

# IDENTIFICAÇÃO DE DANOS NAS RODAS DE VEÍCULOS FERROVIÁRIOS COM BASE NA RESPOSTA DINÂMICA DO SISTEMA VEÍCULO-VIA E INTELIGÊNCIA ARTIFICIAL

**JORGE RUI BARROSO MAGALHÃES**

novembro de 2023

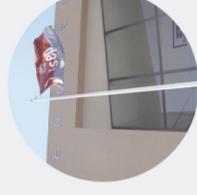
**isep**

INSTITUTO SUPERIOR DE ENGENHARIA DO PORTO  
MESTRADO EM ENGENHARIA CIVIL

INSTITUTO SUPERIOR DE  
ENGENHARIA DO PORTO



isep



IDENTIFICAÇÃO DE DANOS NAS RODAS DE VEÍCULOS FERROVIÁRIOS COM  
BASE NA RESPOSTA DINÂMICA DO SISTEMA VEÍCULO-VIA E INTELIGÊNCIA ARTIFICIAL

# IDENTIFICAÇÃO DE DANOS NAS RODAS DE VEÍCULOS FERROVIÁRIOS COM BASE NA RESPOSTA DINÂMICA DO SISTEMA VEÍCULO- VIA E INTELIGÊNCIA ARTIFICIAL

**isep** Instituto Superior de  
Engenharia do Porto

JORGE RUI BARROSO MAGALHÃES  
Outubro de 2023

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

JORGE RUI BARROSO MAGALHÃES  
Outubro de 2023  
POLITÉCNICO  
DO PORTO



**IDENTIFICAÇÃO DE DANOS NAS RODAS DE VEÍCULOS FERROVIÁRIOS COM  
BASE NA RESPOSTA DINÂMICA DO SISTEMA VEÍCULO-VIA E INTELIGÊNCIA  
ARTIFICIAL**

JORGE RUI BARROSO MAGALHÃES

Dissertação/Projeto submetida(o) para satisfação parcial dos requisitos do grau de

**MESTRE EM ENGENHARIA CIVIL – RAMO DE ESTRUTURAS**

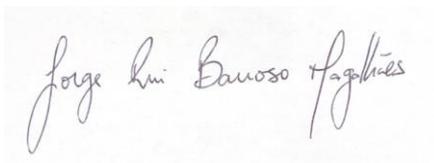
Orientador: Diogo Rodrigo Ribeiro (ISEP)

Coorientadoras: Cecília Vale (FEUP) e Araliya Mosleh (FEUP)

**OUTUBRO DE 2023**

Eu, Jorge Rui Barroso Magalhães estudante nº 1180553, 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 “Identificação de danos nas rodas de veículos ferroviários com base na resposta dinâmica do sistema veículo-via e inteligência artificial” 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, 2023/10/18

A handwritten signature in black ink on a light-colored background. The signature reads "Jorge Rui Barroso Magalhães" in a cursive script.

*“Things that seem hopelessly random and unpredictable when viewed in isolation often turn out to be lawful and predictable when viewed in aggregate.”*

(In “The Joy Of X: A Guided Tour of Math, from One to Infinity”,  
Steven H. Strogatz)



# ÍNDICE GERAL

Índice Geral .....	v
Resumo.....	vii
Abstract .....	ix
Agradecimentos .....	xi
Índice de Texto .....	xiii
Índice de Figuras.....	xv
Índice de Tabelas.....	xix
CAPÍTULO 1    Introdução.....	1
CAPÍTULO 2    Estado da arte .....	7
CAPÍTULO 3    Modelação numérica .....	43
CAPÍTULO 4    Metodologia de identificação de dano .....	53
CAPÍTULO 5    Campanha experimental.....	73
CAPÍTULO 6    Considerações Finais.....	83
Referências Bibliográficas .....	89



## RESUMO

A presente dissertação foca-se no desenvolvimento e aplicação de uma estratégia híbrida de técnicas de Inteligência Artificial (IA) para detetar rodas com defeitos de circularidade no comboio ferroviário de passageiros Alfa pendular. Este algoritmo é alimentado a partir das respostas dinâmicas adquiridas por um sistema de monitorização *wayside* composto por um conjunto de acelerómetros instalados nos carris da via-férrea.

O método foi desenvolvido com o auxílio de diversas simulações numéricas 3D relativas a passagens ferroviárias, permitindo extrair a resposta dinâmica do sistema veículo-via. As simulações numéricas abrangem duas possibilidades de circulação: condições normais (cenários de base) e condições anormais (cenários de dano). Os dois tipos de cenários incluem condições de operação ferroviária variável, nomeadamente, diferentes perfis de irregularidade e ruído no sistema de medição. Relativamente aos cenários de dano, foram considerados dois tipos de defeitos geométricos possíveis de serem modelados, um referente à presença de lisos na superfície de rolamento e outro caracterizado por um desgaste ondulatório periódico ao longo do perímetro da roda, denominado de poligonização.

A metodologia desenvolvida inclui um processo de treino com o auxílio de uma rede neuronal artificial, designada por Autoencoder Esparso, de forma a serem extraídos indicadores de dano. Os dados de entrada para este Autoencoder compreendem as respostas dinâmicas da via adquiridas numericamente. A sensibilidade do indicador de dano é incrementada através da aplicação da distância Mahalanobis. Posteriormente, é aplicada uma análise de outliers, para detetar os danos previamente simulados, e uma técnica de clusters para classificação do dano em duas fases: i) identificação do tipo de dano; ii) identificação da severidade de cada tipo de dano.

Por fim, a metodologia desenvolvida é sujeita a uma validação com base num conjunto de respostas dinâmicas adquiridas experimentalmente.

**Palavras-chave:** Sistema de monitorização *wayside*; rodas defeituosas; comboio Alfa pendular; Autoencoder Esparso; indicador de dano; análise de outliers; análise de clusters.



## ABSTRACT

This dissertation is focused on developing and applying a hybrid strategy of Artificial Intelligence (AI) techniques to detect out-of-roundness (OOR) wheels on the Alfa pendular train. This algorithm is supplied with dynamic response data obtained through a wayside monitoring system comprising a set of accelerometers installed on the railway tracks.

The method was developed with several 3D numerical simulations of railway passages, allowing the dynamic response of the vehicle-track system to be extracted. The numerical simulations cover two circulation possibilities: i) normal conditions (baseline scenarios) and ii) abnormal conditions (damage scenarios). Both scenarios are characterized by a set of traffic variabilities, as well as the presence of irregularity profiles and noise. Regarding the damage scenarios, two types of geometric defects were considered, one referring to the presence of defect on the wheel tread and a defect around the complete wheel circumference called polygonization.

The core of the methodology developed includes a training process with the aid of an artificial neural network, called the Sparse Autoencoder, to extract the damage index. The input data for this Autoencoder comprises the dynamic track responses acquired numerically. The damage index obtained is increased by applying the Mahalanobis distance. Consequently, an outlier analysis is applied to detect previously simulated damage and a cluster technique is used to classify damage in two phases: i) identifying the type of damage (e.g. wheel flat or polygonal wheel) and ii) identifying the severity of each type of damage.

Finally, the methodology developed is subject to validation based on a sample of dynamic responses acquired experimentally.

**Keywords:** Wayside condition monitoring; Out of roundness wheel damage; passenger train Alfa pendular; Sparse Autoencoder; damage index; outlier analysis; cluster analysis.



## **AGRADECIMENTOS**

Ao concluir este trabalho, gostaria de deixar o meu sincero agradecimento a todas as pessoas que contribuíram para a sua concretização, nomeadamente:

Ao Professor Diogo Ribeiro, orientador da dissertação, agradeço-lhe todos os conhecimentos transmitidos ao longo deste último ano, que muito contribuíram para o meu crescimento em termos científicos. O estímulo para assumir caminhos mais desafiantes, as palavras de incentivo e os conselhos nos momentos mais difíceis foram determinantes para a elaboração da dissertação;

À Professora Cecília Vale e à Doutora Araliya Mosleh, coorientadoras da dissertação, pelo auxílio ao longo de todo o trabalho, especialmente na transmissão de conhecimentos técnicos e orientação nas diversas fases do trabalho;

Aos meus colegas do ISEP e membros do grupo de investigação WAY4SAFERAIL, Rúben Silva, António Guedes e Tomás Jorge, pela amizade e incentivo demonstrados durante este período. A troca de ideias contínua, o trabalho em equipa e a entreaajuda desenvolvida proporcionaram um excelente ambiente de trabalho com o principal foco de realizar as tarefas exigidas no projeto;

A todos os restantes membros do grupo de investigação, pelas trocas de ideias e de ferramentas computacionais, assim como todos os conhecimentos transmitidos no decurso do trabalho, nomeadamente: Doutora Andreia Meixedo, Doutor Pedro Montenegro, Professora Lurdes Simões e Mohammadreza Mohammadi;

Aos meus amigos Rui Ribeiro, Joel Reis e Sandro Sousa por todo o apoio e força transmitida nesta fase final do mestrado;

À minha amiga, companheira e namorada, Maria Inês Garcia, por todo o apoio, conselhos e motivação durante a minha formação académica. Agradeço-lhe profundamente por todos os momentos de apoio durante a elaboração da dissertação;

Aos meus avós, Jorge Magalhães e Judite Augusta, e aos meus pais, Jorge Magalhães e Eduarda Barroso, por todo o apoio e carinho, valores e ideais transmitidos, todas as conversas, conselhos e desabafos que me permitiram alcançar vários objetivos ao longo da minha vida.



## ÍNDICE DE TEXTO

1.1	Considerações iniciais .....	1
1.2	Objetivos do trabalho .....	4
1.3	Organização da dissertação .....	5
2.1	Considerações iniciais .....	7
2.2	Sistemas de deteção de danos .....	7
2.3	Análise dinâmica do sistema veículo-via .....	9
2.3.1	O veículo .....	9
2.3.2	A via .....	12
2.3.3	Interação dinâmica veículo-via.....	14
2.4	Defeitos geométricos nas rodas dos veículos ferroviários .....	17
2.4.1	Desgaste superficial liso .....	19
2.4.2	Desgaste poligonal.....	23
2.5	Metodologias de deteção de danos .....	27
2.5.1	Considerações iniciais.....	28
2.5.2	Técnicas aplicadas .....	29
2.5.3	Metodologias desenvolvidas na literatura .....	40
3.1	Modelação de um veículo do comboio Alfa pendular .....	43
3.2	Modelação da via.....	47
3.3	Modelação das irregularidades nas rodas .....	48
3.3.1	Lisos .....	49
3.3.2	Poligonização.....	49
3.4	Interação dinâmica .....	51

4.1	Cenários simulados .....	54
4.2	Procedimento da metodologia .....	54
4.2.1	Aquisição das respostas dinâmicas.....	55
4.2.2	Aplicação de um Autoencoder Esparso .....	59
4.2.3	Indicador de dano .....	62
4.2.4	Fusão dos dados .....	66
4.2.5	Deteção do dano.....	67
4.2.6	Classificação do dano.....	68
5.1	Composição do Sistema de Monitorização.....	73
5.1.1	Acelerómetros .....	73
5.1.2	Extensómetros.....	74
5.1.3	Arquitetura do sistema.....	76
5.2	Respostas experimentais .....	77
5.3	Aplicação da metodologia.....	79
6.1	Conclusões .....	83
6.2	Desenvolvimentos futuros.....	86
6.3	Publicações.....	87
6.3.1	Artigos em conferências nacionais .....	87
6.3.2	Artigos em revistas internacionais.....	87

