ^* é o complexo conjugado da onda-mãe ψ , que consiste numa função contínua tanto no domínio do tempo como no domínio da frequência. O principal objetivo da onda-mãe é fornecer uma função de fonte para a produção de *wavelets* filha, que são simplesmente versões transladadas e escalonadas da onda-mãe. Uma das ondas-mãe mais frequentemente utilizadas para a CWT é a Morlet *wavelet*, e representa-se da seguinte forma:

$$\psi(t) = \frac{1}{\pi^{1/4}} e^{i2\pi f_0 t} e^{-t^2/2} \quad (2.20)$$

em que este *wavelet* é simplesmente um sinusoidal complexo, $e^{i2\pi f_0 t}$, dentro de um envelope gaussiano, $e^{-t^2/2}$, $\pi^{1/4}$ é um fator de normalização para assegurar que a *wavelet* tem energia unitária.

Após o cálculo dos coeficientes *wavelet* através da implementação de um CWT aos sinais avaliados, para uma significativa compressão dos dados, deve-se proceder à realização de uma Análise de Componentes Principais (PCA) extraíndo-se quatro parâmetros estatísticos. Considerando uma matriz X de $n \times m$ elementos, em que são considerados os indicadores CWT extraídos do sinal original relativamente a cada sensor, onde n corresponde ao número de pontos de medição em cada sensor e m representa o número de coeficientes *wavelet*, os componentes principais podem ser calculados com base na seguinte equação:

$$S = X \cdot T \quad (2.21)$$

onde:

S – Matriz, $n \times m$, das pontuações/componentes principais;

X – Matriz, $n \times m$, dos indicadores CWT extraídos;

T – Matriz de transformação linear ortonormal, $m \times m$.

A matriz T aplica uma rotação ao sistema de coordenadas originais.

Posteriormente, quatro parâmetros estatísticos são extraídos das pontuações S , nomeadamente a média quadrática (RMS), o desvio padrão, obliquidade e Kurtosis.

2.4.3 Modelação de Indicadores – Métodos Regressivos e Métodos das Variáveis Latentes

De forma a ultrapassar situações de falso alarme, as metodologias de deteção de dano e as técnicas de monitorização da integridade estrutural têm de estar dotadas de capacidade para distinguir efeitos medidos devido a causas ambientais e variações operacionais (*EOVs – Environmental and operational variations*) daqueles que são causados por danos existentes, para que os métodos de monitorização da integridade estrutural possam ultrapassar este problema de possível falsa identificação de dano é feita a modelação dos indicadores (*feature modelling*). Assim, as grandes variações impostas por ações ambientais, tal como de temperatura, variações operacionais, como por exemplo, a circulação de veículos ferroviários a diferentes velocidades e de diferentes tipologias, que impõe certas excitações nas estruturas são reconhecidas pelas metodologias de monitorização como sendo respostas a ações previstas que ocorrem com determinada frequência e não devido a danos. Para tal, são frequentemente utilizadas duas ferramentas estatísticas multivariadas na prática da modelação de indicadores, (i) baseado em métodos regressivos, tal como Regressão Linear Múltipla (*MLR – Multiple Linear Regression*), sempre que é medido as ações ambientais impostas (por exemplo, do vento, de tráfico, de temperatura) e as respostas estruturais, este método pode ser adotado; entradas-saídas, (ii) baseado em métodos de variáveis latentes, tal como Análise de Componentes Principais (*PCA – Principal Component Analysis*), quando numa metodologia é realizado apenas a medição das respostas estruturais este método pode ser

adotado; apenas saídas, portanto. Considerando unicamente as medições das respostas estruturais, o último método tem a habilidade de excluir ações independentes.

2.4.3.1 Regressão Linear Múltipla

No domínio da modelação de indicadores para o desenvolvimento de uma metodologia de MIE a regressão linear múltipla (RLM) é a ferramenta mais simples dentro dos modelos de análise estatística multivariada utilizados. Devendo-se ao facto de assumir uma relação linear entre as ações ambientais/operacionais e as respostas estruturais medidas, da sua simplicidade teórica e computacional, conjugado com o facto de que a maior parte das relações físicas na natureza impactantes nos sistemas monitorizados são lineares. Porém, é necessário efetuar a medição das ações operacionais e ambientais de forma que sejam retiradas das respostas medidas ou indicadores de dano.

No trabalho desenvolvido em Meixedo et al. (2021), foram considerados como *inputs* as ações medidas da temperatura e velocidade dos veículos ferroviários em ordem a obter como *output* uma matriz representativa dos parâmetros AR estimados (ou previstos). Considerando m parâmetros AR, n simulações de base e s ações operacionais/ambientais o modelo de regressão multivariada é expresso por uma matriz cuja equação é apresentada da seguinte forma:

$$Y = X \cdot \hat{w} + \varepsilon_{MLR} \quad (2.22)$$

onde:

Y – Matriz, $n \times m$, dos parâmetros AR previstos - *output*;

X – Matriz, $n \times (s + 1)$, das ações de temperatura e velocidade;

\hat{w} – Matriz, $(s + 1) \times m$, dos coeficientes que pesa cada *input* ambiental/operacional;

ε_{MLR} – Matriz, $n \times m$, do erro de regressão.

Os coeficientes \hat{w} do modelo que pesam cada *input* ambiental/operacional são obtidos pelo método dos mínimos quadrados de acordo com a seguinte equação:

$$\hat{w} = (X^T \cdot X)^{-1} \cdot X^T \cdot Y \quad (2.23)$$

onde:

X^T – Matriz transposta de X , $(s + 1) \times n$, das ações da temperatura e velocidade;

X – Matriz, $n \times (s + 1)$, das ações da temperatura e velocidade;

Y – Matriz, $n \times m$, dos parâmetros AR previstos – *output*.

Calibrado o modelo, isto é, atingindo-se um valor ótimo dos pesos avaliados, novos dados podem ser usados como *inputs* (\hat{X}) e matriz do erro residual, $\hat{\varepsilon}_{MLR}$, correspondendo aos indicadores sensíveis ao dano donde foram removidos os efeitos ambientais e operacionais, é dada por:

$$\hat{\varepsilon}_{MLR} = Y - \hat{X} \cdot \hat{w} \quad (2.24)$$

Este procedimento é repetido para os parâmetros de cada sensor.

2.4.3.2 Análise de Componentes Principais

Um dos grandes desafios na identificação do dano é eliminar os efeitos da variação das ações ambientais e operacionais das respostas medidas em ordem a obter indicadores com uma maior sensibilidade ao dano. Mudanças nas condições ambientais, por exemplo, temperatura vento, etc., ou de condições operacionais, tal como, diferentes velocidades e tipo de veículos, afetam significativamente as características de vibração. Geralmente, as VAO's não são medidas, porém os seus efeitos podem ser observados pelas variações dos indicadores medidos. A fim de resolver este problema a análise de componentes principais (PCA) é utilizada. O PCA é um método estatístico multivariado que produz um conjunto de vetores linearmente não correlacionados aos quais são chamados de componentes principais ou pontuações, a partir de um conjunto multivariado de dados vetoriais. Partindo do pressuposto que as ações ambientais têm um efeito linear nos parâmetros identificados, numa contínua monitorização o PCA pode eficientemente remover os resultados das VAO's, (Meixedo 2021).

Tal como demonstrado em Meixedo et al. (2021), considerando uma matriz X de $n \times m$ elementos, em que são considerados os indicadores extraídos a partir das respostas dinâmicas, onde n corresponde ao número de simulações dos cenários de base e m é o número de parâmetros AR. Principais componentes podem ser calculados com base na seguinte equação:

$$Y = X \cdot T \quad (2.25)$$

onde:

Y – Matriz, $n \times m$, das pontuações/componentes principais;

X – Matriz, $n \times m$, dos indicadores extraídos;

T – Matriz de transformação linear ortonormal, $m \times m$.

A matriz T aplica uma rotação ao sistema de coordenadas originais. A matriz da covariância dos parâmetros AR relativas às condições de base é obtida pela técnica de decomposição do valor singular. A decomposição da matriz da covariância é dada pela seguinte equação:

$$C = T \cdot \Lambda \cdot T^T \quad (2.26)$$

onde:

C – Matriz da covariância dos parâmetros AR dos cenários de base;

Λ – Matriz da covariância das pontuações/componentes principais;

T e T^T – Matrizes vetoriais singulares.

A matriz da covariância Λ é formada apenas pelos termos diagonais, também denominada como matriz dos valores singulares. Os valores próprios (*eigenvalues*) em Λ são as variações dos componentes em Y definindo assim a importância relativa de cada componente principal na variação de todo o conjunto de dados.

Tal como apresentado em Santos et al. (2013), a informação relacionada com os efeitos operacionais e ambientais mais relevante é retida nos primeiros eixos do PCA. Em trabalhos onde o objetivo passa por identificar defeitos em componentes dos sistemas, nomeadamente defeitos nas rodas dos veículos ferroviários, o método de modelação de dados inclui a remoção dos principais componentes dos indicadores retendo todos aqueles que são mais sensíveis ao dano para as análises estatísticas nas etapas seguintes. Assim sendo, a matriz Λ pode ser dividida em duas matrizes: uma matriz com os primeiros p valores próprios (*eigenvalues*) e uma outra matriz com os restantes $m-p$ valores próprios (*eigenvalues*). É um grande desafio definir o número de componentes p , especialmente quando se trata de uma interpretação fiável de dados multivariados. Apesar do desconhecimento por parte dos autores em ordem a definir o número de componentes p , sendo ainda uma questão em aberto. Em Meixedo et al. (2021), o número de componentes p a descartar calcula-se pela regra comum que passa por considerar todos os componentes a partir do qual seja alcançada a percentagem cumulativa de 80%. Após descartados os componentes (p), a matriz Y dos componentes $m-p$ é calculada pela equação (2.25). Além disso, a matriz T^T é desenhada com as restantes colunas $m-p$ da matriz T . Pela seguinte equação os componentes $m-p$ podem ser estruturados no espaço original:

$$F_{PCA} = Y \cdot T \cdot T^T \quad (2.27)$$

onde:

F_{PCA} – Matriz $n \times m$ elementos de indicadores sensíveis a danos do PCA;

Então, os indicadores obtidos após o processo de modelação são mais sensíveis a danos e menos sensíveis aos efeitos das VAO's. O processo acima descrito é repetido para cada sensor.

2.4.4 Fusão de Dados

A fusão de dados tem como objetivo reduzir o volume de dados extraídos perseverando a informação mais relevante, isto é, manter ou até melhorar a capacidade de caracterizar o fenómeno medido quando comparado com os resultados adquiridos utilizando apenas uma das fontes originais. O processo de fusão

de dados pode combinar indicadores relativamente a várias fontes, a um sensor, a vários sensores distribuídos ao longo do espaço ou até mesmo indicadores relativamente a tipo de dados heterogêneos, ou seja, dados relativos a diferentes tipos de grandezas medidas, como por exemplo acelerações e tensões. Neste contexto a distância Mahalanobis tem sido amplamente utilizada devido ao facto de conseguir descrever a variabilidade de conjunto de dados multivariados, assim como a possibilidade de aplicação a indicadores modelados, permitindo uma fusão eficaz, numa primeira fase dos indicadores de cada sensor e numa segunda fase informação de múltiplos sensores.

A distância de Mahalanobis é uma ferramenta utilizada para fundir indicadores de múltiplos sensores em ordem a obter um índice de dano (ID) para cada simulação. A distância Mahalanobis calcula a distância entre os indicadores de dano e sem dano em ordem a definir semelhanças entre eles, em que curtas distâncias representam grandes semelhanças. A distância Mahalanobis é genérica o suficiente para ser utilizada em ordem a detetar qualquer cenário de dano, enquanto fornece uma ponderação não supervisionada, sendo assim independente de intervenções humanas, tipo da estrutura/sistema e das ações atuantes na mesma. Consiste em indicadores de danos ponderados em que os pesos são determinados pela estrutura da covariância. Além disso, e mais importante, a ponderação proporcional à estrutura da covariância fornece uma camada adicional de modelação de indicadores que, quando definida para ações regulares, permite delinear com alta sensibilidade aqueles que não foram utilizados para a definição da estrutura da covariância, (Meixedo et al., 2021). A distância Mahalanobis é calculada para cada simulação i , simbolizado como DI_i , pela seguinte expressão:

$$DI_i = \sqrt{(x_i - \bar{x}) \cdot S_x^{-1} \cdot (x_i - \bar{x})^T} \quad (2.28)$$

onde:

x_i – Vetor de m indicadores representativos de potenciais danos;

\bar{x} – Matriz da média dos indicadores estimados no cenário de base;

S_x – Matriz da covariância das simulações dos cenários de base.

Portanto, para cada sensor e cada simulação, é calculada a distância Mahalanobis resultando numa matriz de n distâncias Mahalanobis por k número de sensores, onde n representa o número total de simulações. Além do mais, uma nova distância Mahalanobis pode ser aplicada em ordem a obter um vetor $n \times 1$ de toda a informação fundida respeitante a cada sensor e assim fornecer uma ID para cada simulação. Em Meixedo et al. (2021), a distância de Mahalanobis de segunda ordem demonstrou resultados bastantes satisfatórios na promoção de uma deteção de dano mais eficiente, aumentando substancialmente o valor do ID sempre que testados dados relativos a um estado de dano, ou seja, é incrementada a distância entre a linha de base e dos cenários de danos facilitando uma melhor deteção.

2.4.5 Discriminação de Indicadores – *Outlier analysis*

A discriminação de indicadores passa por classificar os indicadores como sendo correspondentes a um caso de dano ou sem dano. Esta etapa pode ser dividida em aprendizagem algorítmica supervisionado ou não supervisionada. Sempre que é possível obter dados de cenários tanto com danos como sem danos no sistema a monitorizar, podem ser usados algoritmos de aprendizagem supervisionada, tais como, controlo estatístico do processo, ou redes neuronais MLP. Por outro lado, uma vez que os dados obtidos relativamente a cenários de dano no sistema a monitorizar são escassos ou inexistentes, a aprendizagem não supervisionada passou a ser alvo de interesse e estudo por parte da comunidade científica. Para tal, são utilizados métodos inovadores tendo por base algoritmos capazes de detetar danos sem acesso a uma base de dados de medição relativo a cenários de dano. O funcionamento deste tipo de ferramentas passa por indicar se um determinado comportamento do sistema é devido a uma condição normal de operação ou não. Esta técnica de análise de dados só de saída (*outlier analysis*) consiste em agrupar, por processos de distribuição probabilística, os dados de condições normais e verificar se os novos dados extraídos têm características semelhantes aos do grupo anteriormente criado, sendo assim possível estabelecer uma comparação entre ambos e determinar se existe uma reação anómala por parte do sistema ou não, para tal, é utilizado um limite de confiança estatístico (*CB – confidence boundary*), baseado na função de distribuição cumulativa inversa Gaussiana, de forma discriminar automaticamente cada indicador de dano. Devido à sua simplicidade e efetividade, esta técnica de análise de dados é amplamente utilizada.

Geralmente, a literatura assume que a distância Mahalanobis ao quadrado pode ser aproximada por uma distribuição qui-quadrada em n dimensões espaciais, portanto a distância Mahalanobis pode assumir uma configuração semelhante a uma distribuição normal (ou gaussiana), sendo assim uma análise *outlier* pode ser realizada com base num limiar estatístico, (Meixedo et al., 2021). Sob esta premissa, é possível estimar um limite de confiança (LC) para detetar um índice de danos, para tal um *outlier* pode ser estimado pela função inversa Gaussiana de uma distribuição cumulativa (FIGDC), sob a seguinte forma:

$$CB = invF_x(1 - \alpha) \quad (2.29)$$

em que:

CB – Limite de confiança (*Confidence boundary*);

α – Nível de significância.

a função F_x é dada por:

$$F(x | \bar{\mu}, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\alpha}^x e^{-\frac{1}{2}\left(\frac{x-\bar{\mu}}{\sigma}\right)^2} dy, c/ x \in \mathbb{R} \quad (2.30)$$

em que $\bar{\mu}$ é o valor médio, σ representa o desvio padrão dos vetores dos indicadores relativos aos cenários de base e para um nível de significância α .

Por conseguinte, sempre que o valor de um indicador de dano seja igual ou ultrapasse a linha representativa do limite de confiança (rejeitada a hipótese nula) considera-se como um indicador *outlier*, representado assim um estado de dano.

2.4.6 Classificação de Indicadores – *Cluster-based*

Tal como mencionado anteriormente, dentro de um conjunto de dados a análise de séries temporais e distâncias ajudam a compreender o comportamento de um determinado sistema. No entanto, após a etapa de discriminação de indicadores, que compreende em fazer a distinção entre cenários de base e de dano, é muito importante que no desenvolvimento de uma metodologia remota de MIE seja desenvolvido algoritmos de *machine learning* cuja sua função é tornar possível a distinção das diferentes severidades do dano assim como a manifestação em diferentes locais. A identificação dos indicadores compreende a agrupação de indicadores de dano em diferentes categorias. As técnicas de *clustering* nos últimos tempos tem atraído a atenção dos investigadores, (Bouzenad et al., 2019).