## ÍNDICE DE FIGURAS

Figura 1-1- Comboio de alta velocidade: a) Eurostar; b) Intercity Express; c) Alfa pendular; d) TGV; e) Nozomi (Shinkansen); f) Fuxing Hao (fonte: Railway Technology, 2023). .....	2
Figura 1-2 - Enquadramento do tema. ....	4
Figura 2-1 – Tipos de sistemas de monitorização: a) Sistema <i>on-board</i> (Ye et al., 2023); b) Sistema <i>wayside</i> (Avsievich et al, 2023). ....	8
Figura 2-2 - Tipologia de veículos ferroviários de passageiros da rede ferroviária portuguesa: a) veículo convencional Alfa pendular (CP 4000); b) veículo suburbano (CP 3400) (adaptado de Vale (2010) e Silva (2018)). ....	10
Figura 2-3 - Modelo dinâmico de um veículo do comboio Alfa-Pendular (adaptado de Mosleh et al., 2021a): a) perspetiva transversal; b) perspetiva longitudinal .....	12
Figura 2-4 - Modelo da via: a) modelo dinâmico, b) modelo numérico em elementos finitos (adaptado de Mosleh et al., 2023) .....	13
Figura 2-5 – Danos nas rodas dos comboios: a) Acumulação de metal; b) Cavidade; c) Reentrância do piso; d) Fragmentação; e) Danos no chanfro; f) Defeito profundo no piso (EN 15313, 2016). ....	18
Figura 2-6 - Formas de rodas com falta de arredondamento: a) presença de lisos; b) imperfeição geométrica regular (periódica); c) imperfeição geométrica irregular (não periódica) (Staśkiewicz et. al., 2018). ....	19
Figura 2-7 - Exemplos de rodas com lisos (EN 15313, 2016). ....	20
Figura 2-8 - Relações entre a velocidade e a força de impacto dinâmica induzida por diferentes características geométricas de lisos (Chang, C. et al., 2022). ....	21
Figura 2-9 - Irregularidade do carril referente a um liso nas rodas. ....	22
Figura 2-10 - Defeito periódico com uma amplitude de pico igual a 0.44 mm (1) e defeito não periódico com uma amplitude de pico igual a 0.35 mm: (2): (a) gráfico em coordenadas polares; (b) distribuição harmónica (Liu e Zhai, 2014). ....	24

Figura 2-11 – Resultados experimentais de desgaste poligonal: (a) roda esquerda; (b) roda direita (Wu et al., 2022).....	25
Figura 2-12 – Imperfeições circulares: excentricidade radial ( $\Delta r$ ), (Müller et al., 2013).....	26
Figura 2-13 - Arquitetura de uma rede neuronal tradicional (adaptado de MATLAB, 2018) .....	29
Figura 2-14 – Modelo não linear de um neurónio artificial (adaptado de Haykin, 1999).....	31
Figura 2-15 – Arquitetura geral de um autoencoder (MATLAB®, 2018) .....	32
Figura 2-16 – Aplicação da técnica de <i>clustering</i> com o algoritmo <i>k-means</i> (Akhter e Mohanty ,2023): a) conjunto de dados S1 com k=3 <i>clusters</i> ; b) conjunto de dados S2 com k=4 <i>clusters</i> ; c) conjunto de dados S3 com k= 3 <i>clusters</i> ; d) conjunto de dados S4 com k=4 <i>clusters</i> .....	40
Figura 2-17 - Fluxograma da metodologia desenvolvida por Meixedo (2021) (adaptado de Meixedo, 2021). .....	41
Figura 3-1 - Comboio Alfa Pendular 4000 (Fonte: Silva, 2018).....	43
Figura 3-2 - Geometria do veículo BBN: a) perspetiva longitudinal; b) perspetiva transversal .....	44
Figura 3-3 - Modelo numérico em elementos finitos do veículo BBN (Saramago et al. (2022)).....	46
Figura 3-4 - Irregularidades de via (L- lateral; V- vertical). .....	48
Figura 3-5 - Localização do tipo de dano. ....	49
Figura 3-6 – Características dos lisos modelados. ....	49
Figura 3-7 – Características do efeito poligonal modelado: a) medições experimentais do espectro de irregularidade; b) exemplo de um perfil de irregularidade da roda para uma amplitude de defeito A1; c) exemplo de um perfil de irregularidade da roda para uma amplitude de defeito A2.....	50
Figura 3-8: Modelo de interação dinâmica veículo-via .....	51
Figura 4-1- Fluxograma da metodologia de identificação de dano.....	55
Figura 4-2 - Esquema de monitorização: a) vista transversal; b) vista de topo. ....	56
Figura 4-3 – Respostas de acelerações medidas no acelerómetro 1 para diferentes condições de base: a) tipos de carregamento; b) irregularidades da vida; c) velocidade de circulação. ....	57
Figura 4-4 – Respostas de acelerações dos diferentes cenários de lisos nas rodas, medidas na posição 1 para: a) 120 km/h; b) 200 km/h. ....	58
Figura 4-5 - Respostas de acelerações dos diferentes cenários rodas poligonais, medidas na posição 1 para: a) 120 km/h; b) 200 km/h. ....	59

Figura 4-6 - Respostas de acelerações usadas para teste medidas no primeiro par de sensores: a) sem dano; b) presença de um liso; c) desgaste poligonal. ....	62
Figura 4-7 – Índice de dano ( <i>MAE</i> ) para passagens com dano a uma velocidade de: a) 120 km/h; b) 200 km/h. ....	64
Figura 4-8 – Índice de dano ( <i>MSE</i> ) para passagens com dano a uma velocidade de: a) 120 km/h; b) 200 km/h. ....	65
Figura 4-9 -Aplicação da distância de Mahalanobis para a fusão do MSE dos sensores: a) 1 e 4; b) 1,2,4 e 5; b) 1-6. ....	67
Figura 4-10 – Análise de outliers consoante o ID obtido no modelo AEE: a) A4; b) B4; c) C1; d) D1. ....	68
Figura 4-11 – Análise de Clusters consoante o ID obtido no modelo AEE: a) A4; b) B4; c) C1; d) D1. ....	69
Figura 4-12 – Análise de Clusters para as passagens de lisos consoante o ID obtido no modelo AEE otimizado para uma velocidade de circulação de: a) 120 km/h; b) 200 km/h. ....	70
Figura 4-13 - Análise de Clusters para as passagens de desgaste poligonal consoante o ID obtido no modelo AEE otimizado para uma velocidade de circulação de: a) 120 km/h; b) 200 km/h. ....	71
Figura 5-1 – Sistema fixador - acelerómetro. ....	74
Figura 5-2 – Materiais utilizados: a) Extensómetro- C4A-06-125SL-350-39P; b) Adesivos- M-Bond 200 Kit; c) Revestimento protetor- M-Coat F Kit. ....	75
Figura 5-3 – Procedimento: a) Preparação da superfície; b) Aplicação do Extensómetro. ....	75
Figura 5-4 –Representação esquemática do troço de via instrumentado. A) Acelerómetros A1-A6 e Extensómetros E1-E4; B) Módulo de aquisição de dados; C) Gateway; D) Cloud; E) PC. ....	77
Figura 5-5 - Respostas de acelerações do veículo Alfa pendular: a) Passagem 171 (Tabela 5.1); b) Passagem 183 (Tabela 5.1). ....	78
Figura 5-6 - Representação esquemática da obtenção da velocidade de circulação através da resposta de extensões referente à passagem nº23. ....	80
Figura 5-7 - Análise de outliers. ....	82
Figura 5-8 – Análise de clusters. ....	82



## ÍNDICE DE TABELAS

Tabela 2.1 - Limite de comprimentos dos defeitos nas superfícies das rodas (EN 15313, 2016).....	22
Tabela 2.2 - Anexo G, EN 15313 (2016): valores admissíveis para a amplitude do defeito de falta de arredondamento $\Delta r$ (mm). .....	26
Tabela 3.1 - Propriedades geométricas do modelo numérico de um veículo do comboio Alfa pendular (Mosleh et al., 2021a). .....	45
Tabela 3.2 – Propriedades mecânica do modelo numérico do veículo BBN do comboio Alfa pendular (Mosleh et al., 2021a). .....	46
Tabela 3.3 - Propriedades mecânicas da via (Mosleh et al., 2021a). .....	47
Tabela 4.1 - Características de operabilidade dos cenários simulados.....	54
Tabela 4.2 – Diferentes tipos de arquitetura de rede e hiperparâmetros considerados. ....	61
Tabela 5.1 – Amostragem de passagens experimentais. ....	80



# CAPÍTULO 1

## INTRODUÇÃO

### 1.1 CONSIDERAÇÕES INICIAIS

A sustentabilidade e a inteligência artificial (IA) são áreas intrinsecamente relacionadas, dado que, de algum modo, conjuntos de técnicas de IA aplicadas nos demais setores da indústria, poderão garantir melhorias na sustentabilidade do planeta. Por exemplo, o sistema de transporte ferroviário é um setor que tem estado em constante desenvolvimento face à possibilidade de transportar dezenas de milhares de passageiros por hora e por direção, garantindo a não emissão de gases de efeito de estufa.

O transporte ferroviário, em particular o de alta velocidade, tem vindo a assumir um papel fundamental no desenvolvimento sustentável dos países, tanto a nível económico como social. As vantagens deste tipo de transporte face a outros meios de transporte, nomeadamente o rodoviário e o aéreo, estão relacionadas com as reduções de custos, gastos energéticos e com as menores consequências em termos ambientais. A redução do tempo das deslocações proporcionada pelo aumento da velocidade de circulação, associada a melhorias das condições de conforto dos passageiros, têm também contribuído para a maior competitividade do transporte ferroviário (Ribeiro, 2012).