O processo de agrupamento (*clustering*) tem como objetivo dividir diferentes conjuntos de dados ou indicadores de dano em que cada conjunto terá de ser o mais compacto e separado dos demais quanto possível, em consequência coloca-se o desafio matemático de tentar minimizar a dispersão entre os diferentes indicadores do mesmo grupo (*cluster*) para que seja estabelecido uma maior diferença entre os diferentes grupos (*clusters*), (Meixedo et al., 2021b). Considerando uma determinada amostra com k *clusters*, $P_k = \{C_1, \dots, C_k\}$, a diferença global dentro do mesmo *cluster*, $W(P_k)$, e a diferença global entre os *clusters*, OD , podem ser definidas através das seguintes equações:

$$W(P_k) = \frac{1}{2} \sum_{k=1}^k \sum_{c(i)=kc(j)=k} \sum d_{ij} \quad (2.31)$$

$$OD = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N d_{ij} \quad (2.32)$$

em que a diferença entre dois *clusters* é dada pela subtração $B(P_k) = OD - W(P_k)$. Nestas expressões, N é o número total de indicadores e $C(i)$ é uma regra de alocação dos diferentes indicadores que possam existir num só *cluster* no qual é feita atribuição para um determinado indicador i um *cluster* k , com base na diferença medida d_{ij} definida por cada par de indicadores i e j . O algoritmo de *clustering* mais conhecido é iterativo e chama-se *k-means*, (Meixedo et al., 2022). O *k-means* requer que o número de $K < N$ clusters seja inicialmente definido com uma série de protótipos de K *clusters* aleatoriamente definidos.

A esta primeira etapa do algoritmo chama-se inicialização. De acordo com uma regra de alocação, $C(i)$, ao longo de cada processo iterativo os indicadores são movimentados para um determinado protótipo de um cluster em função da similaridade ou proximidade entre ambos; indicador e protótipo cluster. A segunda etapa de cada iteração do *k-means* consiste na representação de cada *cluster*, para tal são definidos os centroides de cada *K clusters* como seus protótipos assumindo que cada indicador pertence ao *cluster* cujo protótipo é mais próximo. Em cada iteração, o algoritmo *k-means* minimiza a distância intra-cluster, isto é, a distância entre um indicador e o centroide do mesmo *cluster*, como ilustra a Figura 2.29. Muitas repetições do *k-means clustering* com diferentes centros iniciais leva a maximizar a distância entre diferentes *clusters* (*inter-cluster*). Com base numa função objetivo estes dois processos iterativos são repetidos até que seja alcançado um valor mínimo global de compactidade e separação do *cluster*. Diferentes métricas podem ser utilizadas para calcular a minimização e maximização das distâncias, em Meixedo et al. (2022), foi utilizada a distância euclidiana (raiz quadrada da soma dos quadrados).

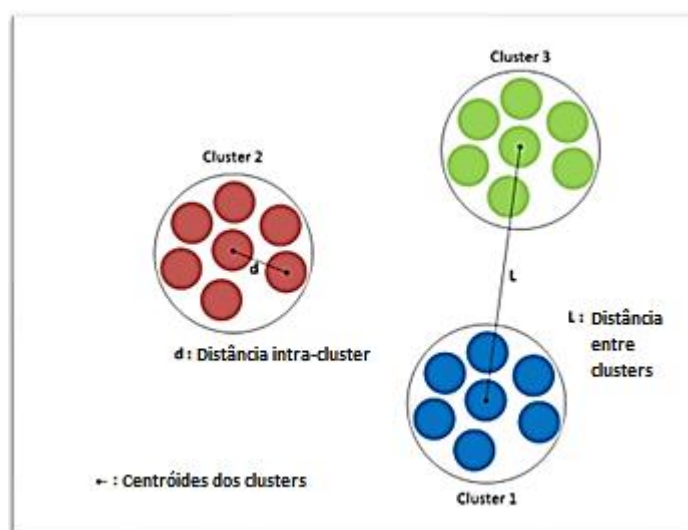


Figura 2.29 – Distâncias maximizadas e minimizadas num processo *k-means clustering* (Bouzenad et al., 2019).

A título de exemplo e demonstrativo, a Figura 2.30 mostra claramente a distinção entre dois tipos de cenários ocorridos num determinado sistema usando a técnica de *k-means clustering*, provando o sucesso desta ferramenta tanto na compactação como na separação de diferentes indicadores de dano. Nesta situação em particular refere-se a indicadores de dano extraídos por um determinado número de sensores em determinadas condições de funcionamento, ou seja, n simulações de cenários com dano e sem dano; trabalho desenvolvido no âmbito da monitorização *online* de uma ponte ferroviária, (Meixedo, 2021). A Figura 2.30a apresenta a matriz para as condições de base e a Figura 2.30b apresenta a matriz tanto para as condições de base como para as de dano. Na Figura 2.30a é possível observar que existe

uma grande compactação dos pontos (indicadores de dano) e apresentam uma uniformidade na sua classificação, enquanto na Figura 2.30b é observável uma inequívoca diferença entre os dois cenários experimentados.

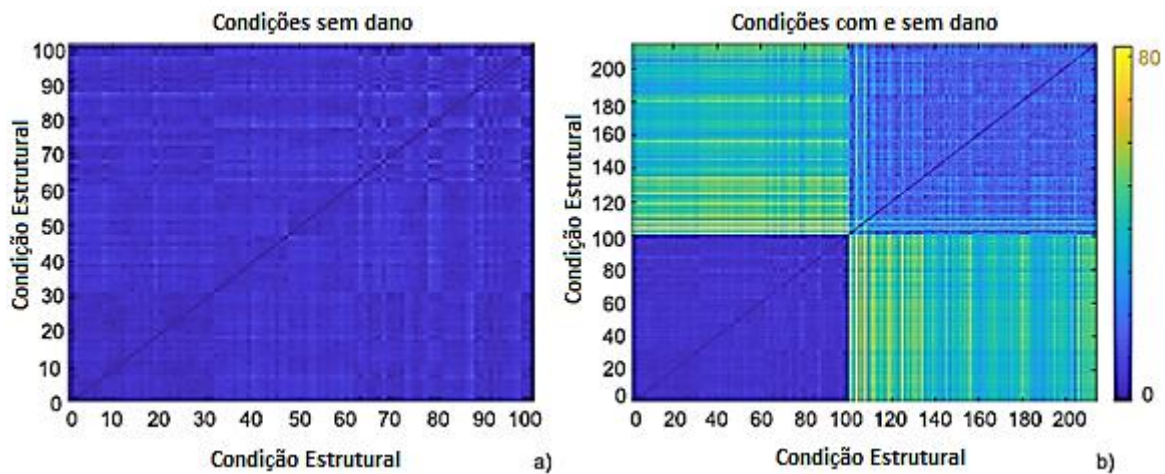


Figura 2.30 – Dissemelhanças matriciais obtidas a partir: a) condições de base, b) condições com e sem dano (azul-escuro – indicadores idênticos, amarelo – os mais diferentes), (Meixedo et al., 2021b).

Como descrito em cima, o processo *k-means clustering* requer que na fase da inicialização do processo seja definido à prior o número de *clusters* (*input*). Em trabalhos de detecção de danos, conhecer o número de *clusters* à partida torna-se impossível, portanto têm de ser experimentadas múltiplas partições, compreendendo diferentes *clusters*, testados e analisados os resultados com recurso a índices de validação. Têm sido propostos uma grande variedade de índices, não só em trabalhos de literatura específica (programação informática), mas também em aplicações no desenvolvimento de metodologias de MIE. Em Meixedo et al. (2022) foi utilizado o chamado índice de silhueta global (SIL), apresentado resultados de grande qualidade tal como referenciado em cima. Dentro daquele número de *clusters* testados são selecionados os que apresentam o valor mais alto de SIL pois são os que melhor descrevem o conjunto de indicadores analisados. Portanto, devem de ser considerados para o desenvolvimento da metodologia de MIE. A Figura 2.31a mostra que foram selecionados cinco *clusters*, a alocação pelo processo *k-means* automaticamente gerou dois tipos de *clusters* (Figura 2.31b). Verifica-se pela Figura 2.31b e Figura 2.31c, usando o SIL, a técnica *k-means* permite claramente agrupar de forma automática diferentes tipo de condições estruturais.




Figura 2.31 – Alocação de indicadores sensíveis a dano em diferentes *clusters*: a) índice de silhueta (SIL), b) centroides de *clusters*, c) *clusters* definidos para todas as condições estruturais, (Meixedo et al., 2021b).

No âmbito do desenvolvimento de uma metodologia de monitorização *online* é imprescindível que todas as etapas sejam processadas automaticamente e com capacidades internas de análises por ordem a serem tomadas as melhores decisões ao longo de todos os processos que perfazem a metodologia. O processo *k-means* embora seja um processo automático, demonstrado nesta seção, quando inserido numa metodologia MIE baseando-se numa abordagem de monitorização *online*, requer uma intervenção do utilizador a fim de verificar se os *clusters* que se vão formando com a entrada de novos indicadores de dano ao longo do tempo são compactos ou dispersos. Para contornar esta limitação, e em vez de confiar na alocação dos indicadores em *clusters* ao longo do tempo cuja abordagem seria propensa a erros, é comumente usada a chamada diferença média entre os aglomerados, DC, cuja formulação apresenta-se abaixo:

$$DC = \frac{1}{K(K-1)} \sum_{k=1}^K \sum_{\substack{c=1 \\ c \neq k}}^K d_{ck} \quad (2.33)$$

onde K é o número de *clusters* pertencendo às partições com maiores índices SIL, c e k são dois de K *clusters*, e d_{ck} é a diferença medida entre dois centroides. Em casos em que não haja dano os *clusters* gerados pelo *k-means* são semelhantes (Figura 2.30) e os valores DC são bastante reduzidos. Em situações que sejam identificados danos serão gerados *clusters* diferentes e separados pelo *k-means* (Figura 2.30b) e consequentemente grandes valores de DC .

E Meixedo et al. (2022), foi desenvolvido um procedimento de deteção de dano *online* compreendendo duas grandes etapas, a primeira etapa consiste na criação de um cenário de base e consequentemente um limite de confiança (CB), a segunda etapa diz respeito à deteção de dano remotamente, o fluxograma demonstrado na Figura 2.32 detalha cada procedimento da metodologia adotada. Os cenários de base são compostos por j simulações, relativas a circulações de comboios, em cada janela i , sendo a estratégia

de *machine learning*, composta por técnicas desenvolvidas nas seções do presente capítulo, desde a extração (ARX) à identificação da severidade (*clustering*), é aplicada tendo por base a resposta medida em cada janela i para cada passagem dos comboios j . No final desta primeira etapa é alcançado o vetor DC dos cenários de base e estimado um limite de confiança (CB). Ao longo da segunda etapa, o processo de janelas móveis é implementado em tempo real, a estratégia de *machine learning*, é implementado em cada janela i . Após a extração dos indicadores de dano, pela técnica ARX, das séries temporais da janela i , obtém-se a transformação PCA dos cenários de base, a covariância dos cenários de base e as matrizes médias são utilizadas para a fusão dos indicadores baseada na distância Mahalanobis. São agregadas as distâncias sensíveis a danos, sendo que o resultado do processo para cada uma das janelas i é um valor DC correspondente. A deteção de dano é baseada na comparação de cada um destes valores DC com o CB. Finalmente, observa-se que se um valor DC for inferior, mas perto de CB então a situação não indica a presença de um dano, podendo ser um efeito das VOA's. Caso o valor DC observado seja superior ao CB conclui-se a ocorrência de um dano.

Uma das características desta metodologia prende-se com a atualização dos cenários de base tendo em conta a entrada de novos indicadores durante a fase operacional do sistema.

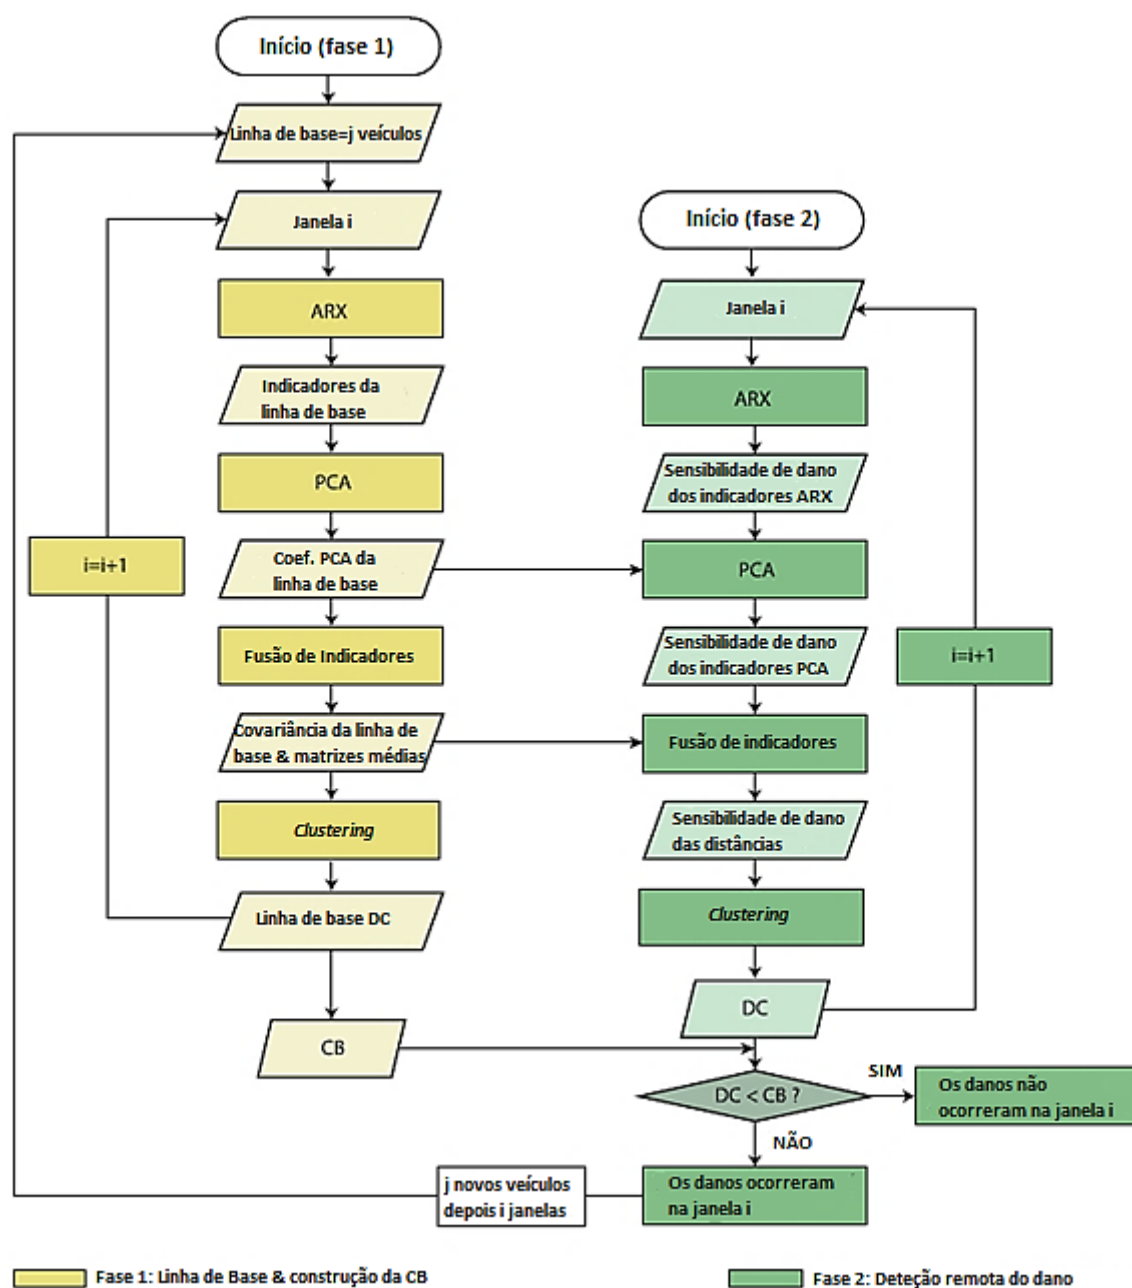


Figura 2.32 – Fluxograma do procedimento de detecção de dano por via remota baseado em janelas móveis (Meixedo et al., 2021b).

CAPÍTULO 3

CASO DE ESTUDO: MODELAÇÃO DINÂMICA DO SISTEMA VEÍCULO-VIA

3.1 DESCRIÇÃO DO MODELO PROPOSTO

A análise dinâmica do sistema veículo-via é um problema complexo, uma vez que a infraestrutura tem um carácter 3D, um grande desenvolvimento longitudinal, e está sujeita a cargas móveis de variável e elevada magnitude devido aos efeitos inerciais desenvolvidos nas massas dos veículos. O contacto entre o veículo e a via materializa-se por um ponto de contacto, tendo em consideração a geometria da roda e do carril. A influência do efeito geométrico da roda na interação do sistema resolve-se através da modelação do perfil da roda sobreposto ao do carril, (Montenegro et al., 2020). A resolução do problema dinâmico de interação do sistema veículo-via permite determinar as forças de contacto e, conseqüentemente as respostas dinâmicas na via.

Um modelo numérico do sistema dinâmico calibrado e validado é uma ferramenta poderosa, permite teoricamente reproduzir cenários equivalentes ao ocorridos em contexto real e assim analisar as diferenças de comportamento, comparando diferentes tipo de respostas a diferentes tipo de ações, estáticas e dinâmicas. Também a possibilidade de simular novos cenários, que do ponto de vista prático não seriam possíveis de reproduzir no sistema real, como por exemplo, simular diferentes tipo de danos e observar qual o comportamento do sistema face aos mesmos. As sucessivas respostas dinâmicas medidas na via, formam um conjunto de dados que serão utilizados neste trabalho para o estudo de defeitos poligonais nas rodas. A modelação numérica do sistema possibilita a validação da metodologia adotada para a deteção e identificação da poligonização nas rodas antes do seu teste em ambiente real.