Com base nas informações disponíveis pela Railway-Technology (2023), a Figura 1.1 compõe alguns dos comboios de alta velocidade existentes que permitem efetuar grandes deslocações em períodos consideráveis. O Eurostar (Figura 1.1a) é um comboio com capacidade de alcançar velocidades de 300 km/h, que estabelece a ligação entre a Grã-Bretanha e a Europa continental, ligando as cidades de Londres e Lille. A linha ferroviária que sustenta a circulação deste veículo, estende-se pelo Reino Unido, França, Bélgica e Holanda. O comboio InterCity Express (Figura 1.1b), ou ICE, circula na rede ferroviária alemã, estabelecendo conexão com França, Bélgica, Holanda, Suíça, Áustria e Dinamarca, a uma velocidade máxima de circulação de 250 km/h. O comboio Alfa pendular (Figura 1.1c), em toda a extensão da linha ferroviária portuguesa que liga Porto-Lisboa, atinge a sua velocidade máxima de 220 km/h em pequenos troços do percurso. Atualmente a viagem é realizada com uma duração de 3 horas, porém são previstas grandes inovações no que toca à circulação ferroviária de alta velocidade, permitindo reduzir,

consideravelmente, o tempo total da viagem. No ano civil anterior, Carlos Fernandes, do conselho de administração da Infraestruturas de Portugal (IP), anunciou, durante a apresentação do projeto de alta velocidade para ligação de Lisboa ao Porto e do Porto a Vigo, no terminal de Campanhã no Porto, que: "Será construída uma nova linha, em via dupla, de alta velocidade entre Porto e Lisboa, em bitola ibérica, com o tempo de percurso direto entre a Campanhã e Lisboa-Oriente de 01h15", (Quaresma, 2022). O comboio de alta velocidade francês TGV (Figura 1.1d) é caracterizado pelo primeiro grande comboio de alta velocidade europeu. Atualmente a sua rede conecta diversas cidades na França com outros países como Alemanha, Bélgica, Luxemburgo, Suíça e Itália, a uma velocidade de 320 km/h. Já no extremo oriente, a engenharia ferroviária é mais desenvolvida face à europeia. O Japão, caracterizado pelo país fundador da ferrovia de alta velocidade, desenvolveu ao longo de mais de 50 anos a rede ferroviária de alta velocidade Shinkansen. A rede centra-se na capital Tóquio, com linhas para oeste, sul, leste e norte desta nação densamente povoada. O comboio de alta velocidade desta rede, designado por Nozomi-Shinkansen (Figura 1.1e) é capaz de operar a uma velocidade máxima de 320 km/h. Porém, já foram realizados testes com um novo comboio, o Alfa-X (série E956), planeado para operar em 2030, a velocidades de aproximadamente 360 km/h. O comboio será equipado com novas medidas de segurança para proteger os passageiros de possíveis ações sísmicas. Por outro lado, na rede ferroviária de alta velocidade chinesa circula o comboio Fuxing Hao (Figura 1.1d), com um design aerodinâmico que permite uma redução da resistência do ar proporcionando que o veículo atinja velocidades operacionais mais elevadas. Este tipo de comboio possui um sistema de monitorização integrado em, aproximadamente, 2500 pontos. A sua velocidade média de operação é de 350 km/h, enquanto a velocidade máxima é de 400 km/h, permitindo deslocamentos entre Pequim e Xangai em períodos de 4 horas.

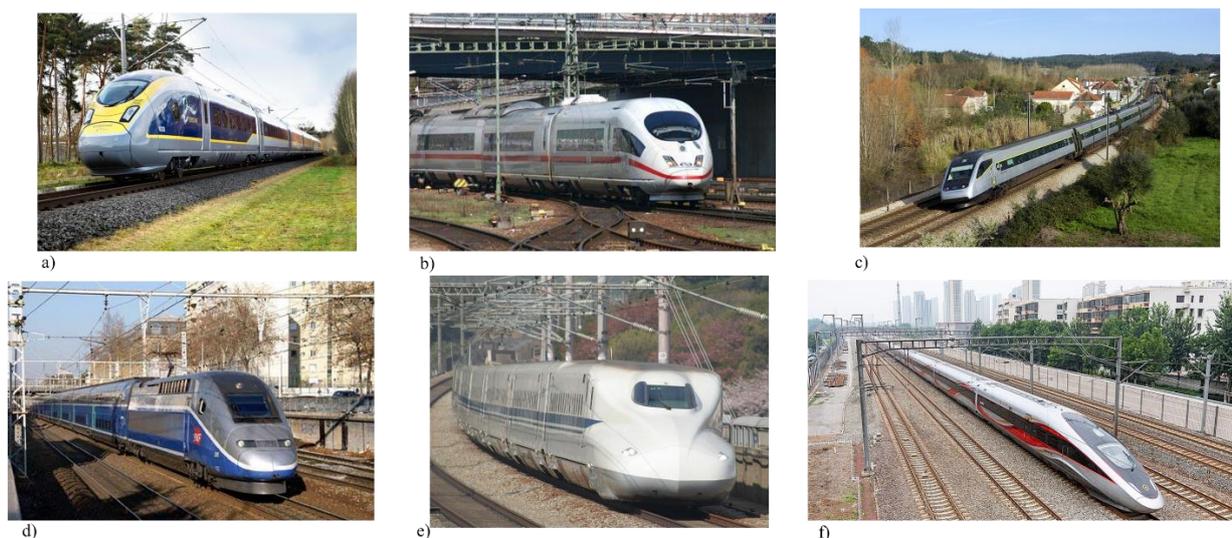


Figura 1-1- Comboio de alta velocidade: a) Eurostar; b) Intercity Express; c) Alfa pendular; d) TGV; e) Nozomi (Shinkansen); f) Fuxing Hao (fonte: Railway Technology, 2023).

Com o aumento da velocidade de circulação novos desafios surgem ao nível do comportamento dinâmico das estruturas integradas no sistema de circulação, implicando um maior controlo operacional. No que diz respeito a estruturas existentes, as passagens de veículos a velocidades superiores na mesma estrutura provocam efeitos dinâmicos distintos dos anteriores, nomeadamente os fenómenos de ressonância. A probabilidade de ocorrência destes fenómenos aumenta quando a circulação é efetuada com a presença de rodas geometricamente imperfeitas. As rodas ferroviárias irregulares representam um desafio significativo na interação entre a roda e o carril, causando flutuações substanciais nas forças normais, vibrações, ruído de rolamento e ruído de impacto. Consequentemente, prejudica substancialmente o conforto dos passageiros e influencia o sistema ferroviário, podendo originar uma série de acontecimentos, tais como, a instabilidade do eixo da roda, levando a deformações, rolamentos danificados, fissuras nas rodas, carris e travessas (Guedes, 2022). A ocorrência destes fenómenos pode ser controlada com a aplicação de sistemas de monitorização que permitam extrair e analisar as respostas dinâmicas dos elementos constituintes do sistema.

Recentemente, na área da monitorização da integridade estrutural (MIE), tem-se vindo progressivamente a estudar a deteção de danos por meio de visão computacional utilizando técnicas de inteligência artificial (Cury et al., 2021; Lee et al., 2022). Na área da engenharia ferroviária, uma aplicação fundamental destas técnicas envolve o aprimoramento da segurança operacional e da abordagem proativa nas necessidades de manutenção. Os sistemas de monitorização localizados na via são uma alternativa promissora e económica para prever danos no material circulante, atendendo que um único troço de via instrumentado é capaz de extrair dados relativos a todo o tipo de circulação existente na mesma (Meixedo et al., 2022b). Neste âmbito, alguns investigadores formularam modelos matemáticos para simular numericamente passagens de comboios com diferentes tipos de variabilidades. Estes modelos compreendem uma avaliação do desgaste roda-carril, envolvendo a integração de um modelo dinâmico de veículo-via e um modelo de danos nas rodas, caracterizado pela sobreposição do defeito no carril, através de um processo iterativo. Com o auxílio deste tipo de algoritmos, com resultados muito próximos da realidade, é possível estabelecer diferentes condições normais e anormais de circulação que permitam desenvolver metodologias de identificação de dano, capazes de serem aplicadas a passagens reais de circulação. Diversos investigadores implementam métodos para identificação de dano com base nas respostas de aceleração usando diferentes tipos de algoritmos de *machine learning* (ML), nomeadamente as redes neuronais artificiais, amplamente utilizadas para identificar danos estruturais (Sarwar et al., 2021; Yessoufou et al. 2023). A principal vantagem deste tipo de técnica de ML, baseada no cérebro humano, é a extração automática de indicadores sensíveis a danos, durante os processos de treino. Estes tipos de algoritmos detêm da capacidade de capturar relações não lineares existentes nos dados de entrada, através do reconhecimento de padrões existentes nesse conjunto de dados (Meng et al., 2017). Entre as

diversas técnicas de redes artificiais existentes, os autoencoders têm sido alvo de estudo em trabalhos recentes (Li et al., 2023).

Sumariamente, na Figura 1.2 apresenta-se em esquema, os aspetos analisados na presente dissertação, compreendendo o conjunto das operações que envolveram todo o trabalho realizado.

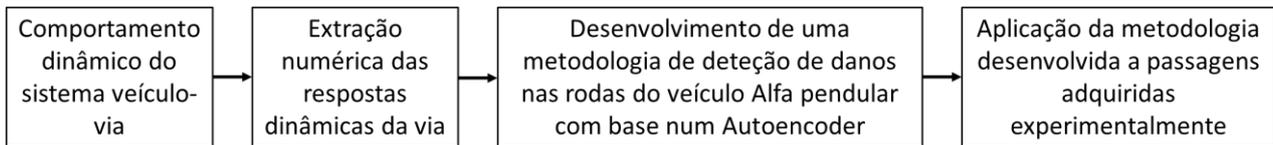


Figura 1-2 - Enquadramento do tema.

## 1.2 OBJETIVOS DO TRABALHO

A presente dissertação enquadra-se no âmbito do projeto de I&D WAY4SafeRail- WAYSIDE MONITORING SYSTEM FOR SAFE RAIL TRANSPORTATION, com a finalidade de desenvolver um conjunto de ferramentas para monitorizar a condição dos rodados ferroviários, distribuição de peso e eventos não relacionados com passagem de comboios. O Projeto é promovido pela EVOLEO Technologies, a Faculdade de Engenharia da Universidade do Porto, o Instituto Superior de Engenharia do Porto, e conta com a participação das Infraestruturas de Portugal como entidade parceira não promotora.

O objetivo do projeto WAY4SafeRail é contribuir para a segurança do transporte ferroviário, da qualidade do serviço e uma melhoria da disponibilidade do sistema ferroviário, tendo como principal propósito a monitorização de fatores críticos associados a uma operação segura do transporte ferroviário.

Com o intuito de contribuir para o avanço do projeto, o presente trabalho permitiu desenvolver uma metodologia não supervisionada de identificação de danos nas rodas do veículo ferroviário Alfa-Pendular. Deste modo, os principais objetivos da dissertação são:

- perceber quais os sistemas de monitorização inerentes à circulação ferroviária;
- analisar dinamicamente o sistema veículo-via e a interação entre estes dois sistemas;
- caracterizar as irregularidades presentes na via, assim como as que vulgarmente se formam nas rodas dos veículos ferroviários ao longo da circulação;
- estudar a natureza da monitorização da integridade estrutural, assim como as diferentes etapas e algoritmos que as compõe;
- desenvolver uma metodologia de deteção de dano com base nas respostas de acelerações verticais adquiridas na via;
- validar a metodologia desenvolvida com uma amostragem de passagens experimentais;

- apresentar as conclusões do trabalho.

### 1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

A dissertação está organizada em seis capítulos, sendo que no presente capítulo, “Introdução”, contempla-se um enquadramento do tema em estudo, indica-se a sua problemática e estratégias de resolução; refere-se o âmbito, os principais objetivos e, por fim, a organização da dissertação.