3.2 MODELAÇÃO DO VEÍCULO - LAAGRSS

O veículo considerado para o desenvolvimento do presente trabalho é o veículo de mercadorias Laagrss, cujo modelo numérico foi desenvolvido por Bragança et al. (2021). O Laagrss é um veículo de transporte de mercadorias em contentores, constituído por vagões duplos com ligação articulada. De acordo com a classificação UIC, pode atingir uma velocidade máxima de 120 km/h. A tara deste vagão é de 27.000 kg,

suportando cargas até um máximo de 52.000 kg. A Figura 3.1 apresenta uma vista do vagão de carga duplo, Bragança et al. (2021).



Figura 3.1 –Visão geral do vagão de carga Laagrss, (Bragança et al.,2021).

O vagão possui dois eixos ligados à plataforma por apenas um nível de suspensão materializado por uma mola em lâminas de aço. A distância entre eixos de cada vagão é igual a 10 m, podendo transportar um contentor com 13.716 m de comprimento ou dois contentores com 6 m de comprimento cada. Neste momento, faz parte do material circulante dos operadores ferroviários Medway e COMSA, sendo este último utilizado para transportar rolos de papel através da Península Ibérica.

O modelo dinâmico tridimensional (3D) foi desenvolvido no programa ANSYS® (2018) com elementos de mola-amortecedor para simular as suspensões em todas as direções e elementos de massa pontual para representar a massa e os efeitos de inércia no centro de gravidade de cada componente dos vagões (plataforma e rodados). Adotam-se elementos de vigas rígidas para ligar os componentes acima mencionados. Apresenta-se na Figura 3.2 o modelo dinâmico do vagão de carga Laagrss, incluindo a localização da suspensão, rodados e eixos.




Figura 3.2 – Modelo dinâmico do vagão de carga Laagrss (adaptado de: Mosleh et al.,2022).

O modelo numérico do veículo encontra-se apresentado na Figura 3.3, sendo reproduzido no presente trabalho e expandido, de forma a considerar-se um conjunto de 5 vagões. As propriedades mecânicas do veículo indicadas na Figura 3.3, nomeadamente rigidez e amortecimento das suspensões designadas por k e c , respetivamente, e inércias e massas por I e m , respetivamente, encontram-se apresentadas na Tabela 3-1. A tabela apresenta ainda as propriedades geométricas, nomeadamente as distâncias longitudinais, transversais e verticais, referidas como L , W e H , respetivamente. A referência a cada um dos elementos principais do veículo, plataforma e rodados, realiza-se pelos índices cb e w , respetivamente.




Figura 3.3 – Modelo numérico do vagão de carga *Laagrss* (Bragança et al.,2021).

Tabela 3-1 – Propriedades geométricas e mecânicas do modelo numérico do vagão *Laagrss* (Bragança et al., 2021).

Parâmetro	Símbolo (unid.)	Limite de valores (mais baixo/mais alto)	Valor adotado
Carroçaria			
Massa	m_{cb} (ton)	33,2/49,8	41,1
Momento de inércia xx	$I_{cb,x}$ (t. m ²)	39,2/58,8	49
Momento de inércia yy	$I_{cb,y}$ (t. m ²)	337/674	673
Momento de inércia zz	$I_{cb,z}$ (t. m ²)	-/-	665
Comprimento	L_{cb} (m)	-/-	10 000
Largura	W_{cb} (m)	-/-	2,170
Altura acima do solo	H_{cp} (m)	-/-	2,297
Rodado			
Massa	m_w (kg)	1250/2875	1247
Momento de inércia xx	$I_{w,x}$ (kg. m ²)	-/-	312
Momento de inércia zz	$I_{w,z}$ (kg. m ²)	-/-	312
Bitola	W_{cp} (m)	-/-	1,668
Altura acima do solo	H_{ws} (m)	-/-	0,450
Suspensões			
Rigidez longitudinal	$k_{1,x}$ (kN/m)	22500/67500	44981
Rigidez lateral	$k_{1,y}$ (kN/m)	15450/46350	30948
Rigidez vertical	$k_{1,z}$ (kN/m)	1560/2780	1860
Amortecimento vertical	$c_{1,z}$ (kN. s/m)	-/-	16,7

A Figura 3.4 ilustra as molas em lâminas de aço que materializa as suspensões do vagão. Cada vagão possui 2 eixos com 2 rodados cada, contabilizando assim 4 molas foliares por vagão.




Figura 3.4 –Mola em lâminas de aço utilizada na suspensão do vagão: (a) desenho técnico; (b) pormenorização do conjunto com a caixa de eixos, (Bragança et al.,2021).

3.3 MODELAÇÃO DA VIA

O modelo numérico da via, utilizado neste trabalho foi modelado com recurso ao programa ANSYS® de elementos finitos, sendo desenvolvido em Mosleh et al. (2022). O modelo baseia-se num esquema de múltiplas camadas, simulando o balastro, as travessas e carris. As palminhas, apoiadas nas travessas sob o carril, são simuladas como elementos de mola fazendo a ligação entre os dois elementos, assim como todas as restantes ligações entre elementos são também simuladas por elementos elásticos, representado o comportamento mecânico de interface. Representa-se a massa do balastro por elementos de pontos de massa discretos, enquanto os carris e travessas modelam-se com o uso de elementos de viga, adotando-se as propriedades dos materiais adequadas a cada um deles. De notar que ambos os carris foram modelados com propriedades equivalentes às secções do tipo UIC60 (EN 13674-1). Finalmente, a fundação modela-se com recurso a uma série de molas independentes com comportamento elástico e linear. A Figura 3.5a, apresenta de forma esquemática a via, enquanto a Figura 3.5b, representa o modelo da via em elementos finitos. As propriedades do modelo da via, incluindo a descrição das variáveis apresentadas na Figura 3.5, são apresentadas na Tabela 3-2.

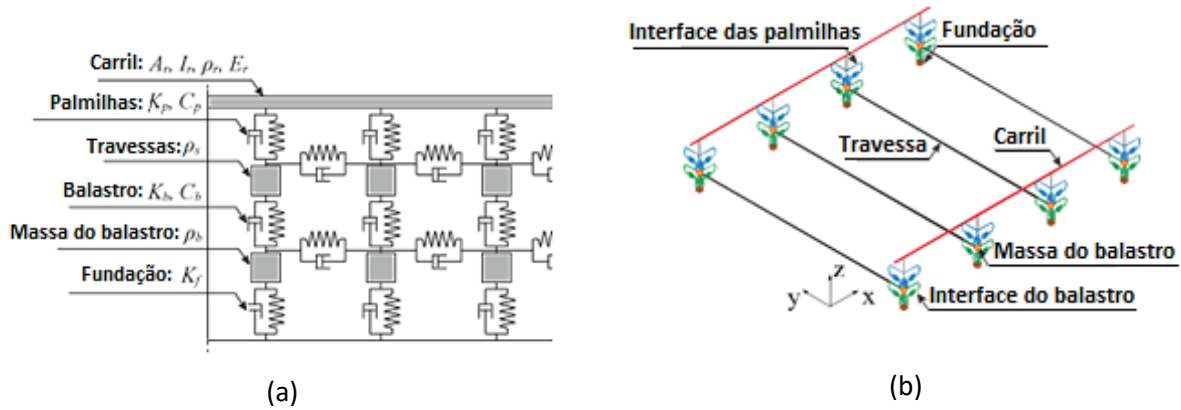


Figura 3.5 – Modelo numérico da via: (a) representação estratificada, (b) modelo EF (Mosleh et al., 2022).

Tabela 3-2 – Propriedades mecânicas da via (Mosleh et al., 2021).

Parâmetro	Valor	
Carril	A_r (m ²)	$7,67 \times 10^{-4}$
	ρ_r (kg. m ³)	7850
	I_r (m ⁴)	$30,38 \times 10^{-6}$
	v_r	0,28
	E_r (N/m ²)	210×10^9
Palmilhas, dir.logitudinal	k_p (N/ m)	20×10^6
	C_p (N. s/m)	50×10^3
Palminhas, dir.lateral	k_p (N/ m)	20×10^6
	C_p (N. s/m)	50×10^3
Palminhas, dir.vertical	k_p (N/ m)	500×10^6
	C_p (N. s/m)	200×10^3
Travessas	ρ_s (N/ m)	2590
	v_s	0,2
	E_s (N. s/m)	$40,9 \times 10^9$
Balastro, dir.logitudinal	$k_{b,x}$ (N/ m)	900×10^3
	$C_{b,x}$ (N. s/m)	15×10^3
Balastro, dir.lateral	$k_{b,y}$ (N/ m)	2250×10^3
	$C_{b,y}$ (N. s/m)	15×10^3
Balastro, dir.vertical	$k_{b,z}$ (N/ m)	30×10^6
	$C_{b,z}$ (N. s/m)	15×10^3
Fundação, dir.logitudinal	$k_{f,x}$ (N/ m)	20×10^6
	$C_{f,x}$ (N. s/m)	$5,01 \times 10^2$
Fundação, dir.lateral	$k_{f,x}$ (N/ m)	20×10^6
	$C_{f,x}$ (N. s/m)	$5,01 \times 10^2$
Fundação, dir.vertical	$k_{f,z}$ (N/ m)	20×10^6
	$C_{f,z}$ (N. s/m)	$5,01 \times 10^2$

3.4 MODELAÇÃO DO PERFIL DE IRREGULARIDADE DA VIA

Num contexto real, é impossível encontrar-se vias completamente regulares. As vias apresentam certas irregularidades que desempenham um papel fundamental na geração de cargas dinâmicas ao longo dos movimentos dos veículos sobre a via. Caso fossem negligenciadas, as cargas transmitidas pelos rodados na via simplificavam-se em cargas quase-estáticas. Porém, para uma correta aproximação ao cenário real a componente dinâmica da carga deverá ser considerada, para tal, é imperativo a modelação da irregularidade da via.

Com base em dados reais, foram geradas curvas de densidade espectral de potência e de seguida criados perfis artificiais de irregularidades no programa MATLAB® (2018a), tanto desvios na direção vertical como na transversal. Adotaram-se comprimentos de onda entre 1m a 75m, cobrindo os intervalos de comprimento de onda D1 (3m a 25m) e D2 (25m a 70m) definidos pela Norma Europeia EN 1384-2 (2006), com uma discretização de amostragem de 0,25m. As curvas de densidade espectral de potência assumidas são as propostas pela Administração Ferroviária Federal (FRA), de acordo com a seguinte função:

$$S(K_1) = \frac{10^{-7}AK_3^2(K_1^2 + K_2^2)}{K_1^4(K_1^2 + K_3^2)} \quad (3.1)$$

em que, K_2 e K_3 são constantes que assumem os valores de 0.1464 e 0.8168 rad/m, respetivamente. K_1 é o número de onda que depende da frequência espacial cíclica da irregularidade, é dado por $2\pi/\lambda$. O comprimento de onda, λ , considerado varia entre o intervalo de 1 a 75m. O parâmetro A está relacionado com a qualidade da via, como mostra a Tabela 3-3, que por sua vez depende da velocidade máxima de circulação na via em estudo (ver Tabela 3-4). Porém, no presente trabalho os dados do parâmetro de irregularidade adotados, foram os calculados em Mosleh et al. (2019), baseados na informação de dados experimentais medidos pela Administração dos Caminhos de Ferro Portugueses, no qual o valor do parâmetro A calculado toma o valor igual a $1.02 \text{ m}^3/\text{rad}$.

Tabela 3-3 – Parâmetro de rugosidade para as classes da via FRA (Administração Ferroviária Federal).

Classe	1	2	3	4	5	6
A (m^3/rad)	660,079	376,229	208,841	116,856	65,929	37,505

Tabela 3-4 – Coeficiente para a densidade espectral de potência (Administração Ferroviária Federal).

Classe	1	2	3	4	5	6
Velocidade máxima	16	40	64	97	129	177
	Mercadorias (km/h)					

No presente estudo foram considerados 4 tipos de perfis de irregularidade em cada uma das direções, vertical e transversal, e em ambos os lados da via. A Figura 3.6 demonstra os 4 tipos de irregularidades adotadas em cada direção relativamente ao lado direito da via. A amostragem dos perfis desenvolve-se ao longo de um troço reto de 170 m, sendo este o comprimento total nas simulações numéricas. Os perfis de irregularidades gerados apresentam valores de pico inferiores ao indicados na NP EN 13848-5:2008+A12015 (Quadro B.3 do Anexo B) relativamente ao nivelamento longitudinal (B.2.2), verificando-se que os valores de pico máximos apresentados abaixo variam entre 5-6mm.




Figura 3.6 – Amostra dos perfis de irregularidade da via (lado direito): a) transversal; b) vertical.

3.5 MODELAÇÃO DO PERFIL DE IRREGULARIDADE DAS RODAS

O interesse do presente trabalho passa pela deteção e identificação do efeito do dano poligonal em rodas de veículos ferroviárias. Atendendo que a forma poligonal da roda é caracterizada pelo número de harmónicos, foram considerados diferentes números de harmónicos em função das medições de campo evidenciados na arte. Para cada intervalo de harmónicos considerado (4-7; 10-13; 17-20) foram gerados no programa MATLAB® 10 perfis aleatórios de irregularidades perimetrais, analisando-se o efeito dos diferentes parâmetros. As expressões geométricas consideradas para a caracterização das irregularidades podem ser consultadas na secção 2.3.2.3. Na Figura 3.7 é retratado uma amostra de 4 tipos de poligonizações para cada conjunto. Pelos gráficos é possível verificar que o nível de severidade vai aumentando em função do número de harmónicos. Como seria de esperar, as ondulações geradas pelos harmónicos de ordem inferior são mais suaves relativamente às de ordem superior. Neste caso a profundidade (Δr) do dano entre sucessivos comprimentos de onda parece não ser representativa de grande influência na futura ação imposta pelo dano, tratando-se de ordens de grandeza bastantes reduzidas, maioritariamente entre $0.5 \times 10^{-5} m$ a $4 \times 10^{-5} m$, aproximadamente.

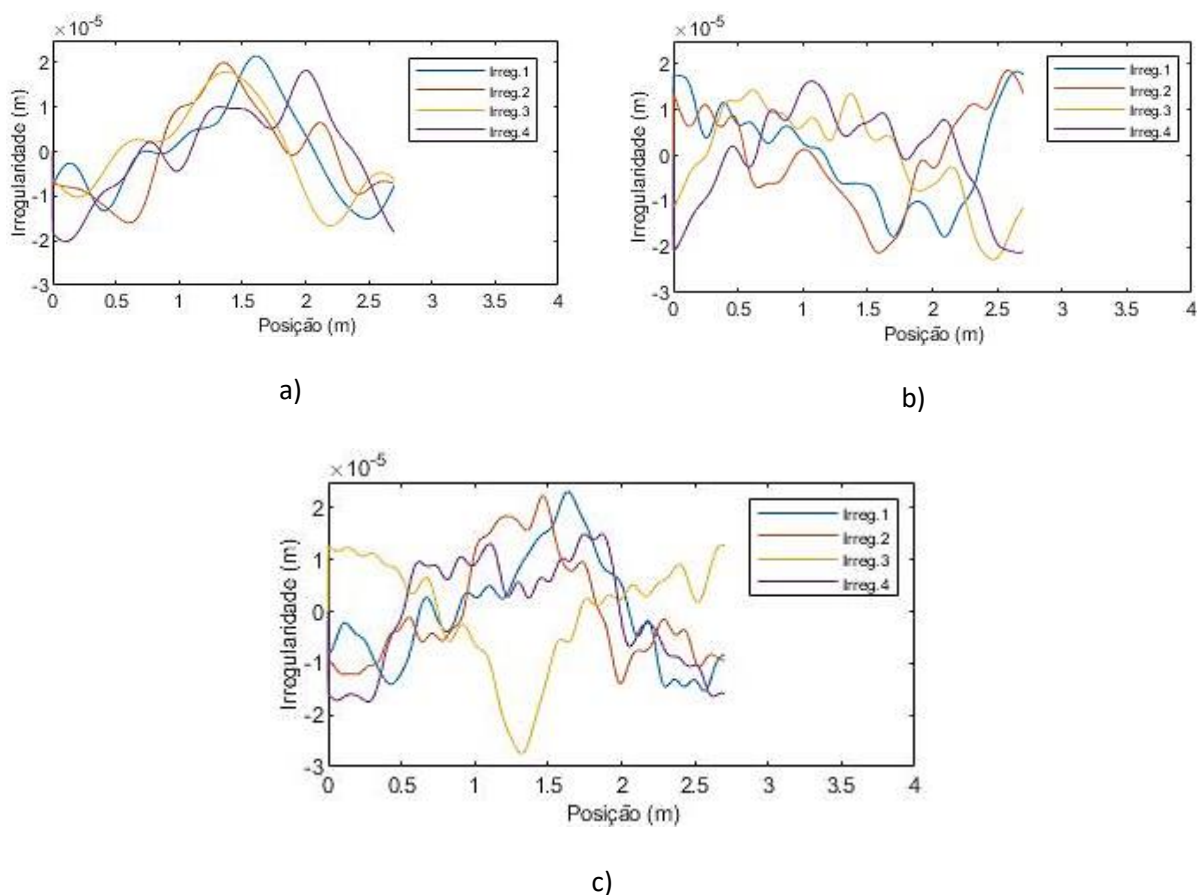


Figura 3.7 – Perfis de irregularidades da roda: a) 4-7 harmônicos; b) 10-13 harmônicos; c) 17-20 harmônicos.