O Capítulo 2, “Estado da arte”, inicia-se com a apresentação dos sistemas de deteção de danos, distinguindo-se os sistemas *wayside* dos sistemas *on-board*. Em seguida, dispõe-se dos fundamentos teóricos relativos à análise dinâmica veículo-via, avaliando a modelação numérica de cada componente e os procedimentos matemáticos que estabelecem a interação dinâmica entre estes dois sistemas. Ainda neste capítulo, abordam-se os defeitos geométricos ao nível das rodas, assim como a sua caracterização numérica. Por fim, analisam-se os conceitos base que sustentaram o desenvolvimento da metodologia de deteção de dano, juntamente com uma revisão teórica relativa às diferentes técnicas aplicadas no desenvolvimento do trabalho.

O Capítulo 3, “Modelação numérica”, explica os modelos numéricos utilizados para simular passagens ferroviárias, tais como o modelo do veículo Alfa pendular e o modelo de via. Apresentam-se ainda os diferentes defeitos geométricos considerados nas análises e o algoritmo que permitiu estabelecer a interação dinâmica entre o veículo e a via.

No Capítulo 4, “Metodologia de identificação de danos”, faz-se a apresentação da metodologia desenvolvida, descrevendo-se os diferentes cenários simulados, tanto de passagens sem dano como de passagens com dano. Em seguida, cada etapa da metodologia é abordada detalhadamente, com a apresentação do raciocínio estabelecido, assim como a especificação das técnicas utilizadas. Os resultados obtidos são apresentados e devidamente comentados.

No Capítulo 5, “Campanha experimental”, expõe-se o procedimento da implementação do sistema de monitorização e da sua composição. Ainda neste capítulo, são apresentadas algumas respostas dinâmicas extraídas que foram submetidas à metodologia de deteção de dano descrita no capítulo anterior (Capítulo 4).

Por fim, no Capítulo 6, “Considerações finais”, descreve-se as conclusões, os desenvolvimentos futuros e as publicações efetuadas no âmbito do presente trabalho.



## CAPÍTULO 2

### ESTADO DA ARTE

#### 2.1 CONSIDERAÇÕES INICIAIS

Este capítulo tem como principal objetivo uma reflexão dos fundamentos teóricos, juntamente com trabalhos experimentais e numéricos desenvolvidos na literatura que permitiram estabelecer um raciocínio para o desenvolvimento do presente trabalho.

Primeiramente é exposta alguma informação sobre a aplicação de instrumentos de medição vulgarmente utilizados em sistemas de deteção de danos estruturais, nomeadamente em estruturas ferroviárias. De seguida são apresentados os principais conceitos relativos à dinâmica estrutural que permitem compreender a interação entre dois subsistemas, o veículo e a via. Os modelos dinâmicos utilizados na literatura que retratam estes dois subsistemas são apresentados, assim como os defeitos geométricos usualmente formados nas rodas dos veículos. Por fim, é abordada de uma forma detalhada as técnicas de inteligência artificial que compõem todas as etapas de análise e tratamento dos dados utilizadas no desenvolvimento da metodologia de deteção de dano.

#### 2.2 SISTEMAS DE DETEÇÃO DE DANOS

Nos últimos anos, os trabalhos de monitorização da integridade estrutural (MIE) evoluíram de técnicas de inspeção visuais para dispositivos de monitorização baseados em sensores, sobretudo devido à falta de recursos humanos qualificados, procedimentos morosos, restrições e acesso limitado a componentes estruturais específicos (Fadel e Zhu, 2023). Uma contínua monitorização estrutural permite a extração, processamento e acompanhamento de características que possibilitem avaliar a integridade da estrutura de forma a diagnosticar possíveis danos.

Ao longo do tempo os carris são submetidos a condições extremas de circulação que poderão produzir deformabilidades e fraturas no elemento. Quando os veículos ferroviários são sujeitos a circular nestas condições, formam-se irregularidades verticais e laterais que caracterizam o movimento das rodas como irregulares. Esses movimentos afetam a qualidade da operação, causando fenómenos aleatórios nas interações roda-carril, podendo levar ao descarrilamento dos veículos (Chellaswamy et al., 2019). A

prevenção destes fenómenos físicos é resolvida pela implementação de sistemas de monitorização capazes de extrair informações temporais relativas às passagens dos veículos ferroviários. Os tipos de sensores correntemente utilizados para adquirir as respostas dinâmicas de um sistema são: os acelerómetros (Mohammadi et al., 2023), extensómetros elétricos (Pintão et al., 2022; Mosleh et al., 2022b) e de fibra ótica (*Fibre Bragg Grating* - FBG) (Pimentel et al., 2021). A monitorização pode ser implementada tanto no veículo (sistemas *on-board*) como na via (sistemas *wayside*). A Figura 2.1 apresenta duas imagens referentes aos dois tipos de sistemas de monitorização. Contudo, a instalação de sensores nos veículos raramente é aplicada devido a questões de custo, operação e manutenção. Portanto, a medição na via tem atraído a atenção tanto da indústria ferroviária como de investigadores científicos, uma vez que o estado de todas as rodas pode ser avaliado durante a passagem de um comboio.

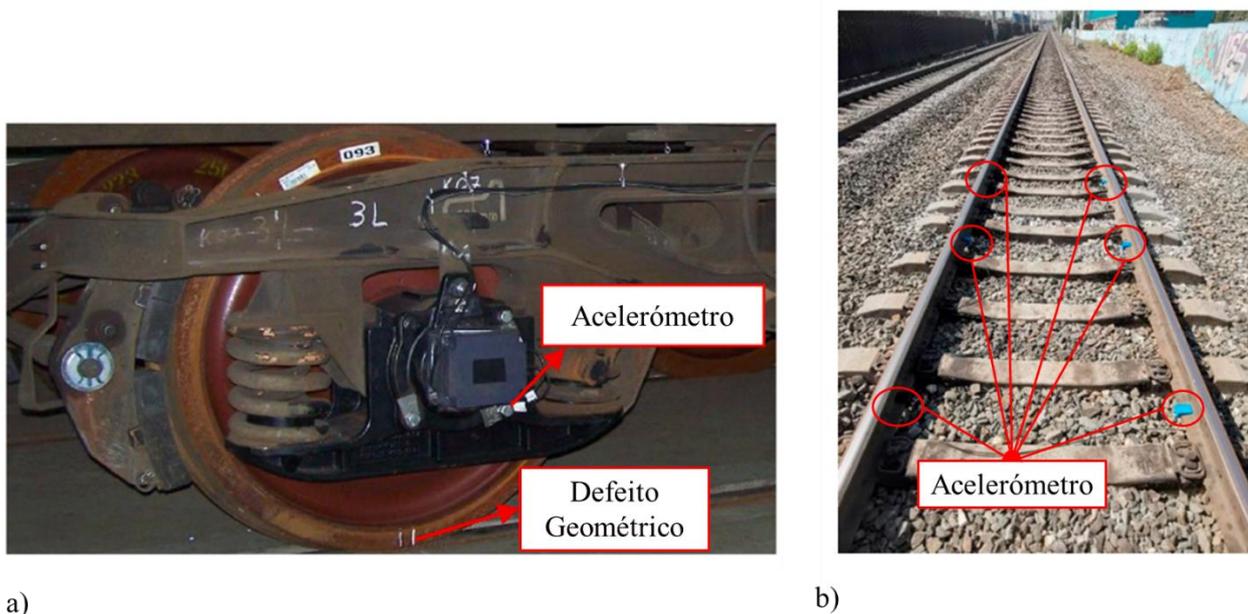


Figura 2-1 – Tipos de sistemas de monitorização: a) Sistema *on-board* (Ye et al., 2023); b) Sistema *wayside* (Avsievich et al, 2023).

Ye et al. (2023) desenvolveram uma metodologia de deteção de danos com o objetivo de diagnosticar anomalias nas rodas ferroviárias. O conjunto de dados foi adquirido através de medições experimentais e numéricas, comparando a eficiência da metodologia para ambas as situações. No contexto experimental, foram instrumentados dois tipos de veículos, um vagão de mercadorias e um veículo de alta velocidade. O vagão foi analisado para velocidades de operação até 100 km/h, já o veículo de alta velocidade para velocidades não superiores a 300 km/h. O grupo técnico introduziu uma superfície lisa com um comprimento de 20 mm na superfície de rolamento da roda do vagão (Figura 2.1a), sujeitando-a a uma circulação de 140 km/h. Referente ao veículo de alta velocidade, este foi sujeito a uma monitorização durante 1,2 milhões de km percorridos, pelo que foi detetado um defeito poligonal de

ordem 20, com desvio radial máximo de 0,2 mm. As respostas de acelerações de ambos os veículos foram medidas através de um acelerómetro instalado na caixa de eixo próximo da roda defeituosa com uma frequência de amostragem de 5 kHz, conforme ilustra a Figura 2.1a referente ao vagão.

Avsievich et al. (2023) comparam fenómenos dinâmicos obtidos por três meios distintos: i) com o uso de um carro de laboratório móvel; ii) aplicação de acelerómetros nos carris (Figura 2.1b) e iii) modelação numérica da interação roda-carril, com recurso ao método dos elementos finitos. A principal atenção do estudo concentra-se na comparação entre as forças de impacto e os deslocamentos obtidos ao nível do carril para as três situações criadas. O estudo revelou as interdependências dos parâmetros medidos, que dependem essencialmente da velocidade do comboio, carregamento dos vagões, oscilação do veículo e da presença de defeitos nas rodas. A combinação destes diferentes métodos de pesquisa permitiu que os autores avaliassem amplamente os descolamentos do carril aumentando as possibilidades de uma análise abrangente do estado da via-férrea. Este estudo desenvolve uma técnica de previsão de longo prazo proporcionando a segurança do transporte ferroviário. A campanha experimental consistiu em instalar seis acelerómetros, conforme o esquema mostrado na Figura 2.1b, extraindo as respostas dinâmicas de acelerações com dois veículos de passageiros e dois vagões.

## **2.3 ANÁLISE DINÂMICA DO SISTEMA VEÍCULO-VIA**

A origem dos fenómenos dinâmicos deve-se, por um lado, à geração de forças de inércia na estrutura devido à passagem do comboio animado de velocidade e, por outro lado, à existência de irregularidades na via e nas rodas dos veículos, irregularidades essas que provocam forças de impacto na estrutura (Ribeiro, 2012).

A metodologia da análise dinâmica do sistema veículo-via, consiste na modelação de cada componente constituinte do sistema e dos respetivos cenários de dano. Entende-se por modelo um “sistema físico, matemático ou lógico que representa as estruturas essenciais de uma realidade, permitindo compreendê-la ou reproduzi-la” (Vale, 2010).

A presente secção contempla uma revisão bibliográfica onde são apresentados os modelos dinâmicos constituintes do sistema, o veículo e a via, assim como os métodos numéricos mais usuais para determinar a interação dinâmica entre estes.

### **2.3.1 O veículo**

Os comboios de passageiros, que circulam na rede ferroviária portuguesa, podem ser convencionais ou articulados. Nos veículos convencionais, cada carruagem tem dois bogies, cada um com dois eixos, como é o caso do Alfa pendular (CP 4000) (Figura 2.2a). Os comboios articulados, apresentam carruagens que

têm, em cada extremidade, um bogie de dois eixos articulados, partilhado com a carruagem adjacente, como é o caso do comboio suburbano (CP 3400) que circula linha ferroviária do Norte (Figura 2.2b). A Figura 2.2 ilustra esquematicamente cada tipo dos comboios referidos, com um registo fotográfico de um comboio exemplo.

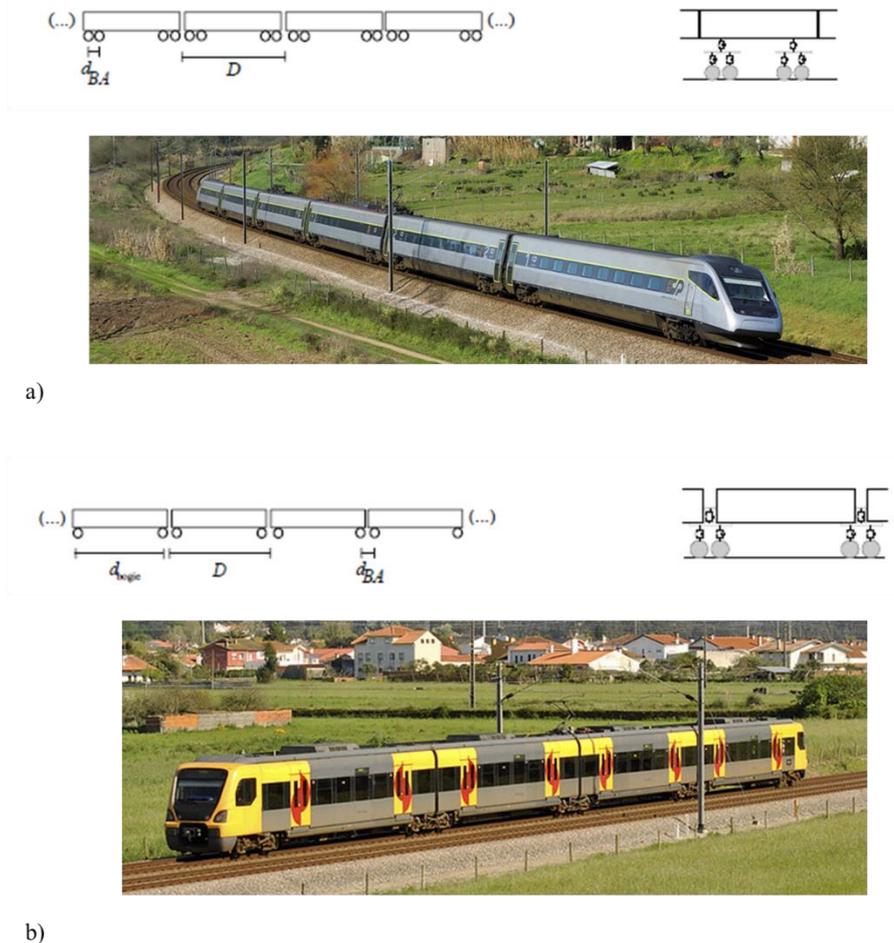


Figura 2-2 - Tipologia de veículos ferroviários de passageiros da rede ferroviária portuguesa: a) veículo convencional Alfa pendular (CP 4000); b) veículo suburbano (CP 3400) (adaptado de Vale (2010) e Silva (2018)).

Os veículos ferroviários distinguem-se não só quanto ao tipo, mas também quanto às características mecânicas dos seus elementos constituintes. Estas características são modeladas numericamente conforme o tipo de análise dinâmica que se pretende executar, podendo ser modelados com um caráter 2D ou 3D (Vale, 2010). Sendo que os de caráter 2D e 3D podem ser modelados como uma associação de corpos rígidos, e ainda os modelos 3D podem ser modelados como modelos flexíveis. Segundo Silvestre e Teixeira (2022, p.273) “O conceito de corpo rígido é uma idealização, na prática, um objeto será aproximadamente um corpo rígido se não sofrer variações apreciáveis de volume e/ou de forma quando submetido à ação de forças que, habitualmente, sobre ele se exercem”. Atendendo ao regime das pequenas deformações, o modelo de corpo rígido é o vulgarmente utilizado para avaliar a resposta global

da estrutura. Do ponto de vista matemático os modelos de corpo rígido são descritos por conjuntos de equações diferenciais de movimento, complementadas por expressões algébricas que modelam as restrições cinemáticas dos corpos. Estas equações dependem fundamentalmente das geometrias, massa e momento de inércia dos componentes do veículo, bem como do comportamento das suspensões (Bragança et al., 2022). Relativamente a este tipo de modelação, o modo de representação dos elementos que devem constituir as carruagens (Figura 2.3) é dado por Calçada (1995) como:

- A caixa do comboio deve ser representada por um elemento com massa  $m_c$  e momento de inércia  $I_c$ ;
- As suspensões secundárias devem ser representadas por elementos de molas com rigidez  $K_2$  e amortecedores, com constante de amortecimento  $c_2$ ;
- Os bogies são simulados como corpos rígidos de massa  $m_b$  e momento de inércia  $I_b$ ;
- As suspensões primárias são simuladas por molas de rigidez  $k_1$ , e amortecedores com constante de amortecimento  $c_1$ ;
- Rodas e eixos representados por massas concentradas  $m_w$  e momento de inércia  $I_w$ ;
- Ligação roda-carril representada por molas de rigidez  $k$ .

Em estudos recentes, os modelos de corpo rígido têm sido amplamente usados em diversos trabalhos, com o objetivo de: i) avaliar a segurança de circulação dos comboios quando submetidos a fenómenos naturais, como sismos (Montenegro et al., 2016) e ventos cruzados (Neto et al., 2020), ii) avaliar o nível de conforto dos passageiros (Jiang, Chen, Thompson, 2019), iii) detetar defeitos geométricos nas rodas dos veículos (Mosleh et al., 2021b; Guedes et al., 2023; Silva et al., 2023; Mohammadi et al., 2023; Lourenço et al., 2023), iv) estudo interação dinâmica entre pantógrafo e catenária (Antunes et al., 2020), v) estudo do comportamento dinâmico de pontes (Saramago et al., 2022).

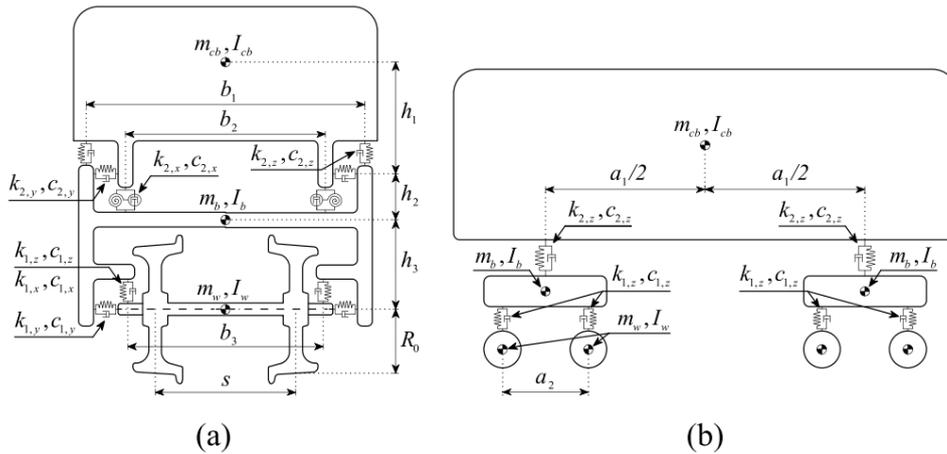


Figura 2-3 - Modelo dinâmico de um veículo do comboio Alfa-Pendular (adaptado de Mosleh et al., 2021a): a) perspetiva transversal; b) perspetiva longitudinal

### 2.3.2 A via

Os modelos da via ferroviária, definidos por elementos finitos, podem ser bidimensionais ou tridimensionais. Os bidimensionais consistem na avaliação do comportamento da estrutura, numa dada direção, por exemplo, a resposta dinâmica do conjunto via-veículo na direção vertical. Os tridimensionais permitem analisar a estrutura, nas direções, vertical, longitudinal e transversal (Vale,2010).

Diversos autores (Mosleh et al., 2023, Guedes et al., 2023; Silva et al., 2023), apresentam o mesmo modelo numérico da via, apresentada na Figura 2.4, desenvolvido no programa ANSYS® (2018), baseado num esquema tridimensional de múltiplas camadas, simulando a fundação (f), o balastro (b), as travessas (s) e os carris (r). As travessas, o balastro e o carril são interligados por elementos elásticos que representam o comportamento mecânico das suas interfaces. A massa do balastro é modelada com elementos pontuais de massa para representar os efeitos de inércia, enquanto as travessas e o carril são simulados como elementos de viga. As interfaces de contacto são garantidas pelo balastro e pelas palmilhas que são modelados com elementos de mola-amortecedor, assim como a flexibilidade da fundação.

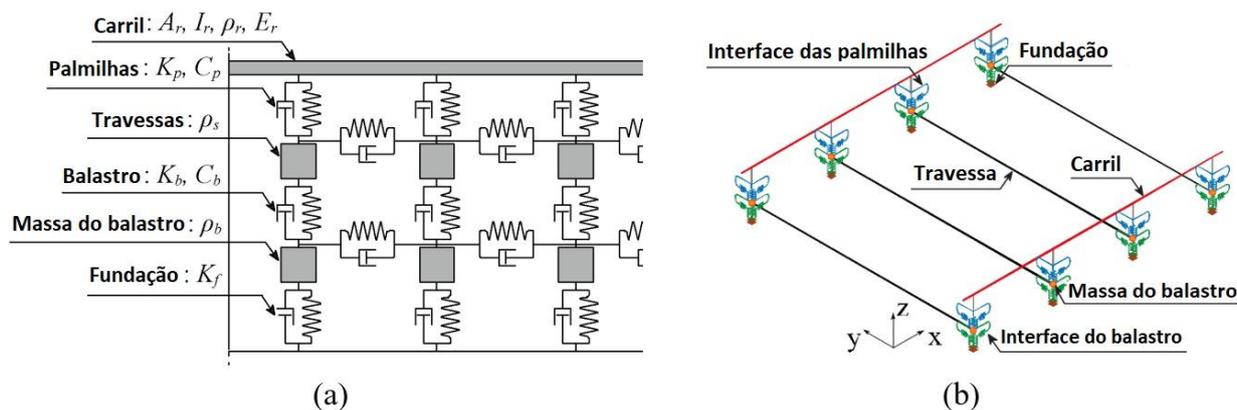


Figura 2-4 - Modelo da via: a) modelo dinâmico, b) modelo numérico em elementos finitos (adaptado de Mosleh et al., 2023)

Dado que a via é um elemento metálico com uma taxa de carbono inferior à taxa de carbono das rodas, esta desenvolve mais facilmente irregularidades, caracterizadas por irregularidades pontuais ou distribuídas. As irregularidades distribuídas da via podem ser definidas pela soma de expressões sinusoidais, por séries de Fourier (irregularidades periódicas), ou por funções de densidade espectral de potência (irregularidades aleatórias). A soma de expressões sinusoidais, com recurso às séries de Fourier, é aplicada na definição de desgaste ondulatório do carril, porque este defeito apresenta regularidade ao longo do espaço. O recurso a funções de densidade espectral de potência permite caracterizar os defeitos de nivelamento, alinhamento e bitola, definidas a partir de medições experimentais realizadas em vias ferroviárias. As irregularidades pontuais da via são de carácter variável quanto ao tipo e às formas das irregularidades (Vale, 2010).