Os valores das amplitudes máximas para cada um dos harmônicos preditas pelo presente modelo de caracterização geométrica são bastante reduzidas ($4 \times 10^{-5} m$). Em alguns levantamentos de campo foram evidenciadas amplitudes de desgaste na ordem dos 0.6 mm (Peng, 2020; Tao et al., 2020).

3.6 INTERAÇÃO DINÂMICA VEÍCULO-VIA

As simulações de interação dinâmica veículo-via foram realizadas no presente trabalho com recurso ao software *VSI-Vehicle-Structure Interaction Analysis*, desenvolvido por Neves et al. (2014) e posteriormente melhorado por Montenegro et al. (2015). O melhoramento do software passou por incorporar a interação lateral através de um modelo de contacto roda-carril, considerando tanto as forças normais como as tangenciais que ocorrem na superfície de contacto. Esta ferramenta numérica, capaz de lidar com a dinâmica lateral, é implementada em MATLAB® (2018) e importa as matrizes estruturais, rigidez, massa e amortecimento, tanto do veículo como da via previamente modelados num programa de elementos finitos, sendo neste caso de estudo o ANSYS® (2018). Note-se que, embora os modelos de ambos os subsistemas sejam primeiro modelados separadamente, o software VSI liga-os através de uma

metodologia totalmente acoplada, conforme apresenta-se na Figura 3.8. Pode-se observar que as irregularidades tanto da roda como da via não são modeladas, mas sim caracterizadas geometricamente em MATLAB® (2018), sobrepostas e consideradas nas análises dinâmicas VSI.

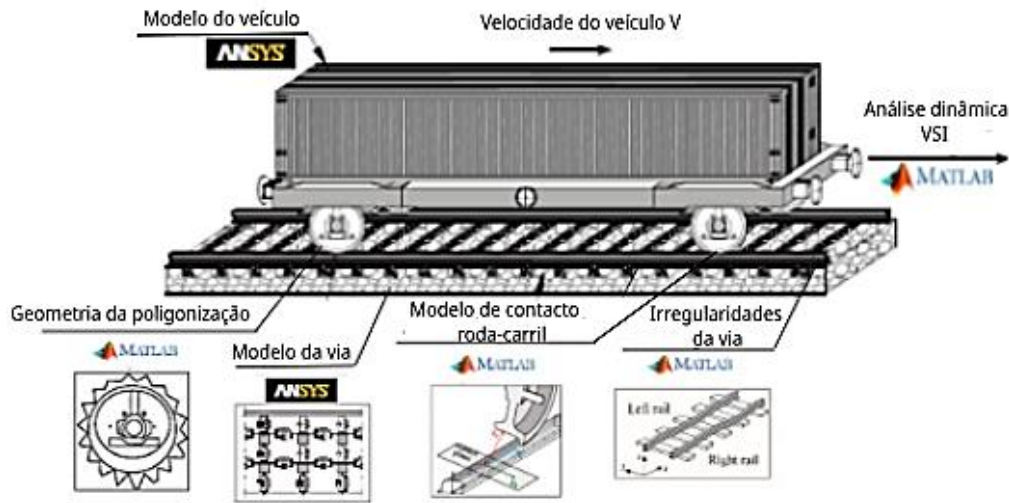


Figura 3.8 – Modelo de interação dinâmica veículo-via, (adaptado de Bragança et al., 2021).

A formulação para a resolução do problema de contacto consiste nas seguintes principais etapas: (i) deteção do ponto de contacto, (ii) solução do problema de contacto normal e (iii) solução do problema de contacto tangencial. Com a interface de contacto totalmente caracterizada, as equações de movimento do veículo e da via são complementadas com as equações de constrangimento que acoplam estes dois sistemas estruturais. Nesta secção será realizada uma breve descrição do modelo de contacto roda-carril, assim como será apresentada as equações de equilíbrio do sistema dinâmico. A formulação matemática completa e validação do modelo numérico pode ser consultada em Neves et al., 2014 e Montenegro et al., 2015.

A formulação do contacto roda-carril assenta num elemento finito de contacto especialmente desenvolvido para a ferramenta numérica. Este elemento, implementado em MATLAB® (2018), é utilizado em primeiro lugar para avaliar a localização de ponto de contacto entre a roda e o carril, com base no movimento relativo entre o veículo e a estrutura, (Montenegro et al., 2022). Este primeiro passo, denominado de deteção do ponto de contacto, é realizado através da parametrização das superfícies dos corpos em contacto, nomeadamente a roda e o carril. A potencial posição do ponto de contacto é avaliada pelas seguintes equações não lineares:

$$\begin{cases} \mathbf{t}_r \cdot \mathbf{d}_{wr} = 0 \\ \mathbf{t}_w \cdot \mathbf{n}_r = 0 \end{cases} \quad (3.2)$$

em que \mathbf{t}_r e \mathbf{t}_w são vetores tangentes às superfícies de contacto do carril e da roda, respetivamente, \mathbf{n}_r é um vetor normal à superfície de contacto na via e \mathbf{d}_{wr} é o vetor que define a posição relativa entre os pontos de contacto na superfície da roda e no carril. A direção do vetor é apontada para a roda. Salienta-se que o sistema de equações (3.2) pode ter várias soluções caso as superfícies de contacto não sejam convexas. Partindo-se deste pressuposto, a região côncava na zona de transição entre o carril e a flange da roda é desconsiderada, Montenegro et al. (2015). A Figura 3.9, demonstra as duas possibilidades, ocorrência de ponto de contacto e não ocorrência, representativo de possíveis soluções para o sistema de equações (3.2).

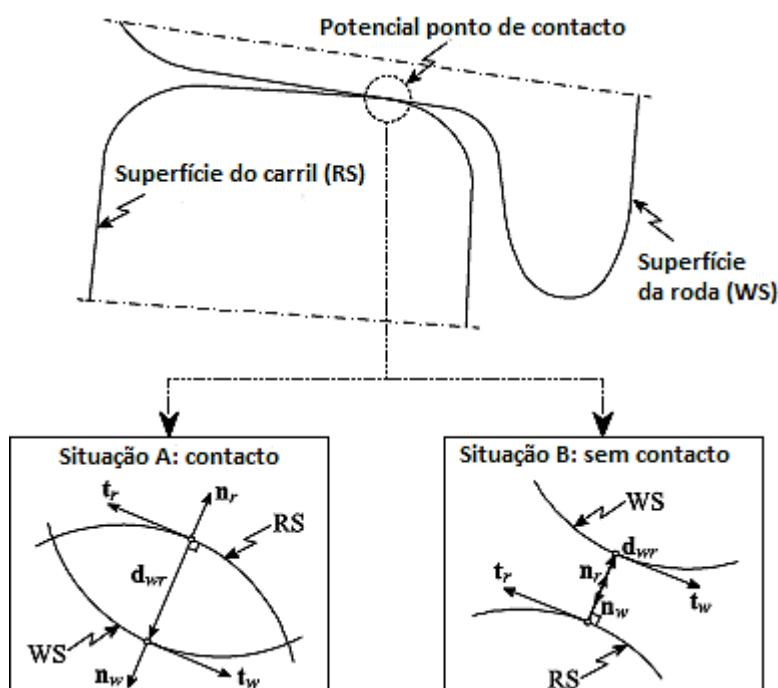


Figura 3.9 – Possíveis cenários de soluções válidas na procura do ponto de contacto, (Montenegro et al., 2022).

Conforme se pode verificar pela Figura 3.9, quando há contacto entre as duas superfícies os vetores \mathbf{d}_{wr} e \mathbf{n}_r têm direções opostas, então para satisfazer a condição de ocorrência de ponto de contacto entre as superfícies dos elementos (roda e carril) a condição abaixo tem de ser verificada:

$$d_{wr}^t \cdot n_r^t \leq 0 \quad (3.3)$$

A solução do ponto de contacto consiste num processo iterativo até que seja alcançado o mesmo. Um dos grandes desafios no processo iterativo é o de evitar a divergência no processo ou uma convergência muito lenta, maioritariamente causado pelos saltos da posição do ponto de contacto, devido à ocorrência de contactos entre a flange e a mesa de rolamento. Pode ser consultado em Montenegro et al. (2015) o desenvolvimento de um estudo detalhado de todos os passos necessários para contornar estes problemas a fim de obter-se uma eficaz e otimizada formulação.

Após a solução do ponto de contacto estar resolvida, o problema de contacto normal é analisado com base na teoria não linear de Hertz, esta teoria é apropriada para situações em que a área de contacto é bastante diminuta quando comparada com a escala da dimensão dos dois corpos em contacto, sendo essa a situação presente. A força de contacto normal F_n entre a roda e o carril é dada por:

$$F_n = K_h d^{3/2} \quad (3.4)$$

em que, d é a penetração sendo $d = \|\mathbf{d}_{wr}\|$ e K_h é o coeficiente generalizada de Hertz. Por último, as forças tangentes ao plano de contacto calculam-se com base na teoria exata do contacto tridimensional de rolamento de Kalker. Em Montenegro et al. (2015) essas forças foram calculadas previamente e armazenadas, as formulações podem ser consultadas no estudo referenciado.

As equações de equilíbrio de forças do sistema veículo-via são complementadas com equações de restrição adicional que relacionam as deslocações do nós de contacto do veículo com a correspondente deslocação nodal da estrutura. Estas equações formam um sistema único, cujas incógnitas são deslocamentos e forças de contacto. O sistema matricial pode ser descrito matematicamente como:

$$\begin{bmatrix} \bar{\mathbf{K}} & \bar{\mathbf{D}} \\ \bar{\mathbf{H}} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \Delta \mathbf{a}_F^{i+1} \\ \Delta \mathbf{X}^{i+1} \end{bmatrix} = \begin{bmatrix} \boldsymbol{\Psi}(\mathbf{a}^{t+\Delta t, i}, \mathbf{X}^{t+\Delta t, i}) \\ \bar{\mathbf{r}} \end{bmatrix} \quad (3.5)$$

onde $\bar{\mathbf{K}}$ é a matriz de rigidez efetiva do sistema acoplado, $\bar{\mathbf{r}}$ é o vetor de irregularidades da via, em cada período este vetor é interpolado em função da posição da roda. Devido à natureza não linear do problema, foi implementada uma formulação baseada em deslocamentos incrementais $\Delta \mathbf{a}$ e forças de contacto $\Delta \mathbf{X}$, no qual $\boldsymbol{\Psi}$ é o vetor da força residual. Finalmente, uma vez que o nó B do elemento de contacto está localizado sobre pontos não nodais da via (o elemento de contacto está em constante movimento), $\bar{\mathbf{D}}$ e $\bar{\mathbf{H}}$ são matrizes de transformação que relacionam as forças de contacto e as deslocações, respetivamente, no sistema de coordenadas locais com o sistema de coordenadas globais. Os sobrescritos $t + \Delta t$ indicam o instante de tempo atual, enquanto i e $i + 1$ referem-se à anterior e atual iteração, respetivamente.

CAPÍTULO 4

METODOLOGIA DE DETEÇÃO E IDENTIFICAÇÃO DE POLIGONIZAÇÃO EM RODAS BASEADO NAS RESPOSTAS INDUZIDAS POR TRÁFEGO

4.1 DESCRIÇÃO DA METODOLOGIA

No âmbito da presente dissertação foi desenvolvida uma metodologia de deteção e identificação de danos poligonais nas rodas de veículos ferroviários de mercadorias. Este capítulo apresenta uma estratégia de aprendizagem de máquina que consiste numa combinação híbrida entre os métodos de análises das séries temporais e as técnicas estatísticas multivariadas. São desenvolvidas diferentes técnicas de extração de indicadores sensíveis aos danos, e o correspondente tratamento de dados, por forma a obter uma metodologia robusta e efetiva, conforme ilustrado na Figura 4.1. As técnicas implementadas foram detalhadas na secção 2.4. No presente capítulo serão analisados os resultados de cada etapa do procedimento da implementação da metodologia.

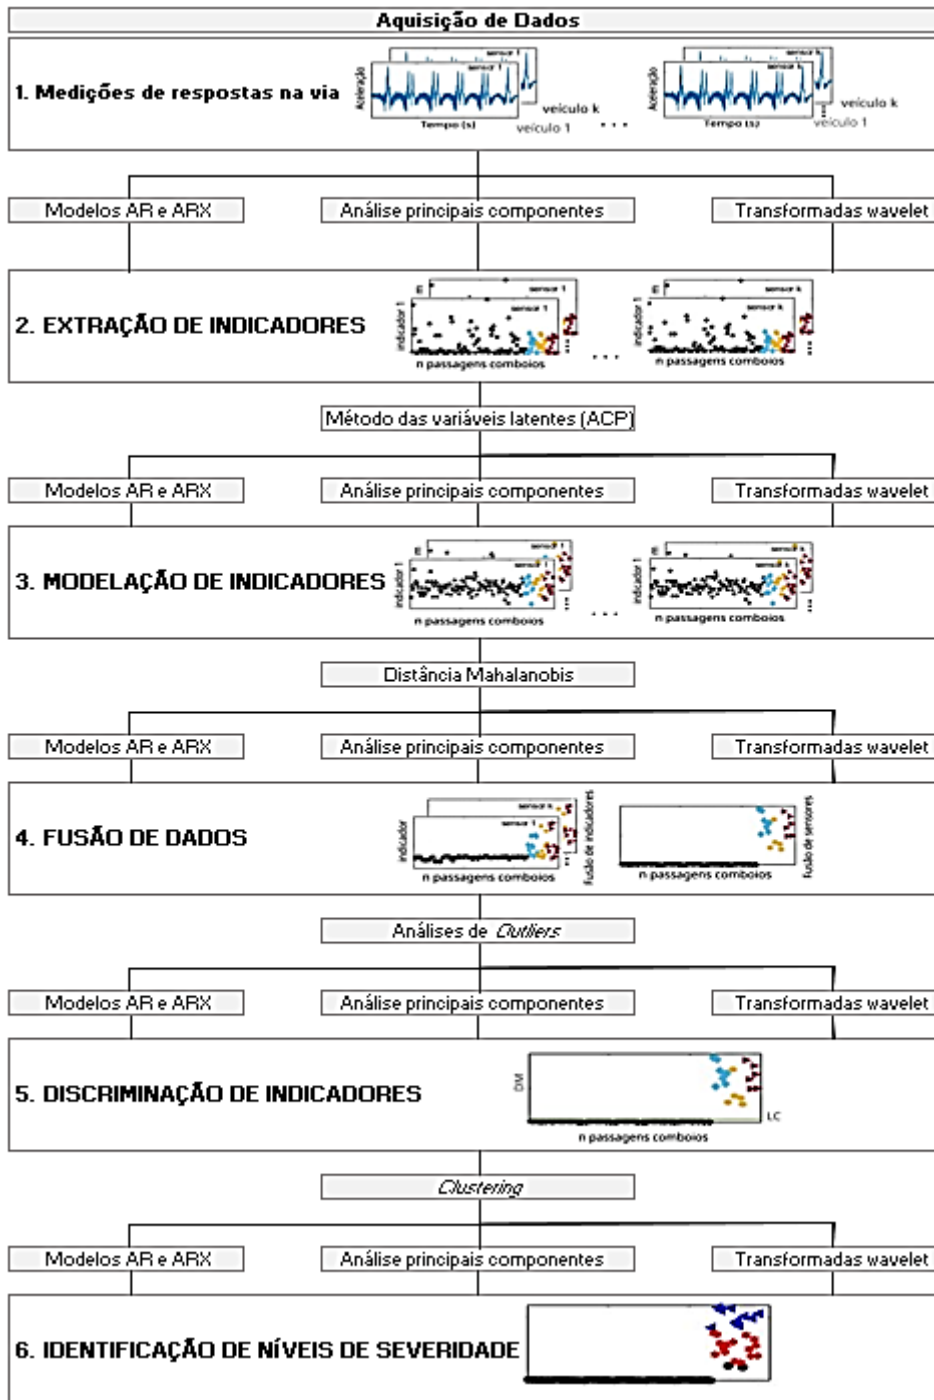


Figura 4.1 – Fluxograma das diferentes técnicas implementadas na estratégia de aprendizagem de máquina para a deteção e identificação de danos poligonais nas rodas dos veículos.