Atendendo às irregularidades de via possíveis de serem caracterizadas numericamente, apenas são descritas as irregularidades distribuídas aleatoriamente por funções de densidade espectral de potência, dado que foram as utilizadas no âmbito da presente dissertação. De forma a definir-se analiticamente os perfis de irregularidade referente ao nivelamento longitudinal e transversal, tendo em conta a sua aleatoriedade, as funções de densidade espectral de potência  $S(\omega)$  são expressas por (Vale, 2010):

$$S(\omega_1) = \frac{A \cdot \omega_3^2 \cdot (\omega_1^2 + \omega_2^2)}{\omega_1^4 \cdot (\omega_1^2 + \omega_3^2)} \quad (2-1)$$

Sendo  $\omega_2$  e  $\omega_3$  frequências padrão que assumem os valores de 0.1464 e 0.8168 rad/m, respetivamente;  $\omega_1$  corresponde à frequência angular da irregularidade ( $2\pi/\lambda$ ) e o parâmetro  $A$  está relacionado com a qualidade da via. O procedimento analítico que permite gerar perfis aleatórios de irregularidade consiste nas fases seguidamente transcritas de Vale (2010):

- i. Cálculo dos números de onda mínimo e máximo a partir da gama de comprimentos de onda assumidos:

$$\omega_0 = \frac{2\pi}{\Lambda_{m\acute{a}x.}} \wedge \omega_f = \frac{2\pi}{\Lambda_{m\acute{m}n.}} \quad (2-2)$$

ii. Definição do intervalo de números de onda  $\Delta(\omega)$ :

$$\Delta(\omega) = \frac{\omega_f - \omega_0}{N} \quad (2-3)$$

iii. Obtenção do parâmetro  $A_n$ :

$$A_n = \sqrt{\frac{S_\omega(\omega) \cdot \Delta(\omega)_n}{2\pi}} \quad (2-4)$$

iv. Cálculo de perfis de irregularidades com ângulo de fase aleatórios  $\varphi_n$  entre 0 e  $2\pi$ :

$$z(x) = \sqrt{2} \sum_{n=0}^{N-1} A_n \cos(\omega_n \cdot x + \varphi_n) \quad (2-5)$$

Sendo:  $\Lambda_{m\acute{a}x.}$ , comprimento de onda máximo;  $\Lambda_{m\acute{m}n.}$ , comprimento de onda mínimo;  $\omega_0$ , número de onda mínimo;  $\omega_f$ , número de onda máximo;  $\Delta(\omega)$ , intervalo de número de onda;  $N$ , número de sub-intervalos.

### 2.3.3 Interação dinâmica veículo-via

A estabilidade do contacto entre a roda e o carril será assegurada se a geometria da via for compatível, em todos os instantes, com a geometria do comboio, (Calçada 1995). Dado que o veículo e a via formam um único sistema dinâmico, a resposta da via depende, não só do comportamento dos seus elementos constituintes, mas também das características dos veículos que sobre ela circulam.

A lei fundamental da dinâmica traduz o efeito de quando a resultante das forças que se exercem sobre um dado corpo não é nula, por outras palavras, traduz o equilíbrio das forças associadas a cada grau de liberdade da estrutura. Em cada ponto e em cada instante de tempo estão presentes quatro tipos de forças: as forças exteriores  $f(t)$ , as forças de inércia  $f_i(t)$ , as forças de amortecimento  $f_c(t)$ , e as forças elásticas  $f_e(t)$  (Calçada, 1995).

O equilíbrio dinâmico é então estabelecido através da equação:

$$f_i(t) + f_c(t) + f_e(t) = f(t) \quad (2-6)$$

Dado que as forças de inércia são expressas por  $f_i = M \cdot \ddot{u}$ , sendo  $\ddot{u}$  o vetor das acelerações e  $M$  a matriz de massa. As forças de amortecimento são dadas por  $f_c = C \cdot \dot{u}$ , em que  $\dot{u}$  corresponde ao vetor das velocidades e  $C$  à matriz de amortecimento. As forças elásticas são definidas por  $f_e = K \cdot u$ , sendo  $u$  o vetor dos deslocamentos e  $K$  a matriz de rigidez. Posto isto, a equação (2-1) é equivalente à seguinte equação:

$$[M] \cdot \ddot{u}(t) + [C] \cdot \dot{u}(t) + [K] \cdot u(t) = F(t) \quad (2-7)$$

É de realçar que a ordem das matrizes na equação (2-7) corresponde ao número de graus de liberdade da estrutura. Para cada nó de um elemento de barra tridimensional estão associados seis graus de liberdade, três deslocamentos e três rotações, resultando matrizes de dimensão 12x12 para as matrizes elementares de massa  $[M]$  e de rigidez  $[K]$ .

A matriz de amortecimento é dada pela formulação de Rayleigh, expressa através de uma combinação linear das matrizes de rigidez  $[K]$  e de massa  $[M]$ , dada por:

$$[C] = c_1 \cdot [M] + c_2 \cdot [K] \quad (2-8)$$

Sendo  $c_1$  e  $c_2$  são as constantes de amortecimento de Rayleigh, que dependem diretamente dos coeficientes de amortecimento e das frequências angulares do elemento. É de salientar que o amortecimento é uma das propriedades mais complexas de determinar, pois não depende apenas dos materiais e da solução estrutural, mas também da conexão entre os elementos estruturais e dos elementos não estruturais presentes na estrutura (Saramago, 2020).

Em conformidade com Montenegro (2015) destacam-se três métodos que permitem determinar o comportamento dinâmico do sistema veículo-via, seguidamente transcritos e enumerados:

- i. Modelo de Cargas Móveis: baseado no princípio de que as ações verticais transmitidas pelo veículo à via são constituídas por cargas verticais rolantes,  $F(t)$ , que para cada instante contêm uma componente estática,  $F_{est.}$ , e uma componente dinâmica,  $F_{din.}(t)$ . Invocando a equação (2-2) e substituindo  $F(t)$  pelas duas componentes mencionadas, virá:

$$[M] \cdot \ddot{u}(t) + [C] \cdot \dot{u}(t) + [K] \cdot u(t) = F_{est.} + F_{din.}(t) \quad (2-9)$$

Sendo  $F_{est.}$  correspondente ao peso do veículo e  $F_{din.}(t)$  correspondente aos movimentos verticais a que os veículos ficam sujeitos devido à interação entre estes e a via. A equação (2-4) pode ser resolvida utilizando técnicas de integração direta, como por exemplo o método de Newmark.

- ii. Método do Caminho Virtual: este método consiste numa abordagem que não considera a interação entre os sistemas veículo-via, mas permite o cálculo de uma resposta dinâmica aproximada de cada um dos sistemas. O método é dividido em duas fases, sendo a primeira abrangida pelo cálculo do chamado caminho virtual para as rodas do veículo. O caminho virtual resulta do cálculo da resposta dinâmica da via submetida à ação do veículo, descrito por um modelo de cargas móveis. A segunda fase consiste em prescrever a história temporal dos deslocamentos da via às rodas do veículo a fim de obter a sua resposta desacoplada.
- iii. Método de Interação Veículo-Via:

Este método rege o equilíbrio das forças que atuam na interface de contacto roda-carril e usa um processo iterativo para impor as equações restritas que relacionam os deslocamentos dos nós de contacto do veículo com os correspondentes deslocamentos da via. Os dois subsistemas, o veículo e a via, são modelados como duas subestruturas separadas, cujas equações de equilíbrio desacopladas podem ser expressas de forma matricial através da equação (2-7):

$$\begin{bmatrix} M_v & 0 \\ 0 & M_c \end{bmatrix} \cdot \begin{bmatrix} \ddot{u}_v(t) \\ \ddot{u}_c(t) \end{bmatrix} + \begin{bmatrix} C_v & 0 \\ 0 & C_c \end{bmatrix} \cdot \begin{bmatrix} \dot{u}_v(t) \\ \dot{u}_c(t) \end{bmatrix} + \begin{bmatrix} K_v & 0 \\ 0 & K_c \end{bmatrix} \cdot \begin{bmatrix} u_v(t) \\ u_c(t) \end{bmatrix} = \begin{bmatrix} F_v(t) \\ F_c(t) \end{bmatrix} \quad (2-10)$$

Em que os índices “v” e “c” correspondem, respetivamente, à via e ao comboio. O processo iterativo parte do pressuposto que para cada instante de tempo ocorrem as seguintes operações em cada iteração  $i+1$ :

- A via é sujeita a cargas móveis que correspondem aos eixos do veículo, em que cada carga móvel  $F_v^{i+1}$  é dada por:

$$F_v^{i+1} = F_{est.} + F_{din.}^{i+1} \quad (2-11)$$

Dado que  $F_{est.}$  corresponde à carga estática de cada eixo do veículo e  $F_{din.}^i$  é a força dinâmica de interação calculada na iteração anterior  $i$ . Com isto, através da resolução da expressão (2-5) correspondente à via, os deslocamentos nodais  $u_v^{i+1}$  são determinados, e a partir das funções de forma dos elementos finitos, é possível calcular os deslocamentos da via sob os nós de contacto, dados por  $u_Y^{i+1}$ .

- Em simultâneo com o descrito no tópico anterior, aos deslocamentos  $u_v^{i+1}$ , que correspondem aos deslocamentos da via sob os nós de contacto  $u_Y^{i+1}$  é adicionado uma irregularidade  $r$  presente na interface de contacto, são impostos os nós de contacto do veículo. Com isto, através da resolução da expressão (2-10) correspondente ao veículo, são calculadas as forças de reação nos nós de contacto. Estas reações correspondem à força de interação dinâmica  $F_{din.}^{i+1}$  a ser aplicada à via na iteração seguinte.
- No fim de cada iteração, é verificado o seguinte critério de convergência:

$$\frac{\|F_{din.}^{i+1} - F_{din.}^i\|}{\|F_{din.}^i\|} \leq \varepsilon \quad (2-12)$$

Onde  $\varepsilon$  corresponde a uma tolerância especificada. Caso o grau de convergência seja atingido, o processo avança para o instante de tempo seguinte, caso contrário, o processo iterativo procede.

Montenegro et al. (2015) desenvolveram um algoritmo capaz de simular passagens ferroviárias. Os autores descrevem a formulação do método de interação veículo estrutura como um processo que se inicia com a elaboração do modelo referente ao comportamento da interface de contacto entre a roda e

o carril. Em seguida, são calculadas as forças internas do modelo, que correspondem às forças geradas na interface de contacto. O algoritmo associado ao modelo de contacto é dividido maioritariamente em três etapas: 1) o problema geométrico, que consiste na deteção dos pontos de contacto; 2) o problema de contacto normal, no qual as forças são determinadas com base na teoria não-linear de Hertz e 3) o problema de contacto tangencial, onde são calculadas as forças de fluência que aparecem devido ao atrito do plano de rolamento. Finalmente, é utilizado um método para acoplar o veículo e a estrutura, denominado método direto (Neves et al., 2012; Neves et al., 2014). Este método complementa as equações de equilíbrio que caracterizam o veículo e a estrutura com as equações de restrição adicionais que relacionam os deslocamentos dos nós de contacto do veículo com os deslocamentos nodais correspondentes à estrutura. Essas equações formam um único sistema no qual as incógnitas são os deslocamentos e as forças de contacto, expressas por (Montenegro et al., 2020):

$$\begin{bmatrix} \bar{K} & \bar{D} \\ \bar{H} & 0 \end{bmatrix} \cdot \begin{bmatrix} \Delta a_F^{i+1} \\ \Delta X^{i+1} \end{bmatrix} = \begin{bmatrix} \Psi(a^{t+\Delta t,i}, X^{t+\Delta t,i}) \\ \bar{r} \end{bmatrix} \quad (2-13)$$

Onde  $\bar{K}$  corresponde à matriz de rigidez efetiva do sistema veículo-via;  $\bar{D}$  matriz que relaciona as forças de contacto com as forças nodais da estrutura e  $\bar{H}$  à matriz transformação que relaciona os deslocamentos nodais da estrutura com os deslocamentos do elemento de contacto (ver (Montenegro et al., 2015) para detalhes). Os deslocamentos nodais incrementais são caracterizados por  $\Delta a$ , e as forças de contacto por  $\Delta X$ , já o vetor da força residual  $\Psi$  e o vetor de irregularidades da via  $\bar{r}$  formam o vetor do outro lado da igualdade. Os índices  $i, i + 1$  indicam a iteração anterior e atual, respetivamente, enquanto  $t + \Delta t$  refere-se ao intervalo de tempo atual.

O modelo proposto baseia-se no método dos elementos finitos, que permite a análise de estruturas e veículos com qualquer grau de complexidade tendo em consideração as deformações sofridas pelos dois sistemas. A sua formulação foi implementada no MATLAB (2011), com os veículos e a via previamente modelados no ANSYS (2010), sendo as suas matrizes estruturais importadas para o MATLAB de forma a ser aplicado o processo iterativo que permite simular passagens ferroviárias.

## 2.4 DEFEITOS GEOMÉTRICOS NAS RODAS DOS VEÍCULOS FERROVIÁRIOS

As rodas dos comboios não são perfeitamente circulares e a sua superfície não é completamente lisa, mesmo aquando do processo de fabricação. Estas imperfeições apresentam diversas formas que são influenciadas pelo seu processo de formação (Staśkiewicz et. al., 2018).

A Figura 2.5 contempla alguns dos típicos danos existentes nas rodas dos veículos ferroviários presentes na EN 15313 (2016).

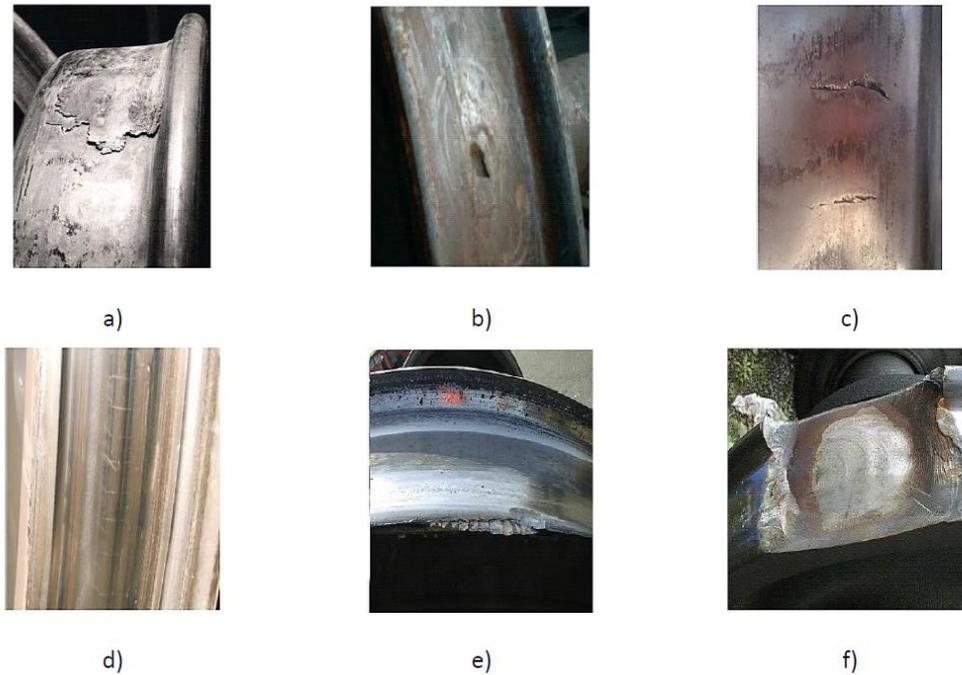


Figura 2-5 – Danos nas rodas dos comboios: a) Acumulação de metal; b) Cavidade; c) Reentrância do piso; d) Fragmentação; e) Danos no chanfro; f) Defeito profundo no piso (EN 15313, 2016).

Tendo em conta a diversidade de defeitos existentes, é conveniente avaliar aqueles que são possíveis de serem modelados numericamente. Na literatura os estudos de defeitos geométricos ao nível das rodas dos veículos concentram-se nas rodas com falta de arredondamento, correntemente designadas como *out-of-round wheels (OOR wheels)*. A este tipo de defeito estão associadas diversas características, tais como, a presença de lisos, excentricidades, efeitos poligonais e irregularidades aleatórias (Wu et al., 2017).

Nesta secção só serão abordados dois tipos de defeitos, o efeito poligonal nas rodas e a presença de lisos na superfície de rolamento. Estes tipos de danos detêm a possibilidade de serem caracterizados matematicamente por expressões algébricas, permitindo assim a simulação numérica de cada um individualmente. Deste modo, poderão ser incluídos nas simulações de interação dinâmica veículo-via (vetor de irregularidades  $\bar{r}$  equação 2-13) tornando-se um input para simulação de passagens de comboios com a presença de danos nas rodas. A Figura 2.6 dispõe de uma ilustração geométrica do desvio da forma de círculo perfeito que as rodas dos veículos podem assumir.

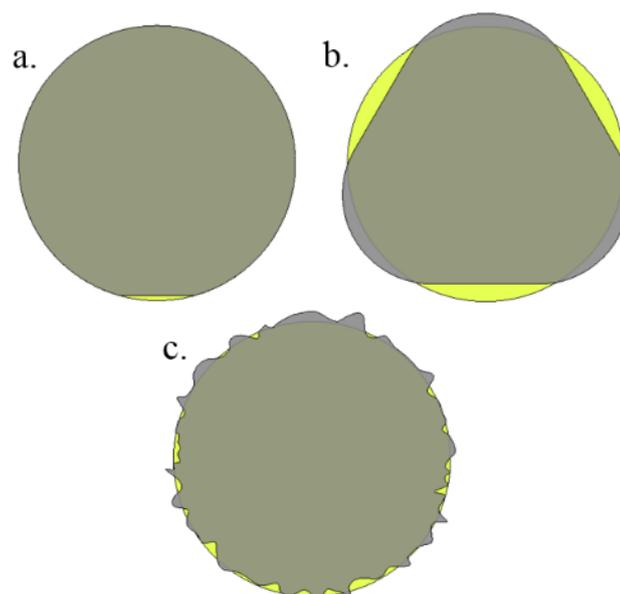


Figura 2-6 - Formas de rodas com falta de arredondamento: a) presença de lisos; b) imperfeição geométrica regular (periódica); c) imperfeição geométrica irregular (não periódica) (Staśkiewicz et. al., 2018).

Um defeito poligonal na roda é definido como uma irregularidade (contínua) circunferencial periódica medida a partir do raio médio da roda (Nielsen e Johansson, 2000). Já as rodas que contenham superfícies lisas em certas zonas do seu perímetro são caracterizadas por um defeito (discreto) comum na superfície de rolamento, causado principalmente pelo atrito entre a roda e o carril durante a frenagem e o rolamento das rodas ao longo da circulação (Chang et al., 2022). Em estudos recentes, diversas formas geométricas destes dois tipos defeitos têm sido investigadas através de medições experimentais e numéricas, permitindo avaliar quais as consequências estruturais causadas pelos fenômenos dinâmicos (Chang et al., 2022; Vale, 2021; Ye et al., 2022).

#### 2.4.1 Desgaste superficial liso

A presença de uma superfície plana ao longo do perímetro roda é designado por lisos nas rodas. Os mecanismos que promovem a formação deste tipo de dano são geralmente causados pelo deslizamento da roda sobre o carril, que podem ocorrer sobretudo devido a sistemas de travagem com anomalias ou por elevadas forças de frenagem. Na Figura 2.7 apresentam-se duas rodas com a presença de lisos.



Figura 2-7 - Exemplos de rodas com lisos (EN 15313, 2016)

O atrito existente entre a roda e o carril aquando de uma travagem faz com que surjam planos superficiais na faixa de rolamento. Por vezes falhas relativas ao sistema de travagem também poderão estar na origem deste evento. A formação deste fenómeno induz cargas de alto impacto na infraestrutura, causando danos significativos aos veículos, como eixos partidos e rodas fraturadas, e à via, danificando o carril e as travessas (Mosleh et al, 2023). A contínua circulação dos veículos com este tipo de defeito levará à formação de cantos arredondados em torno do liso, o que poderá dificultar a identificação do dano.

Chang et al. (2022) avaliaram experimentalmente o impacto causado por diversas rodas com geometrias de lisos distintas. As rodas foram posicionadas em torno de um círculo de rolamento da banda de rodagem a velocidades que variam de 0 a 400 km/h. Este equipamento laboratorial compreende um modelo de um rodado à escala real com funções perfeitas de medição. As forças verticais roda-carril foram obtidas pelos extensómetros instalados na secção circular do eixo, com uma frequência de amostragem de 2000 Hz. As respostas de acelerações causadas pelo impacto da roda no carril foram medidas pelos acelerómetros instalados na extremidade da caixa de eixo com uma frequência de amostragem igual a 12800 Hz. Na Figura 2.8 apresentam-se graficamente os resultados obtidos pelos autores.

A Figura 2.8a mostra as relações entre a máxima força de impacto dinâmico roda-carril e as características geométricas de cada cenário de liso avaliadas (D-profundidade; L- comprimento). Os resultados expressam que os valores máximos das forças de impacto aumentam à medida que a velocidade aumenta até 35 km/h. A partir dessa velocidade ocorre uma inflexão no gráfico pelo que a curva assume uma tendência decrescente à medida que a velocidade continua a aumentar. Para um mesmo nível de velocidade, o aumento das características do liso induz maiores forças de impacto na estrutura. Na Figura 2.8b é apresentada a relação entre o máximo valor da aceleração do impacto vertical roda-carril e a velocidade. O aumento do valor da aceleração com o aumento da velocidade assume a mesma variação

do que na Figura 2.8a. A partir dos 250 km/h, os desenvolvimentos das curvas começam a variar, evidenciando-se um comportamento não linear.