A metodologia foi criada tendo por base unicamente resultados de medições de resposta na via adquiridos por análises numéricas, para os quais utilizaram-se os modelos descritos no Capítulo 3. Para tal, consideraram-se diferentes tipos de cargas, velocidades e irregularidades, de forma a serem criados cenários abrangentes formando uma linha de referência bastante robusta aproximando-se à gama de cenários experienciados em contextos reais. É efetuada a comparação de desempenho entre diferentes

técnicas de extração de indicadores, nomeadamente modelos autorregressivos AR e ARX, transformadas wavelet e análise de componentes principais. Para remover os efeitos das variações operacionais e ambientais adotou-se o método das variáveis latentes APC, que demonstrou ser eficiente na normalização dos dados. Utilizou-se a distância Mahalanobis para a fusão de todos os indicadores e numa segunda fase para a fusão de todos os sensores, provando-se, assim, que a operação de fusão de segunda ordem aumentou significativamente a efetividade da deteção de dano. A deteção automática de dano e de classificação da severidade do dano foram desenvolvidas com recurso à técnica de *Outliers* e *Clusters*, respetivamente. Com a primeira foi criado um limite de confiança em que distingue os cenários de referência (sem dano) daqueles com dano, e no segundo é gerado o agrupamento automático para cada tipo de severidade de dano. As técnicas implementadas na presente dissertação estão em linha com trabalhos desenvolvidos na área da deteção de danos em rodas de veículos ferroviários, nomeadamente em Mosleh et al. (2022), que consistiu em desenvolver uma abordagem de deteção de lisos nas rodas de veículo ferroviários. A criação de estratégias para a deteção e identificação de poligonização nas rodas pretende aumentar o alcance deste tipo de abordagens uma vez que já obteve resultados satisfatórios, por exemplo no caso dos lisos nas rodas. Porém, a poligonização traz um grande desafio, primeiro porque é um fenómeno ainda pouco estudado e segundo este efeito, apesar de poder colocar em causa a segurança ferroviária, induz impactos de baixa magnitude comparando com os lisos nas rodas.

Ao longo do presente capítulo serão expostos todos os cenários numéricos considerados, a análise dos resultados de acordo com a influência de diferentes parâmetros, nomeadamente, velocidade, cargas e irregularidades tanto da via como das rodas. De seguida, serão abordados os diferentes passos da estratégia de deteção e identificação de danos proposta, extração de indicadores, modelação de indicadores, fusão de dados e discriminação dos indicadores.

4.2 SIMULAÇÕES DE CENÁRIOS DE BASE E DE DANO

Sendo difícil obter condições experimentais para a validação das estratégias de deteção de danos devido ao elevado custo, após a validação do modelo dinâmico de interação veículo-via, é possível simular cenários de danos no modelo numérico calibrado de forma a poder validar a metodologia de deteção de danos proposta. Foram considerados diferentes tipos de cenários baseados em condições reais de operabilidade, quer para cenários de base (sem dano) quer para os cenários de dano.

4.2.1 Cenários de Base

Tal como demonstrado em Meixedo (2021) o procedimento de simulação de danos passa por duas etapas: numa primeira fase, de forma a reproduzir a resposta, considerando o veículo de mercadoria Laagrss

foram adotadas diferentes combinações, de velocidades, cargas, irregularidades estando sumariadas na Figura 4.2. Nestas combinações de diferentes cenários não estão incluídos quaisquer tipos de danos na estrutura da via e nem no veículo.

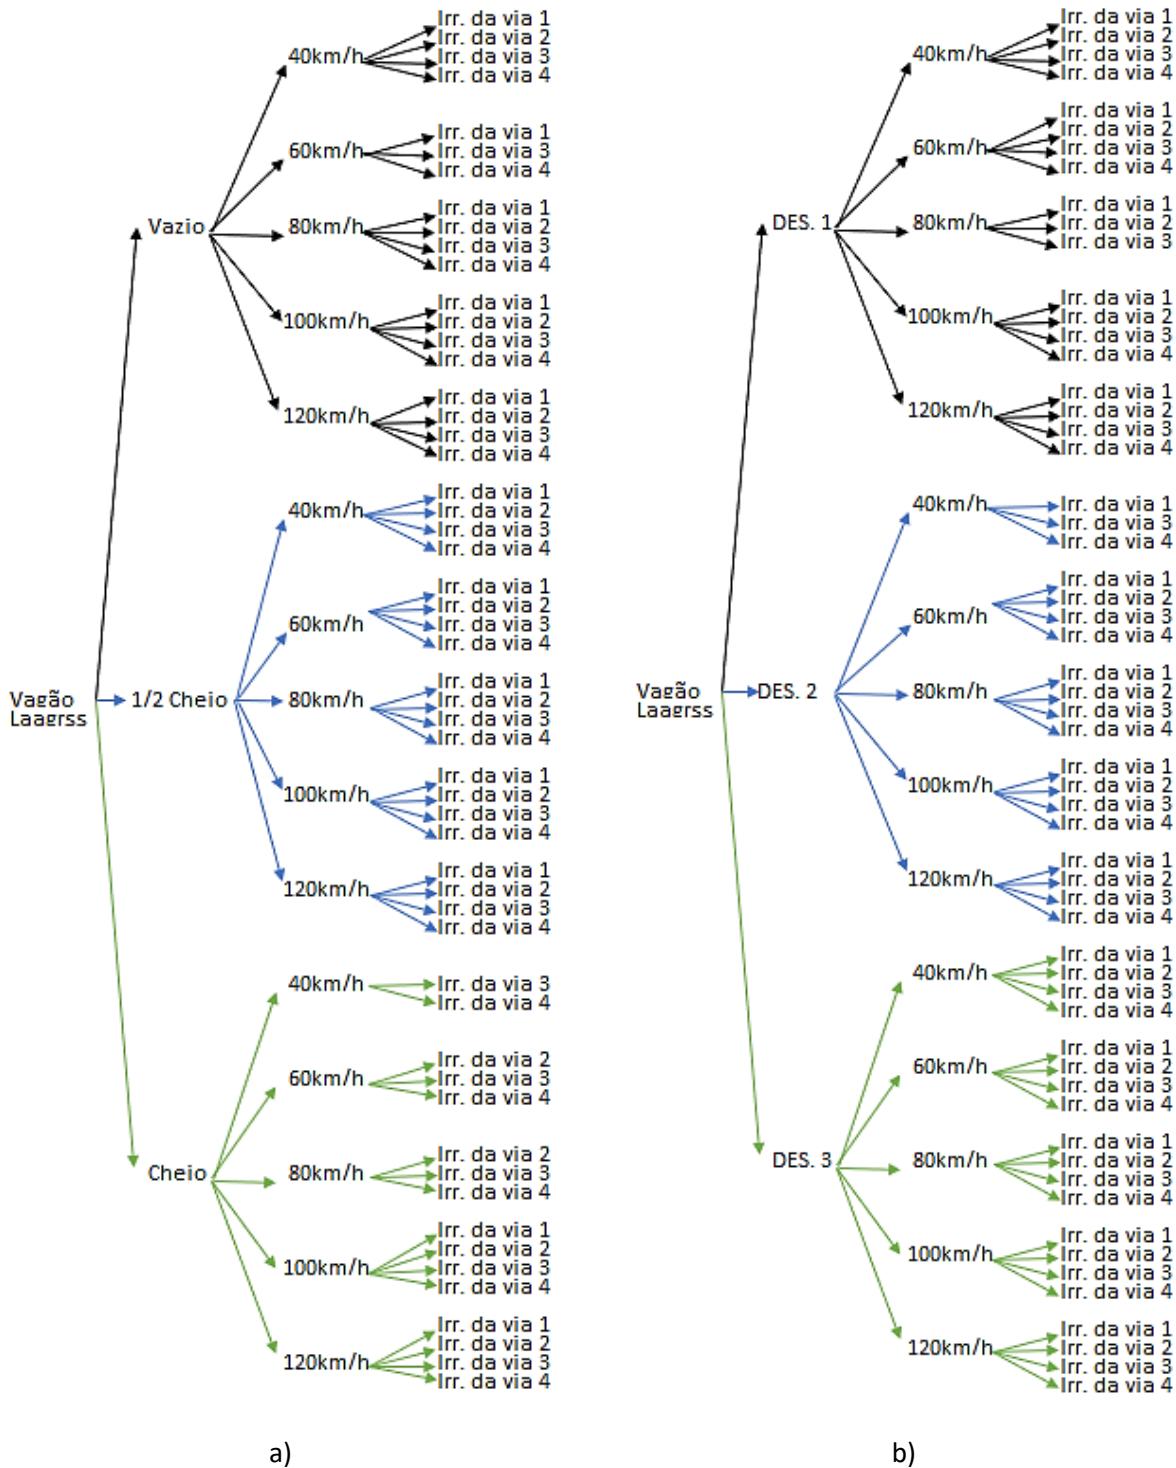


Figura 4.2 – Cenários de base (referência) considerados (113 no total): a) Diferentes tipo de cargas uniformemente distribuídas, b) Desequilíbrio de cargas abaixo do limite.

A gama de velocidades adotadas são as que se experienciam num contexto real no transporte ferroviário de mercadorias assim como as irregularidades da via caracterizadas. Os diferentes tipo de carregamentos têm um grande impacto nas respostas medidas, tal que, foram considerados 6 diferentes tipos de esquemas de cargas, uniformemente distribuídas e de desequilíbrio de cargas abaixo do limite legal, conforme ilustram as Figura 4.3 e Figura 4.4 abaixo representadas.




Figura 4.3 – Diferentes esquemas de carga (uniformemente distribuídos) considerados: a) carga total, b) ½ carga, c) vazio.




Figura 4.4 – Diferentes esquemas de desequilíbrio de cargas abaixo do limite considerados: a), b) desequilíbrio longitudinal (DES.1 e 2), c) desequilíbrio transversal (DES.3).

4.2.2 Cenários de Dano – Poligonização

Foram consideradas diferentes gamas de irregularidades circulares nas rodas, poligonização nas rodas com harmônicos de ordem (w) 4-7, 10-13 e 17-20, estando localizadas na 1ª roda do lado direito do 1º vagão, na 2ª roda do lado esquerdo do 3º vagão e na 2ª roda do lado direito no 5º vagão. De acordo com a bibliográfica foram observados danos poligonais com harmônicos de ordem 17 a 24 em estágios mais avançados. Assim, consideraram-se estes níveis de severidade, primeiro para garantir uma correta detecção do dano em estágios avançados, e em segundo para identificar danos poligonais em estágios precoces – ordens de harmônicos ou número de comprimentos de onda (w) mais reduzidos. Porém, a amplitude do desgaste considerada no presente trabalho é bastante reduzida face a alguns levantamentos no campo (Peng, 2020; Tao et al.,2020). A Figura 4.5 representa o esquema de localização do dano.




Figura 4.5 – Esquema de localização do dano.




Figura 4.6 – 90 cenários de dano considerados.

A velocidade de circulação adotada foi de 80km/h, na qual representa a média de velocidades a que os vagões circulam, uma irregularidade da via (tipo 2) e carga total (15x2 toneladas). No total foram considerados 90 cenários de dano conforme retrata a Figura 4.6.

4.2.3 Simulação Numérica

Para a detecção da poligonização nas rodas foram considerados 48 acelerómetros instalados consecutivamente a meio vão entre travessas, 24 do lado direito da via e 24 do lado esquerdo. A Figura 4.7 ilustra o sistema de monitorização virtual do lado da via.




Figura 4.7 – Sistema de monitorização virtual - do lado da via.

As simulações numéricas foram implementadas considerando diferentes dados de entrada, tais como, velocidades, esquemas de cargas e diferentes tipo de irregularidades descritas nas secções 4.2.1 e 4.2.2, a fim de reproduzir as respostas na via tanto para os cenários de base (sem dano) como para os cenários de dano. O ruído pode perturbar de forma significativa a avaliação das respostas na via. Por forma a avaliar o seu efeito nas medições foi considerado em cada simulação numérica um ruído artificial de 5% e em termos de frequência de amostragem é utilizada uma frequência igual a 10 kHz, para obter uma reprodução mais aproximada e fiável da resposta dinâmica.

Na Figura 4.8 é possível observar exemplos de séries temporais de acelerações, onde é visível a influência dos diferentes parâmetros considerados nas simulações numéricas. A Figura 4.8a, retrata a influência de diferentes velocidades nas respostas das acelerações medidas ao longo do tempo. Sendo estabelecida a comparação das respostas para velocidades de 40km/h e 80km/h, verificando-se que quanto mais elevada é a velocidade maior é a magnitude da resposta. Nestas simulações foram considerados o mesmo tipo de carregamento (cheio) e o mesmo perfil de irregularidades (tipo 2). Na Figura 4.8b, demonstra-se a influência dos perfis de irregularidades da via considerando o mesmo tipo de carga (cheia) e a mesma velocidade (80km/h) concluindo-se, como se esperaria, não haver uma diferença significativa na resposta observada. Quando considerado diferentes tipos de cargas é possível observar uma clara diferença entre as respostas (Figura 4.8). Quanto maior o carregamento maior é a magnitude da resposta, sendo que nesta análise comparativa adotou-se uma velocidade igual a 80km/h e o perfil de irregularidades da via do tipo 2.

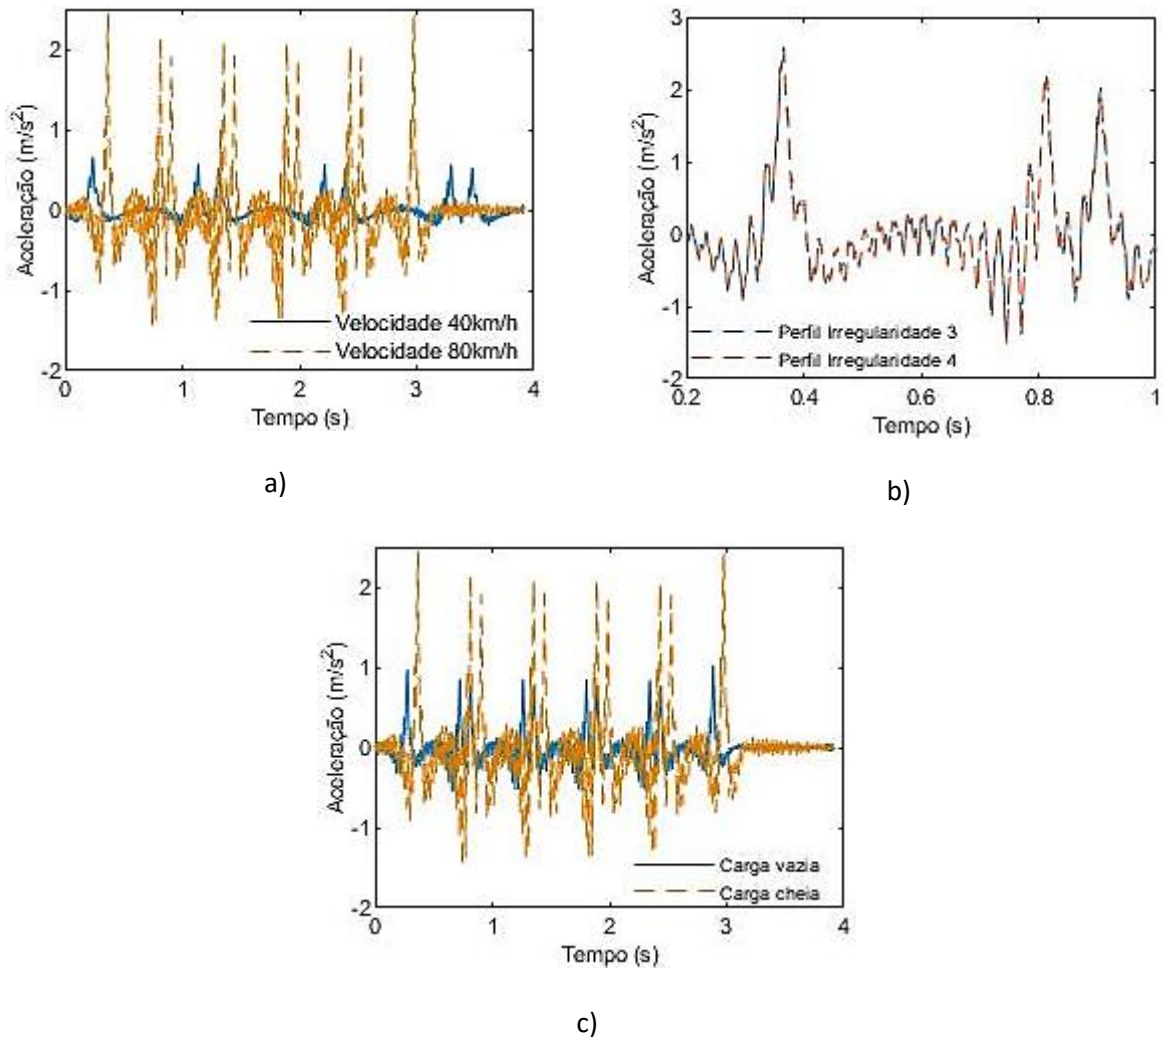


Figura 4.8 – Séries temporais de acelerações no sensor 1 considerando o cenário de base, 5% de ruído e corte de frequência nos 500Hz: a) influência da velocidade, b) influência dos perfis de irregularidades da via, c) influência da carga.

Na Figura 4.9 ilustra-se a comparação da resposta medida relativamente a passagem de vagões com e sem dano. Apesar de ser considerado o tipo de dano mais gravoso (17-20 harmônicos) é visível a similaridade entre as acelerações medidas em cada um dos casos. Sendo a amplitude de desgaste reduzida não é promovido um grande aumento das forças de impacto. O dano considerado foi na 1ª roda do 1º vagão.




Figura 4.9 – Séries temporais de acelerações no sensor 1 considerando cenário de base e cenário com dano poligonal na roda do 1ºvagão com 5% de ruído e corte de frequência nos 500Hz: a) Todos os registros da passagem do veículo, b) pormenorização.

Apesar de pequenas as diferenças nas respostas, é observável pela Figura 4.10 que quanto maior a gama da ordem dos harmónicos maior é a resposta. Em todas as análises os picos das acelerações correspondem à passagem dos eixos dos vagões, sendo que os dois picos simultâneos correspondem aos dois eixos próximos entre cada um dos vagões. Todas as séries temporais foram filtradas com base num filtro digital passa-baixo Chebyshev tipo II com uma frequência de corte igual a 500 Hz. Pela análise das simulações pode-se concluir, como era expectável, que o cenário mais gravoso de poligonização é o relativo à gama de ordem dos harmónicos entre 17-20. Será esta a gama de dano poligonal considerada no desenvolvimento da estratégia de deteção automática de dano.




Figura 4.10 – Séries temporais de acelerações no sensor 1 para diferentes severidades de dano poligonal na roda do 1ºvagão com 5% de ruído e corte de frequência nos 500Hz: a) Todos os registros da passagem do veículo, b) pormenorização.

4.3 DETEÇÃO AUTOMÁTICA DE POLIGONIZAÇÃO NAS RODAS

Os fundamentos teóricos de cada técnica utilizada nos subgrupos da presente secção foram desenvolvidos na secção 2.4. Em todos os passos foram considerados resultados de indicadores relativos a diferentes abordagens/técnicas, para aumentar a sensibilidade de forma a conduzir a uma melhor solução a adotar na estratégia de aprendizagem de máquina para deteção remota e não supervisionada da poligonização nas rodas. Os indicadores utilizados são os baseados em modelos autorregressivos AR e ARX, análises de componentes principais (PCA) e transformadas contínuas wavelet (CWT). De seguida são abordadas a aplicação de técnicas de normalização de dados em relação a fatores ambientais e operacionais (baseados em PCA), aplicação de técnicas de classificação de dados, concretamente as baseadas em análises Outliers e Clusters.

4.3.1 Extração de Indicadores

A determinação da ordem dos modelos AR/ARX foi calculada de acordo com Critério de Informação Akaike (AIC). Foram considerados 113 séries temporais de cenários de base e assim estimado o número de parâmetros AR/ARX. De acordo com os resultados obtidos considerou-se a ordem do modelo como sendo igual a 40. A Figura 4.11 retrata os resultados obtidos de AIC em função da ordem do modelo AR. Verifica-se que apesar de não existir uma zona de patamar claramente assumida, em que os valores num determinado intervalo tomem iguais valores de AIC, o valor de ordem do modelo AR igual a 40 é suficientemente ajustado tendo em conta as pequenas variações dos resultados AIC relativos a ordens superiores ao valor considerado.





Figura 4.11 – Ordem do modelo AR/ARX: baseado em todos os cenários de base.

Os indicadores extraídos pelas diferentes técnicas são avaliados em cada um dos sensores utilizados (48 acelerómetros), constituindo uma matriz X de $n \times m$, em que n é o número das diferentes passagens relativas aos cenários considerados, e m representa o número de coeficientes (indicadores) de cada uma das técnicas. As matrizes dos resultados avaliados em cada um dos sensores são:


- matriz X_{AR} de 143 x 40 – Modelo AR
- matriz X_{ARX} de 143 x 80 – Modelo ARX
- matriz X_{CWT} de 143 x 468 – técnica CWT
- matriz X_{PCA} de 143 x 4 – técnica PCA

em que o valor 143 é relativo ao total de passagens dos cenários considerados, 40 é o número de indicadores AR extraídos a partir das respostas dinâmicas induzidas pelo veículo na via, depois de definido a ordem do modelo AR determinada, 80 é o número de indicadores ARX extraídos uma vez que o parâmetro da parcela das entradas exógenas considerado é 40. Por forma a permitir uma significativa fusão dos dados depois da extração dos coeficientes wavelet (117 valor obtido) a partir das respostas dinâmicas de interação veículo-via, são obtidos os parâmetros estatísticos PCA das pontuações, obtendo-se 468 indicadores CWT resultado da multiplicação dos 4 parâmetros estatísticos (média quadrática, desvio padrão, obliquidade, kurtosis) pelos 117 coeficientes wavelet. Também é aplicada a análise de componentes principais (PCA) aos valores das medições das respostas, sendo feita a normalização das acelerações medidas. De seguida para cada um dos resultados é calculada as pontuações PCA, e posteriormente são aplicados os parâmetros estatísticos sobre as pontuações PCA, resultando em 4 indicadores PCA relacionados com os 4 parâmetros estatísticos considerados na formulação do cálculo (média quadrática, desvio padrão, obliquidade, Kurtosis).

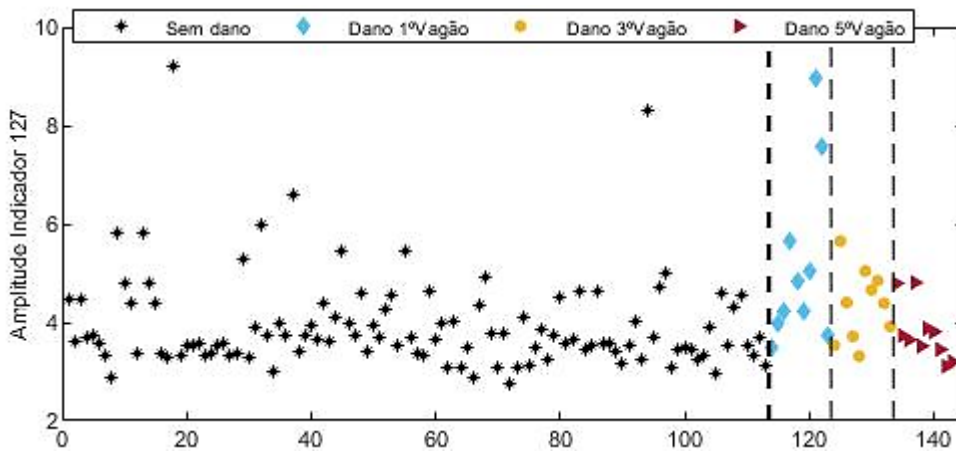
A Figura 4.12 retrata quatro exemplos de indicadores respeitantes a cada uma técnicas acima mencionadas. Os resultados estão divididos em dois grandes grupos, o primeiro é referente a passagens sem dano e o segundo a passagens com dano, sendo este último dividido em três partes, relativo às diferentes localizações do dano nas rodas do veículo. É bem visível, nas técnicas ARX e PCA, uma maior dispersão nos indicadores dos cenários de base (sem dano) comparativamente aos indicadores das passagens dos vagões em cenários de dano, podendo ser indicativo da influência dos efeitos das variações ambientais e operacionais considerados nos cenários de base.




a)



b)



c)




d)

Figura 4.12 – Extração de indicadores para todos os 113 cenários de base e cenários de dano – sensor 1:


- a) método autorregressivo AR, b) método autorregressivo ARX, c) transformadas contínuas wavelet CWT, d) análise de componentes principais PCA.

4.3.2 Modelação de Indicadores – Normalização (ACP)


Numa primeira fase (extração de indicadores) verificou-se a dificuldade em distinguir os indicadores referentes a passagens com e sem dano, não sendo visíveis quaisquer diferenças entre as amplitudes dos dois grupos. Sendo que as variações ambientais e operacionais podem gerar grandes influências nas amplitudes para as passagens dos cenários de base é importante a normalização dos dados relativos aos efeitos ambientais e operacionais, promovendo o realce dos indicadores do lado do dano. Foi adotado o Método das variáveis latentes (PCA) para a normalização dos dados, conforme retratado na Figura 4.1, e implementado com base em todas as técnicas de extração de indicadores abordadas na secção anterior 4.3.1, obtendo-se as mesmas dimensões das matrizes consideradas na extração de dados para cada um dos sensores em cada uma das técnicas. Verifica-se na Figura 4.13, uma condensação dos dados relativo à etapa anterior da metodologia (normalização) do lado das passagens sem dano, sendo claramente notório uma menor dispersão, nomeadamente nos indicadores 22, 20 e 127, relativos às técnicas AR, ARX e CWT, respetivamente.




a)



b)



c)




d)


Figura 4.13 – Normalização de indicadores para todos os 113 cenários de base e cenários de dano – sensor 1: a) método autorregressivo AR, b) método autorregressivo ARX, c) transformadas contínuas wavelet CWT, d) análise de componentes principais PCA.

4.3.3 Fusão de Dados

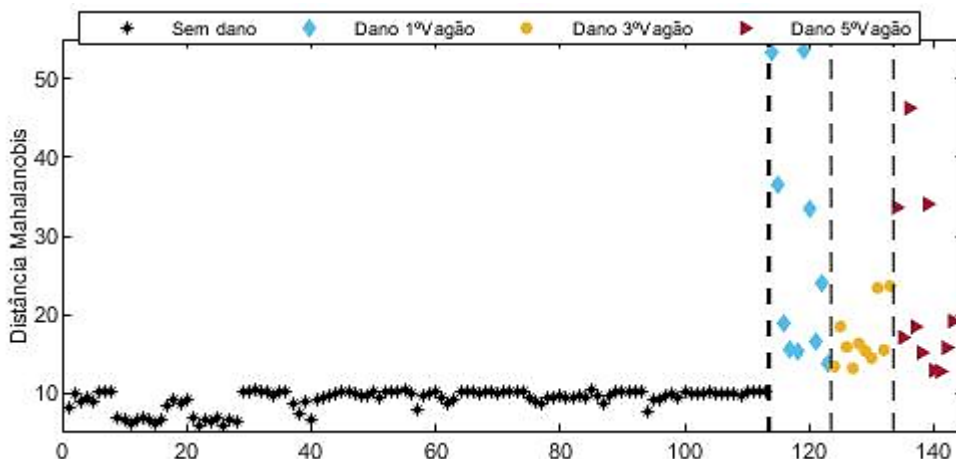
Por forma a fundir todos os parâmetros dos indicadores baseados nas técnicas AR, ARX, CWT e PCA, para cada um dos sensores foi implementada a distância Mahalanobis. A distância Mahalanobis permite converter todos os indicadores num único indicador sensível a dano, para cada passagem de comboio e sensor. O processo de fusão resulta num vetor de 143x1 para cada um dos 48 sensores. A Figura 4.14 demonstra 4 resultados baseados em cada uma das técnicas (AR, ARX, CWT e PCA) relativos ao sensor 12. Observa-se que este processo melhorou significativamente a sensibilidade à deteção do dano, sendo que no caso das fusões baseadas em resultados ARX, CWT e PCA constata-se uma distinção clara entre os diferentes cenários – com e sem dano, evidenciando-se de entre estes os baseados em ARX, conforme retrata a Figura 4.14b.




a)



b)



c)




d)


Figura 4.14 – Fusão de indicadores para todos os 113 cenários de base e cenários de dano – sensor 12:

- a) método autorregressivo AR, b) método autorregressivo ARX, c) transformadas contínuas wavelet CWT, d) análise de componentes principais PCA.


Com o intuito de aumentar ainda mais a sensibilidade ou distinção entre os diferentes cenários, com e sem dano, foi implementada uma nova fusão (2º ordem) do resultado de todos os sensores, culminando num vetor com 143x1 em que estão fundidos todos os indicadores de cada um dos sensores e todos os sensores. Prova-se um aumento na diferença de amplitude entre os diferentes cenários, aumentando em muito a possibilidade de uma eficaz detecção de danos, tal como demonstra a Figura 4.15. Os resultados mais promissores são os baseados em indicadores ARX, CWT e PCA, Figura 4.15b, Figura 4.15c e Figura 4.15d, respetivamente.




a)



b)



c)



d)


Figura 4.15 – Fusão de indicadores e de todos os sensores para os 113 cenários de base e cenários de dano: a) método autorregressivo AR, b) método autorregressivo ARX, c) transformadas contínuas wavelet CWT, d) análise de componentes principais PCA.

4.3.4 Discriminação de Indicadores – Análise de *Outliers*


Apesar das séries temporais e do tratamento de dados acima abordados permitirem visualmente distinguir as amplitudes dos diferentes cenários, na ótica da monitorização remota não supervisionada, as estratégias devem recorrer à aprendizagem de máquina com base em algoritmos capazes de distinguir comportamentos relativos a estados com e sem dano (Meixedo, 2021).

Também é realizada a comparação entre os resultados indicativos de dano baseados nas 4 diferentes técnicas de extração de indicadores considerada (AR, ARX, CWT e PCA), promovendo as melhores combinações de métodos na estratégia de aprendizagem de máquina a fim de ser escolhido aquele que conduz a melhores resultados. A discriminação de indicadores é a última fase no que concerne à deteção automática do dano, sendo proposto a deteção da poligonização nas rodas com base num limite de confiança utilizando a função inversa Gaussiana de uma distribuição cumulativa. O nível de significância foi definido como sendo 1%, tal como normalmente se observa em diversos estudos de Monitorização da Integridade Estrutural para a identificação de danos (Meixedo, 2021).


Conforme é provado pelas diferentes parcelas da Figura 4.16 a deteção de dano foi bem-sucedida em todas as abordagens. Para os resultados baseados em indicadores AR apenas ocorre um caso de má deteção – 1 falso negativo relativo ao dano na roda do 3º vagão. Destacam-se os resultados baseados em indicadores ARX, CWT e PCA, conforme retratado na Figura 4.16b, Figura 4.16c e Figura 4.16d, respetivamente, provando uma maior sensibilidade para a deteção da poligonização nas rodas.




a)



b)



c)



d)

Figura 4.16 – Detecção automática de dano para todos os 113 cenários de base e cenários de dano baseada em indicadores: a) método autorregressivo AR, b) método autorregressivo ARX, c) transformadas contínuas wavelet CWT, d) análise de componentes principais PCA.


4.4 ESTUDO DE EFETIVIDADE PARA DIFERENTES CONFIGURAÇÕES DE SENSORES

Para reduzir os custos de instalação e manutenção, é importante reduzir o número de sensores instalados sem comprometer a qualidade dos resultados. No âmbito do projeto WAY4SAFERAll, no qual insere-se a presente dissertação, a realidade experimental da configuração do sistema de sensores é constituída por sensores instalados consecutivamente a meio vão entre travessas, sendo essa a razão de figurarem apenas sensores a meio vão no dispositivo de configuração virtual. Embora, inicialmente fossem considerados 48 sensores (24 de cada lado da via) as soluções teóricas terão de ser otimizadas em função do contexto real, onde são admitidas soluções que não excedam os 8 sensores de cada lado (16 no total). Por conseguinte, será feito um estudo paramétrico considerando diferentes configurações de sensores. Serão analisadas três diferentes configurações de sensores, 24, 12 e 6 sensores, demonstrando-se para quais a metodologia proposta para detetar a poligonização das rodas do veículo é conseguida.


Pelos resultados obtidos na secção 4.3.4, pode-se concluir que os dados baseados nas técnicas ARX, CWT e PCA são as mais promissoras para o estudo da deteção do dano em configurações minimalistas, sendo então os considerados para o presente estudo paramétrico.

4.4.1 24 sensores


Os resultados demonstrados na Figura 4.17 provam que a deteção de dano para a presente configuração de sensores (24 no total) é conseguida em todas as técnicas que servirão de base para a extração dos indicadores, não existindo casos de falta deteção. Apenas nota-se, na Figura 4.17c, que existe um indicador no limiar da linha de confiança. A amplitude relativa à diferença entre o limite de confiança e os cenários de dano não apresenta grandes diferenças entre as diferentes abordagens. Os resultados baseados na técnica PCA, Figura 4.17c, apresentam uma maior condensação para os indicadores dos grupos referentes ao cenário de dano.



a)



b)




c)

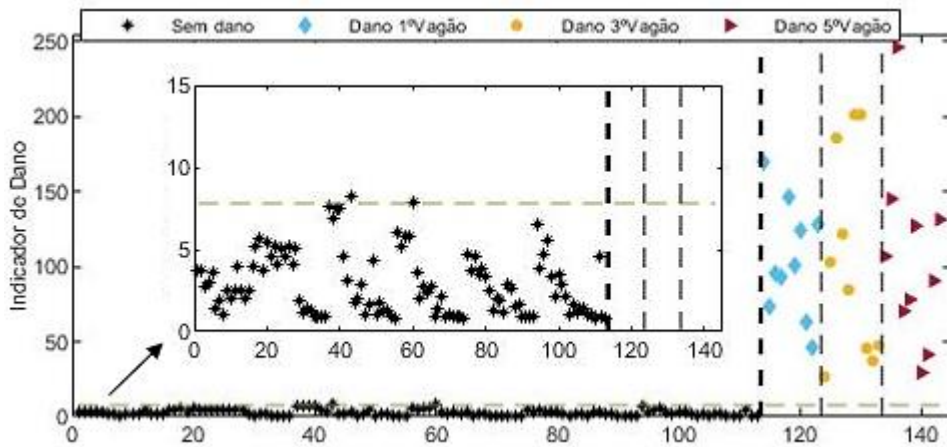
Figura 4.17 – Detecção automática de dano considerando 24 sensores para todos os 113 cenários de base e cenários de dano: a) baseado na técnica ARX; b) baseado na técnica CWT; c) baseado na técnica PCA.

4.4.2 12 sensores


Diminuindo o número de sensores para um total de 12, obtêm-se resultados claramente satisfatórios sendo observado apenas um falso positivo nos resultados baseados nos indicadores ARX e CWT, Figura 4.18a e Figura 4.18b, respetivamente. Constata-se nos resultados baseados em indicadores PCA, Figura 4.18c, dois falsos positivos, aumentando a percentagem de falsa deteção, porém residualmente. Verifica-se existir uma maior condensação para os indicadores dos grupos referentes ao cenário de dano baseados na técnica PCA, Figura 4.18c, e uma maior dispersão nos indicadores de dano CWT, Figura 4.18b. Em suma, tendo em consideração a robustez da linha de referência criada, será expectável que num contexto real a metodologia apresente bons resultados de deteção, apesar da previsível oscilação dos resultados.



a)



b)




c)

Figura 4.18 – Detecção automática de dano considerando 12 sensores para todos os 113 cenários de base e cenários de dano: a) baseado na técnica ARX; b) baseado na técnica CWT; c) baseado na técnica PCA.

4.4.3 6 sensores

A configuração mais reduzida aqui apresentada, demonstra também um sucesso na detecção do dano pela metodologia desenvolvida. Observam-se dois falsos positivos na abordagem baseada em indicadores ARX e um no limiar do limite de confiança, Figura 4.19a. O cenário com maior número de falsas identificações é relativo à abordagem baseada em indicadores PCA, com quatro casos de falsos positivos, Figura 4.19c. Porém, na abordagem baseada em indicadores CWT, Figura 4.19b, não se verifica claramente nenhuma falsa identificação, sendo que existem três indicadores no limiar do limite de confiança. Em todos os casos de todas as abordagens as falsas identificações, ou aqueles sobre o limiar do limite de confiança, ocorrem sempre do lado dos cenários de base, ou seja, trata-se de falsos positivos. A técnica baseada em indicadores CWT conduz a um melhor resultado de detecção do dano, tanto para a presente configuração como para a configuração com doze sensores. Balanceando os custos associados com os resultados obtidos, pode-se concluir que o sistema com doze sensores é mais equilibrado. Foi verificada uma maior distância dos indicadores relativos às passagens sem dano relativamente ao limite de confiança, potencializando uma menor tendência a que ocorra com mais frequência casos de falsos positivos em contexto real. Porém, o peso que se atribui a um falso positivo é muito inferior do que a um falso negativo, pelo facto dos dois tipos de falsas deteções originarem prejuízos bem diferenciados. A metodologia demonstra resultados relativos aos cenários de danos bem distantes da linha representativa do limite de confiança perspetivando-se, em contextos reais de operabilidade, possibilidades reduzidas de ocorrência de falsos negativos.



a)

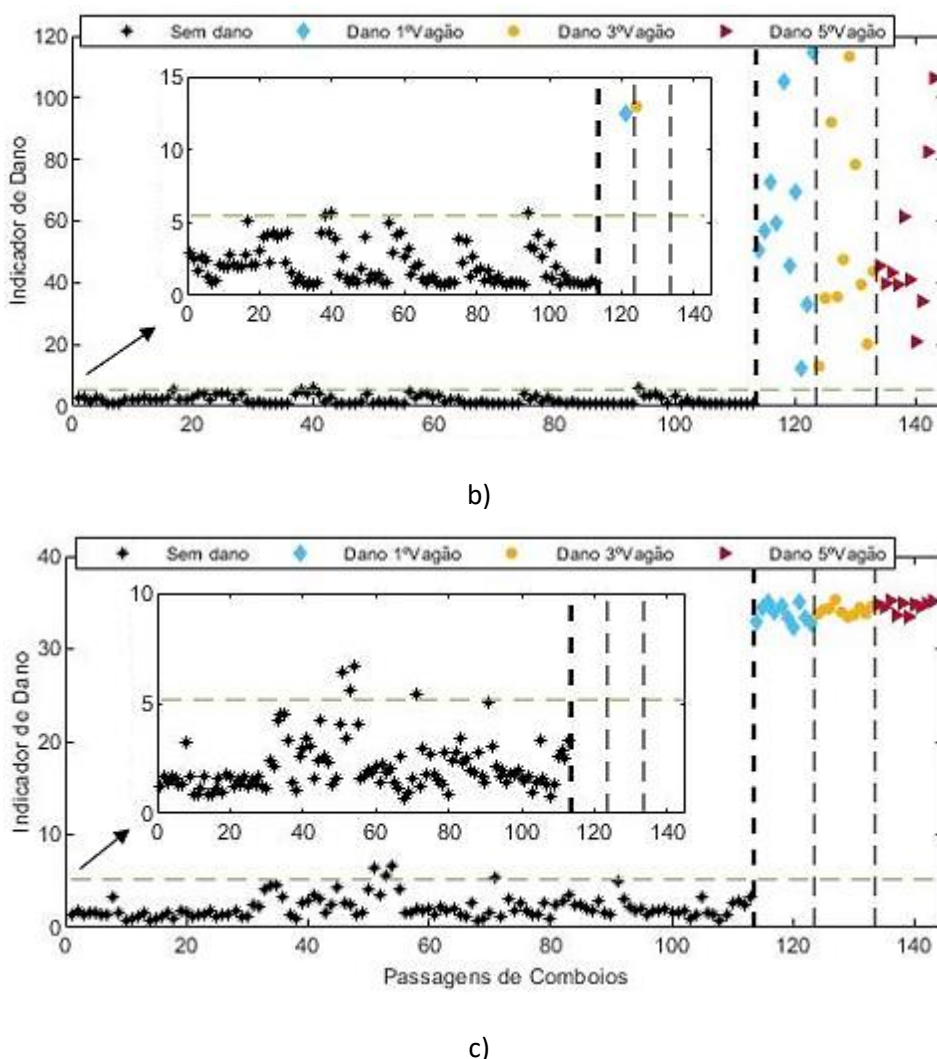


Figura 4.19 – Detecção automática de dano considerando 6 sensores para todos os 113 cenários de base e cenários de dano: a) baseado na técnica ARX; b) baseado na técnica CWT; c) baseado na técnica PCA.

4.5 IDENTIFICAÇÃO DO DANO

A identificação do dano consiste na categorização por níveis de severidade ou magnitude do dano, assim como na localização do dano. No presente trabalho não serão abordadas estratégias de localização do dano, ficando para trabalhos futuros.

A técnica utilizada para a identificação de várias severidades da poligonização nas rodas do veículo ferroviário é baseada em análise de *Clusters*. Os fundamentos teóricos da técnica encontram-se descritos na secção 2.4. A técnica de *Clustering* tem como objetivo dividir os dados de uma forma compacta e separada em diferentes grupos. Neste trabalho foi utilizada a técnica *k-means* para a implementação do *Clustering*, sendo que o propósito desta técnica é o de agrupar os dados em *k* grupos (*Clusters*) com base em distâncias vetoriais, sendo que no presente estudo foi adotado a distância Euclidiana.


Tendo por base os valores dos dados de entrada, indicadores de dano, e um número arbitrário de k grupos (*Clusters*), o algoritmo k -means visa encontrar k centroides cujo as distâncias dos vetores sejam mínimas para o centroide mais próximo, formando um grupo para um determinado conjunto de dados. As quatro etapas principais do processamento do algoritmo são: i) a partir dos dados de entrada gerar aleatoriamente k centroides, ii) extrair vetores de indicadores dos dados de entrada (indicadores de dano), iii) alocar o vetor de cada indicador ao centroide mais próximo, e iv) calcular novos centroides dos grupos (*Clusters*) formados. As etapas iii e iv são repetidas até que sejam consolidados os grupos, isto é, através de um processo de otimização os grupos não sofram quaisquer alterações em iterações seguintes. Conforme abordado na secção 2.4 é necessário *à priori* a definição do número de grupos (*Clusters*) a definir, porém em trabalhos de monitorização de danos é impossível previamente conhecer quais os tipos de danos que ocorrerão e conseqüentemente adotar diferentes grupos para diferentes severidades. De forma a tornar o processo automático alguns índices de validação podem ser utilizados nomeadamente o índice de silhueta global (SIL).

Na presente secção pretende-se desenvolver uma ferramenta de identificação de várias severidades do dano, tendo sido consideradas nas análises diferentes magnitudes de dano poligonal com ordens de harmónicos, entre 4-7, 10-13 e 17-20, ordenados respetivamente por ordem crescente de nível de severidade. A configuração de sensores utilizada foi de 12 sensores.


Foram considerados indicadores de diferentes abordagens (AR, ARX, CWT e PCA) de forma a estudar o desempenho de várias técnicas para a identificação do dano baseada em *Clusters*. A identificação do dano passa pela criação de dois grandes grupos (*Clusters*) relativos aos cenários de base (sem dano) e aos cenários com dano. Pretende-se que dentro do grupo de danos sejam criados diferentes grupos relativos a cada nível de severidade. Os grupos das diferentes severidades estão separados pelas linhas tracejadas dos gráficos sendo o primeiro grupo relativo ao nível de menor severidade e o terceiro grupo o de maior severidade. A Figura 4.20 mostra os resultados obtidos, descartando-se à partida os resultados baseados em indicadores AR e PCA, Figura 4.20a e Figura 4.20d, respetivamente. Os resultados baseados em indicadores AR não apresentam uma clara distinção entre os cenários de base e dano, existindo diversos falsos negativos. Nos resultados baseados em indicadores PCA é estabelecida a distinção entre os cenários de dano e sem dano, porém não é concretizada a separação em grupos distintos relativamente aos diversos níveis de severidade de dano. Os resultados baseados em indicadores ARX e CWT, Figura 4.20b e Figura 4.20c, respetivamente, mostram melhorias na identificação da severidade do dano. Nos dois casos é garantida a distinção entre os indicadores relativos aos cenários de base e com danos, sendo que dentro dos cenários de danos nos resultados baseados em indicadores ARX, apesar de apresentarem diversas falsas identificações, é possível observar uma ligeira tendência na escalação dos grupos em

função do nível de severidade. Os resultados baseados em indicadores CWT também apresentam várias falsas identificações. As amplitudes dos resultados tendem a crescer no terceiro grupo.


Conclui-se assim que a identificação do nível de severidade não é possível. Porém, se for considerado apenas dois grupos de análise, cujo intuito é igualmente a identificação do dano num estágio anterior ao mais severo. No qual o primeiro e segundo grupo representam um nível intermédio de severidade e o terceiro grupo de maior severidade. Os resultados para os indicadores baseados em ARX e CWT, mas sobretudo os baseados em CWT, tendem a agrupar-se nestes dois níveis. Enquadrado nesta premissa, na abordagem baseada em indicadores CWT são evidenciadas seis falsas identificações. Poderá este ser um ponto de partida para futuras análises. De uma forma clara definir dois grandes grupos de severidade para a identificação da poligonização nas rodas dos veículos.




a)



b)



c)



d)

Figura 4.20 – Severidade do dano para todos os 113 cenários de base e cenários de dano na roda do 1º vagão (lado direito): a) baseado na técnica AR; b) baseado na técnica ARX; c) baseado na técnica CWT; d) baseado na técnica PCA.

Com intuito de procurar melhores resultados com os dados adquiridos nas simulações numéricas ao longo do trabalho, foi testada a identificação do nível de severidade baseada em *Clusters* para diferentes configurações de sensores. Os resultados não mostraram melhorias quando considerado o posicionamento de sensores intercalados entre si e em diferentes números. O melhor resultado foi obtido com o posicionamento de 5 sensores no lado esquerdo e 6 sensores no lado direito intercalados entre si e alternando entre diferentes lados, Figura 4.21.




Figura 4.21 – Sistema de monitorização virtual – sensores intercalados.

Na Figura 4.22 demonstra-se o resultado obtido, constata-se que não houve uma melhoria face aos resultados obtidos com configurações de sensores consecutivos. Tendo igualmente em consideração a premissa de se obter bons resultados para a identificação de dois grandes grupos de severidade de dano tal como acima referido. Neste caso observa-se um maior número de falhas de identificação da severidade de dano comparativamente com os resultados obtidos anteriormente – sensores consecutivos e baseando-se em indicadores CWT.




Figura 4.22 – Severidade do dano para todos os 113 cenários de base e cenários de dano na roda do 1º vagão (lado direito) baseado na técnica CWT considerando sensores intercalados: 5 no lado esquerdo e 6 no lado direito.

CAPÍTULO 5

CONCLUSÕES E DESENVOLVIMENTOS FUTUROS

5.1 CONCLUSÕES

A presente tese foca-se no desenvolvimento de uma metodologia de detecção de dano poligonal em rodas de veículos ferroviários de mercadorias, através de um processo contínuo e não supervisionado. O procedimento passa por uma estratégia de aprendizagem de máquina orientada por dados adquiridos e tratados ao longo de todas as etapas que compõem a metodologia. O intuito é dotar uma metodologia de detecção e identificação do dano completamente automática, sem necessidade de intervenção do utilizador.

No Capítulo 2 foi apresentado um estudo sobre os sistemas de monitorização normalmente disponíveis e utilizados no campo da aplicação da segurança ferroviária, dando-se especial destaque para dois grandes grupos, sistemas reativos e preditivos. Foram abordados os principais defeitos nas rodas encontrados na literatura relativamente a imperfeições circulares, nomeadamente lisos nas rodas e poligonização nas rodas. De seguida foi efetuado um levantamento de diversas técnicas de tratamento de dados multivariados, nomeadamente as utilizadas em trabalhos cujo objetivo passa pela detecção de lisos nas rodas cujos resultados evidenciaram-se satisfatórios.

No Capítulo 3 foi descrito o veículo considerado no presente trabalho, o veículo de mercadorias do tipo Laagrss. Foi apresentado o modelo numérico realizado no programa ANSYS® que o representa digitalmente. Uma das particularidades destes vagões é de serem constituídos apenas por um nível de suspensão materializada por uma mola em lâminas de aço que a ligação carroçaria-rodados é estabelecida pela própria suspensão. Foi apresentada a modelação numérica da via, também realizada no programa ANSYS®, foi efetuada a caracterização geométrica das irregularidades da via e das rodas no programa MATLAB® e posteriormente aleatoriamente gerados perfis de irregularidades. Para aquisição de dados de respostas numéricas, foi utilizada a ferramenta de análise e cálculo *VSI-Vehicle-Structure Interaction Analysis*, no qual é descrita de forma sucinta a sua formulação para a resolução do problema de interação dinâmico roda-carril.

No Capítulo 4 é descrita a metodologia de detecção e identificação de dano utilizada. Numa primeira fase são apresentados os valores das respostas numéricas adquiridas pelos modelos descritos no Capítulo 3, é estudado e analisado a influência de determinados parâmetros nas respostas, verificando-se que a velocidade e o tipo de carga são os fatores que mais contribuem para a oscilação da amplitude da resposta. Observa-se ainda a diminuta influência de todos os tipos de severidades de dano poligonal quando comparadas as respostas de rodas com e sem dano, assim como a semelhança entre as respostas de todos os níveis de severidade. Após a aquisição de respostas foi realizado a extração de indicadores sensíveis ao dano poligonal nas rodas. Os resultados baseados em indicadores ARX e PCA apresentam uma maior dispersão quando comparadas as amplitudes entre os cenários de dano e sem dano. De forma a ultrapassar os efeitos das variações ambientais e operacionais procedeu-se à normalização dos dados relativamente a estes efeitos, tendo por base a abordagem PCA. Verificou-se em todas as abordagens uma compactação entre os indicadores relativos a cenários de base. De seguida foi processada a fusão de dados, por forma a diminuir o volume de dados e aumentar a correlação do indicador com o dano em estudo. Demonstrou-se uma clara distinção entre os dois grandes grupos, cenários de base e com dano, sendo os resultados baseados em indicadores ARX aqueles que apresentam uma maior diferenciação entre os dois cenários. A comparação dos resultados baseados em modelos autorregressivos AR e ARX, , permitiu concluir que os modelos ARX conduzem a uma maior sensibilidade de dano devido à sua capacidade de capturar informação cruzada entre os diversos sensores. Para além da fusão de 1ª ordem (entre indicadores) foi realizada uma segunda fase de fusão de dados, considerando todos os sensores. Os resultados baseados em indicadores ARX como seria expectável não obtiveram melhorias face à primeira fase de fusão de dados, devido à característica dos indicadores em que o comportamento num determinado ponto de medição (sensor) é influenciado pelos comportamentos preditivos nos outros pontos de medição (entradas exógenas), porém nesta fase já apresenta um grande resultado bastante satisfatório. No final desta fase concluiu-se que todos os resultados baseados nas diferentes técnicas de extração, com exceção dos modelos ARX, melhoraram substancialmente. Em todas as abordagens foram obtidos bons resultados com destaque para os baseados em modelos ARX, transformadas wavelet CWT e análise de componentes principais PCA.

Ainda neste capítulo foi implementada a detecção automática do dano, tendo-se criado um limite de confiança com base nos valores da linha base de forma automática. Foram considerados os resultados de todas as técnicas de extração de indicadores sensíveis ao dano nesta fase de análise, tendo-se concluído que em todos os resultados apenas 1 falso positivo é identificado relativamente aos resultados baseados em indicadores AR. Todos os indicadores relativos a cenários de dano situaram-se acima do limite de confiança, assim como todos os indicadores relativos a cenários sem dano encontram-se abaixo do limite de confiança. Foi elaborado um estudo de sensibilidade para diferentes configurações de sensores com intuito de otimizar a solução. Três tipos de configurações de sensores consecutivamente instalados a meio

vão entre travessas foram considerados: 24 sensores (12 em ambos os lados), 12 sensores (6 em ambos os lados) e 6 sensores (em ambos os lados). Atendendo aos fatores de eficácia e número de sensores, verifica-se que a solução composta por 12 sensores é a mais equilibrada apresentando apenas 1 falso positivo para a abordagem baseada em indicadores ARX, 1 falso positivo com indicadores CWT e 2 falsos positivos com indicadores PCA. Apesar da solução constituída por 6 sensores apresentar também resultados bastantes satisfatórios, especialmente para os baseados em indicadores ARX e CWT que apresentaram apenas 2 falsos positivos, esta solução mais minimalista apresenta um maior número de indicadores próximos do limite de confiança quando comparada com a solução constituída por 12 sensores. Assim, antevê-se que a solução cujo um número de sensores inferior pode em situações de contexto real promover a um maior número de falsas deteções. Quanto à identificação automática da severidade do dano os resultados não foram satisfatórios, porém são animadores caso se considere a possibilidade de agrupar os tipos de danos em 2 níveis. Os resultados baseados em indicadores AR e PCA não apresentam quaisquer distinções entre os diferentes grupos de danos. Sendo os resultados mais promissores obtidos com base nas abordagens ARX e CWT, onde esta última apresenta os melhores resultados, contando com 6 falsas identificações, se considerados 2 grupos de severidade. Foi ainda efetuada uma análise para diferentes distribuições de sensores intercalados entre si, mas não foram alcançadas melhorias nos resultados.

Conclui-se assim que esta metodologia apresenta bons resultados na deteção do dano, conseguindo ter uma linha bem definida da condição fronteira entre estados com e sem danos nas rodas do veículo. Principalmente com base nas abordagens ARX, CWT e PCA provando-se o bom funcionamento da metodologia para a deteção da poligonização nas rodas. A diferença entre amplitudes dos resultados relativos a cenários de dano e sem dano é considerável, podendo-se esperar um baixo incremento de falsos negativos em contextos reais. Porém, podem evidenciar-se um aumento de falsos positivos em situações reais pelo motivo de existirem *à priori*, neste contexto teórico, um número de indicadores próximos da linha de fronteira, assim como, devido a outras variáveis que naturalmente influenciarão as amplitudes das respostas em contextos reais. Com este trabalho mostrou-se que esta metodologia consegue detetar eficazmente o efeito poligonal nas rodas, tal como verificado em trabalhos anteriores no estudo de deteção de lisos nas rodas. A metodologia provou-se eficaz considerando amplitudes de desgaste bastante reduzidas. Foi dado um contributo no sentido de tornar esta metodologia mais robusta tendo em consideração diferentes danos relacionados com imperfeições nas rodas, como para o melhoramento da tecnologia para outros danos ainda não experimentados. A identificação do nível de severidade não foi atingida por completo no presente trabalho, a inclusão de dados com diferentes características, nomeadamente os relativos a deformações, pode promover uma melhoria nesta fase da metodologia. Será interessante também avaliar se para o presente caso de dano nas rodas –

poligonização, não é vantajoso considerar dois níveis de severidade claramente bem definidos cujo intuito seria a possibilidade de deteção deste tipo de dano numa fase anterior à mais severa.

5.2 DESENVOLVIMENTOS FUTUROS

Os trabalhos futuros que podem ser desenvolvidos, tendo por base este trabalho com o objetivo de ser alcançado um conhecimento aprofundado, limitações e possíveis aplicações da metodologia na ótica de um contexto prático são:

- Realização de campanhas experimentais por forma a testar o funcionamento da metodologia em contextos reais de operação;
- Inclusão de dados com diferentes características, tais como relativos a deformações nos pontos de controlo – funcionamento da metodologia com dados heterogéneos (acelerações e extensões), pode promover um melhoramento da sensibilidade ao dano entre diferentes níveis de severidade conduzindo a uma melhor identificação;
- Realizar simulações numéricas com modelos de desgaste das rodas mais acentuados;
- Dotar a metodologia com capacidades de localizar o dano. No presente trabalho foi considerado danos em rodas de diferentes vagões nas análises, porém não se obteve qualquer indicação correlacionada com a posição do dano. Possivelmente a solução para a localização do dano passará por implementar ferramentas cuja extração de informação esteja relacionada com fatores espaciais ou temporais, por exemplo, métodos baseados em modelos ocultos de Markov. No qual é possível contar as passagens de cada eixo do veículo e identificar variações comportamentais pela análise das oscilações das respostas em cada uma dessas passagens, comparando a amplitude das respostas atuais com valores teóricos expectáveis em passagens sem dano.

REFERÊNCIAS BIBLIOGRÁFICAS

Addison PS. - Introduction to redundancy rules: the continuous wavelet transform comes of age. Phil. Trans. R. Soc.; 2018, A 376: 20170258 <http://dx.doi.org/10.1098/rsta.2017.0258>.

Alvandi, A., Cremona, C. - Assessment of vibration-based damage identification techniques. J Sound Vib 2006;292(1-2):179–202. <https://doi.org/10.1016/j.jsv.2005.07.036>.

Alves, V., Meixedo, A., Ribeiro, D., Calçada, R., Cury, A. - Evaluation of the performance of different damage indicators in railway bridges. Procedia Eng 2015; 114:746–53. <https://doi.org/10.1016/j.proeng.2015.08.020>.

Amini, Arash, Mani Entezami, Mayorkinos Papaelias - Onboard detection of railway axle bearing defects using envelope analysis of high frequency acoustic emission signals. In: Case Studies in Noderstructive Testing and Evaluation; 2016, 6 pp. 8-16. Issn: 22146571. doi: 10.1016/j.csndt.2016.06.002.

ANSYS®, 2018. Academic Research, Release, 19.2. ANSYS Inc., Canonsburg, PA, USA.

Barke, D., Chiu, W. K. - Structural Health monitoring in the railway industry: A review. Structural Health Monitoring; 2005 Vol. 4. pp. 81-93, Journal, Electronic access: <http://shm.sagepub.com>.

Blair, J., Barke, D. - MRX Technologies – Wayside Detection Systems, Perth, 2003.

REFERÊNCIAS BIBLIOGRÁFICAS

Bouzenad, A.E., Mountassir, M.E., Yaacoubi, S., Dahmene, F., Koabaz, M., Buchheit, L., Ke, W. - A Semi-Supervised Based K-Means Algorithm for Optimal Guided Waves Structural Health Monitoring: A Case Study; 2019, 4, 17; doi:10.3390/inventions4010017.

Bragança, C., Neto, J., Pinto, N., Montenegro, P.A., Ribeiro, D., Carvalho, H., Calçada, R. - Calibration and validation of a freight wagon dynamic model in operating conditions based on limited experimental data, Vehicle System Dynamics; 2021, DOI: 10.1080/00423114.2021.1933091.

Cavadas, F., Smith, I. F. C., Figueiras, J. - Damage detection using data-driven methods 157 applied to moving-load responses. Mechanical Systems and Signal Processing, 39(1–2), 409– 425; 2013, <https://doi.org/10.1016/j.ymssp.2013.02.019>.

Chong, S.Y., Lee, J., Shin, H. - A review of health and operation monitoring technologies for trains. Smart Structures and Systems, 6(9):1079–1105, dezembro de 2010.

Componentes das forças de contacto roda-carril: <https://www.youtube.com/watch?v=KxU3tJDItxw>, acessado em abril de 2022.

Detetor de equipamento de arrasto constituído por acelerómetros, www.voestalpine.com, acessado em abril de 2022.

Detetor de Perfil da Roda, www.wabteccorp.com, acessado em abril de 2022.

Directiva 2004/49/CE do Parlamento Europeu e do Conselho de 29 de abril de 2004, relativa à segurança dos caminhos-de-ferro da Comunidade.

EN 13674-1:2002 - “Track – Rail - Part 1: Vignole railway rails 46 kg/m and above”; European Committee for Standardization (CEN), Brussels, 2002.

EN 15313:2016 – “Railway applications - In-service wheelset operation requirements - In-service and off-vehicle wheelset maintenance”; European Committee for Standardization (CEN), Brussels, Belgium, 2015.

EN 13848-2:2006 – “Railway applications - Track - Track geometry quality - Part 2: Measuring systems - Track recording vehicles”; European Committee for Standardization (CEN), Brussels, 2006.

NP EN 13848-5:2008+A12015 – “Via – Qualidade da geometria da via – Parte 5: Níveis de qualidade da geometria da via – Plena via” Edição 2015-07-15, Instituto Português da Qualidade.

Farrar, C., Worden, K. - A machine learning perspective. Wiley. Structural Health Monitoring; 2013.

Figueiredo, E., Park, G., Farrar, C. R., Worden, K., Figueiras, J. - Machine learning algorithms for damage detection under operational and environmental variability. Structural Health Monitoring, 10(6), 559–572;2010, <https://doi.org/10.1177/1475921710388971>.

GCU - General Contract of Use for Wagons, Janeiro de 2021.

Gonzalez, I., Karoumi, R. - BWIM aided damage detection in bridges using machine learning. Journal of Civil Structural Health Monitoring; 2015, 5(5), 715–725. <https://doi.org/10.1007/s13349-015-0137-4>.

Sistema de deteção da temperatura nos rolamentos e rodas: www.revistaitransporte.com, acessido em março de 2022.

Lagnebäck, R. - Evaluation of wayside condition monitoring technologies for condition-based maintenance of railway vehicles, Licenciante Thesis, Luleå University of Technology, 2007.

Li, D., Dai, H., Jia, X., He, B. - Out-of-round of subway wheel caused by rail flexibility. In: Proceedings of 11th international conference on contact mechanics and wear of rail/wheel system (CM2018), Delf, the Netherlands, 24–27 September 2018, pp 529–535; 2018.

REFERÊNCIAS BIBLIOGRÁFICAS

Liu, X., Zhai, W. - Analysis of vertical dynamic wheel /rail interaction caused by polygonal wheels on high-speed trains; 2013.

MATLAB®, 2018. Release R2018a. The MathWorks Inc., Natick, MA, USA.

Meixedo, A., Alves, V., Ribeiro, D., Cury, A., Calçada, R. - Damage identification of a railway bridge based on genetic algorithms. In: Maintenance, Monitoring, Safety, Risk and Resilience of Bridges and Bridge Networks - Proceedings of the 8th International Conference on Bridge Maintenance, Safety and Management, IABMAS 2016, pp. 998-1005, ISBN: 978-113802851-7.

Meixedo, A.G. - Damage Identification in Railway Bridges Based on Train Induced Dynamic Responses, Dissertation for the degree of Doctor of Philosophy in Civil Engineering, FEUP, Porto, 2021.

Meixedo A., Santos J., Ribeiro D., Calçada R., Todd M. - Damage detection in railway bridges using traffic-induced dynamic responses. *Engineering Structures*, 2021. 238: 112189, doi: 10.1016/j.engstruct.2021.112189.

Meixedo A., Santos J., Ribeiro D., Calçada R., Todd M. - Online unsupervised detection of structural changes using train-induced dynamic responses. *Mechanical Systems and Signal Processing*, 2022. 165: 108268, doi: 10.1016/j.ymssp.2021.108268.

Montenegro, P.A., Neves, S.G.M., Calçada, R., Tanabe, M., Sogabe, M. - Wheel-rail contact formulation for analyzing the lateral train-structure dynamic interaction. *Computers & Structures*, 2015. 152: 200-214.

Montenegro, P.A., Heleno, R., Carvalho, H., Calçada, R., Baker, C.J. - A comparative study on the running safety of trains subjected to crosswinds simulated with different wind models, *Journal of Wind Engineering, and Industrial Aerodynamics*; 2020; 207: 104398. DOI: 10.1016/j.jweia.2020.104398.

Mosleh A., Costa, P., Calçada, R. - A new strategy to estimate static loads for the dynamic weighing in motion of railway vehicles. *Proceedings of the Institution of Mechanical Engineers*; 2019, doi: 10.1177/0954409719838115.

Mosleh, A., Montenegro, P.A., Costa, P., Calçada, R. - An approach for wheel flat detection of railway train wheels using envelope spectrum analysis. *Structure and Infrastructure Engineering*; 2020: 1-20, doi: 10.1080/15732479.2020.1832536.

Mosleh, A., Montenegro P., Costa P., Caçada, R. - Railway Vehicle Wheel Flat Detection with Multiple Records Using Spectral Kurtosis Analysis, *Applied Sciences* 2021; 11 (9): 4002. DOI:10.3390/app11094002.

Mosleh, A., Meixedo, A., Ribeiro, D., Montenegro, P., Caçada, R. - Early wheel flat detection: an automatic data-driven wavelet-based approach for railways; 2022, *Constuct – Lese*, Faculty of Engineering, University of Porto and School of Engineering, Polytechnic of Porto, Portugal.

Ngigi, R. W. et al. (2012) - Modern techniques for condition monitoring of railway vehicle dynamics. In: 364, p. 012016. doi: 10. 1088 / 1742 - 6596 / 364 / 1 / 012016. url: <https://doi.org/10.1088/1742-6596/364/1/012016>.

Neto, J.A.D. - On-board track condition monitoring system based on inverse dynamic models, *Research Project Thesis, Civil Engineering Doctoral Program, FEUP, Porto, 2021*.

Neves, S.; Azevedo, A. F. M.; Calçada, R. - A direct method for analyzing the vertical vehicle–structure interaction. *Engineering Structures*; 34(2014):414–420.

Neves, A.C., González, I., Leander, J., Karoumi, R. - Structural health monitoring of bridges: a model-free ANN-based approach to damage detection. *Journal of Civil Structural Health Monitoring*, (7);2017, 689–702. <https://doi.org/10.1007/s13349-017-0252-5>.

REFERÊNCIAS BIBLIOGRÁFICAS

Nie, Z., Guo, E., Li, J., Hao, H., Ma, H., Jiang, H. - Bridge condition monitoring using fixed moving principal component analysis. *Structural Control and Health Monitoring*; fevereiro de 2020, 1–29. <https://doi.org/10.1002/stc.2535>.

Nielsen, J.C.O., Johansson, A. - Railway wheel out-of-roundness – Influence of wheel-rail contact forces and track response. In: 13th International Wheelset Conference, Rome, 2001.

Nielsen, J.C.O., Johansson, A. - Out-of-round railway wheels-a literature survey. *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, 214(2):79–91, janeiro de 2000.

Ouyang, Y., Li, X., Barkan, C.P.L, Kawprasert, A., Lai, Y. - Optimal Locations of Railroad Wayside Defect Detection Installations; Department of Civil Engineering, National Taiwan University, Taipei, Taiwan, 2009.

Papaelias, Mayorkinos et al. (2014a) - Advanced wayside condition monitoring of rolling stock wheelsets, In: Prague, Czech Republic, p. 13.

Papaelias, Mayorkinos et al. (2014b) - Online condition monitoring of rolling stock wheels and axle bearings. In: *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit* 230.3, pp. 709–723. issn: 0954-4097, 2041-3017. doi: 10.1177/0954409714559758. url: <http://journals.sagepub.com/doi/10.1177/0954409714559758>.

Peng, B. - Mechanisms of Railway Wheel Polygonization. Doctoral thesis, University of Huddersfield; University of Huddersfield, 2020, <http://eprints.hud.ac.uk/id/eprint/35359/>.

Randall, R. – “Vibration-based condition monitoring.” John Wiley & Sons, Ltd. ISBN: 978-0-470-74785-8, India, 2011.

Ribeiro N., Vale C., Costa P., et al. - Estimativa dos parâmetros de rigidez e de amortecimento para modelos simplificados de vias-férreas não balastradas. In: Congresso de métodos numéricos em engenharia, Coimbra, Portugal, 2011.

Tarawneh, Constantine et al. (2019) - An investigation into wayside hot-box detector efficacy and optimization. In: International Journal of Rail Transportation 8.3, pp. 264– 284. issn: 2324-8378 2324-8386. doi: 10.1080/23248378.2019.1636721.

Tao, G., Wang, L., Wen, Z., Guan, Q., Jin, X. - Measurement and assessment of out-of-round electric locomotive wheels. Proc Inst Mech Eng Part F J Rail Rapid Transit 232(1):275–287; 2018.

Tao, G., Wen, Z., Liang, X., Ren, D., Jin, X. - An investigation into the mechanism of the out-of-round wheels of metro train and its mitigation measures. Veh Syst Dyn 57(1):1–16; 2019.

Tao, G., Wen, Z., Jin, X., Yang, X. - Polygonisation of railway wheels: a critical review; 2020, September, Rail. Eng. Science (2020) 28(4):317–345 <https://doi.org/10.1007/s40534-020-00222-x>; University, Chengdu 610031, China.

Vale, C. - Wheel Flats in the Dynamic Behavior of Ballasted and Slab Railway Tracks. Appl. Sci.; 2021, 11, 7127. <https://doi.org/10.3390/app11157127>.

Yan, A., Kerschen, G., De, B.P., Golival, J. - Structural damage diagnosis under varying environmental conditions - Part I: a linear analysis. Mech Syst Sig Process 2005; 19:847–64. <https://doi.org/10.1016/j.ymsp.2004.12.002>.

Yang, X., Li W, Tao, G., Wen, Z. - The mechanism of highorder polygonal wear of metro train wheels. In: Klomp M, Bruzelius F, Nielsen J, Hillemyr A (eds) Advances in dynamics of vehicles on roads and tracks. IAVSD 2019. Lecture notes in mechanical engineering. Springer, Cham; 2020.

REFERÊNCIAS BIBLIOGRÁFICAS

Wu, X., Chi, M. - Study on stress states of a wheelset axle due to a defective wheel; Junho de 2016, DOI 10.1007/s12206-016-1003-y.

Wu, T.X., Thompson, D.J. - A Hybrid Model for Wheel/Track Dynamic Interaction and Noise Generation due to Wheel Flats; ISVR Technical Memorandum, no. 859; University of Southampton: Southampton, UK, 2001.