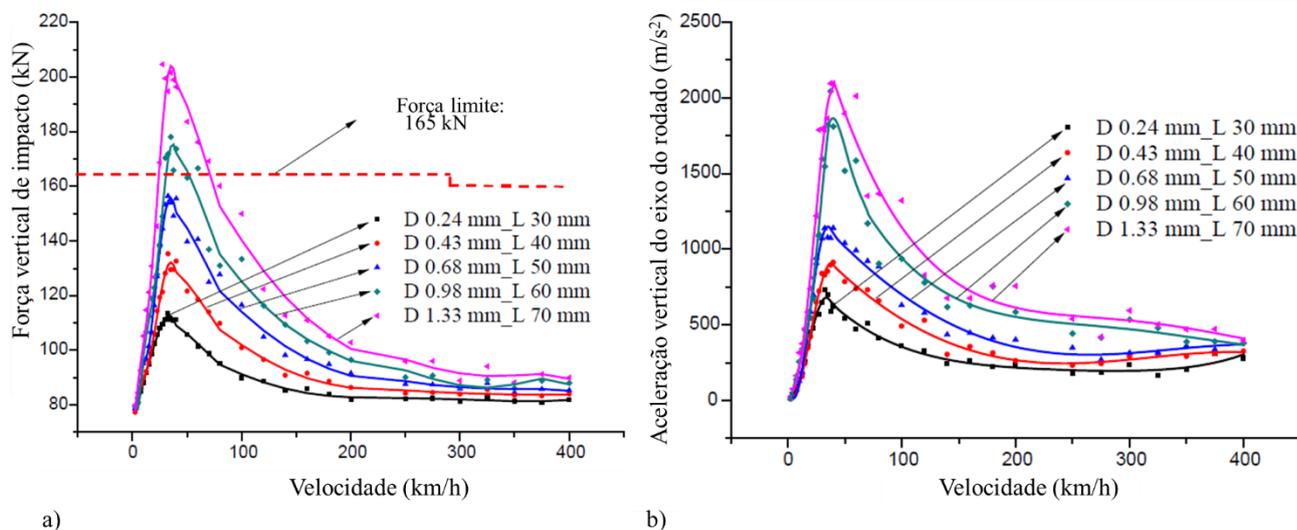


Figura 2-8 - Relações entre a velocidade e a força de impacto dinâmica induzida por diferentes características geométricas de lisos (Chang, C. et al., 2022).

Os autores descobriram ainda que o impacto da roda com lisos origina vibrações de frequência média de 100–500 Hz e vibrações de alta frequência em torno de 2000 Hz a 6000 Hz. Este estudo permitiu concluir que à medida que a velocidade aumenta até aos 35 km/h, quanto maior for a geometria do liso maior é a força de impacto dinâmico. Em seguida, à medida que a velocidade aumenta dos 35 km/h para 200 km/h, o valor máximo da força de impacto diminui bruscamente, no entanto, à medida que a velocidade aumenta entre 200 km/h e 400 km/h, o valor decresce lentamente.

#### 2.4.1.1 Requisitos normativos e caracterização geométrica

De acordo com as ações normais de operação, a norma EN 15313 (2016) prevê um conjunto de valores limite relativamente aos comprimentos dos planos superficiais das rodas, constituindo um critério a adotar em diferentes condições de operação, nos quais os valores oscilam entre os 20-80 mm, consoante a velocidade de circulação e o diâmetro das rodas (Tabela 2.1).

Tabela 2.1 - Limite de comprimentos dos defeitos nas superfícies das rodas (EN 15313, 2016).

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

Como resultado de travagens frequentes e forçadas em condições de tráfego urbano, as rodas ferroviárias apresentam frequentemente condições para desenvolver lisos na banda de rodagem devido ao atrito. O comportamento deste fenómeno é caracterizado geometricamente através do esquema da Figura 2.9, sendo que a presença de um liso na roda é equivalente a transpor as características do defeito para via.

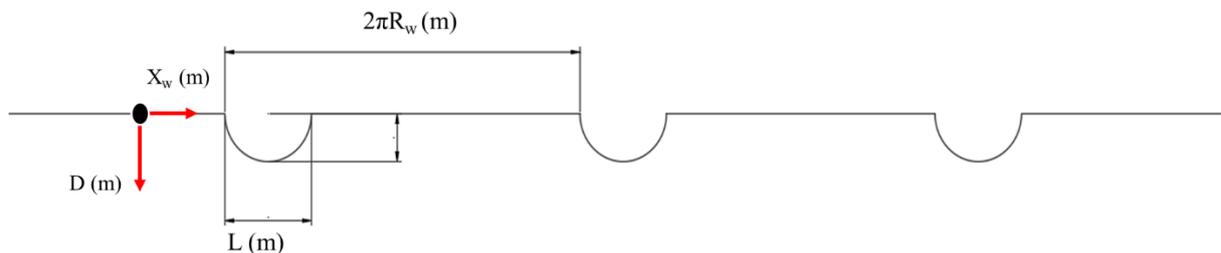


Figura 2-9 - Irregularidade do carril referente a um liso nas rodas.

Sendo a profundidade do liso (D) dada pela equação (2-14) como indica Mosleh et al. (2023) e Vale (2010):

$$D = \frac{L^2}{16 \cdot R_w} \tag{2-14}$$

Onde L é o comprimento do liso e R<sub>w</sub> é o raio da roda.

O desvio vertical do perfil da roda com liso é caracterizado geometricamente através da seguinte expressão.

$$Z = \frac{D}{2} \cdot \left(1 - \cos \frac{2\pi \cdot x_w}{L}\right) \cdot H[x_w - (2\pi \cdot R_w - L)], \tag{2-15}$$

$$0 \leq x_w \leq 2\pi R_w$$

Onde  $H$  representa a função periódica de Heaviside e  $x_w$  é a coordenada alinhada com a direção longitudinal da via.

### 2.4.2 Desgaste poligonal

O efeito poligonal ao longo da superfície da roda é uma imperfeição comum que se forma nas rodas dos veículos ferroviários, caracterizado pela alteração da forma da superfície do rodado. Numericamente, este efeito pode ser expresso como um movimento harmónico simples, caracterizado por um comprimento de onda compreendido no intervalo  $[14-2\pi r]$  cm, sendo  $r$  o raio da roda, enquanto a sua amplitude é geralmente inferior a 1 mm (Liu e Zhai, 2014). Este tipo de fenómeno pode ser distinguido entre defeitos periódicos e não periódicos (Peng, 2020).

Os defeitos periódicos apresentam harmónicos com amplitudes semelhantes, 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 de amplitudes variadas, nos quais apresentam irregularidades estocásticas de complexa caracterização (Guedes, 2022). Em Liu e Zhai (2014) é apresentado graficamente a distinção entre os dois tipos de efeito, exibida na Figura 2.10. As representações gráficas da distribuição harmónica presentes na figura mostram que no defeito periódico a ordem dos harmónicos dominantes pertence à ordem 1 e 3; ao contrário do defeito não periódico em que não é possível evidenciar a ordem do harmónico dominante. Posto isto, na presente secção abordar-se-á apenas os defeitos com irregularidades periódicas, de forma a serem distinguidos consoante a ordem dos harmónicos dominantes e diferentes valores da amplitude de desgaste.

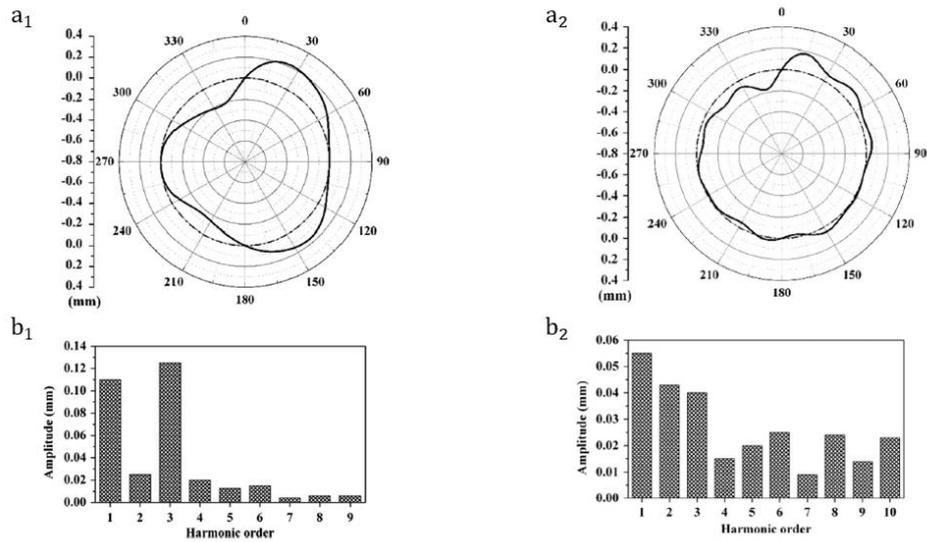


Figura 2-10 - Defeito periódico com uma amplitude de pico igual a 0.44 mm (1) e defeito não periódico com uma amplitude de pico igual a 0.35 mm: (a) gráfico em coordenadas polares; (b) distribuição harmônica (Liu e Zhai, 2014).

Nos trabalhos de Wu et al (2022) e Cai et al. (2019) foi realizada uma análise experimental sobre o mecanismo de formação de efeitos poligonais nos veículos de alta velocidade da China. De acordo com resultados obtidos, as formações de efeitos de alta ordem dependem essencialmente da velocidade de circulação, das frequências ressonantes e da geometria inicial da roda. Os resultados apresentados por Wu et al. (2022) demonstraram que as ordens dominantes dos harmônicos aumentam com o aumento da velocidade de circulação, ao contrário do estudo desenvolvido por Cai et al. (2019), em que o incremento da velocidade origina um decréscimo na ordem dos harmônicos para uma ordem inferior devido ao mecanismo de “frequência fixa”. No estudo realizado por Wu et al. (2022), os autores avaliariam experimentalmente o mecanismo de desgaste poligonal quando um eixo rodado é submetido a diversas velocidades de operação ao longo de um dado intervalo de tempo. Os autores realizaram uma análise modal numérica e experimental, com recurso ao martelo de impacto em pontos específicos de toda a roda e do eixo, permitindo estabelecer os modos de vibração da estrutura com um limite de frequência de 1000 Hz. Os rodados foram sujeitos a três diferentes condições de operabilidade (velocidade e distância percorrida) permitindo extrair os perfis de irregularidade das superfícies de rolamento antes e após a operação. Este processo é realizado com equipamento Müller-BBM desenvolvido para medir com elevada precisão a superfície das rodas ferroviárias. Os resultados obtidos permitiram analisar quais as ordens de harmônicos dominantes que se formam consoante a velocidade e a duração do movimento. A Figura 2.11 mostra os resultados obtidos quando o rodado é sujeito a percorrer diferentes distâncias com processos incrementais de aceleração e desaceleração de 3,6 km/h no intervalo de velocidade igual [220-300] km/h. Os resultados evidenciam a permanência de ordens iniciais ao longo do tempo, ao contrário

das restantes ordens, que comprometem um comportamento não linear consoante as condições a que as rodas estão sujeitas. Nos espectros apresentados são ainda realçadas com a cor verde diferentes variações do nível de irregularidade em função da distância percorrida.

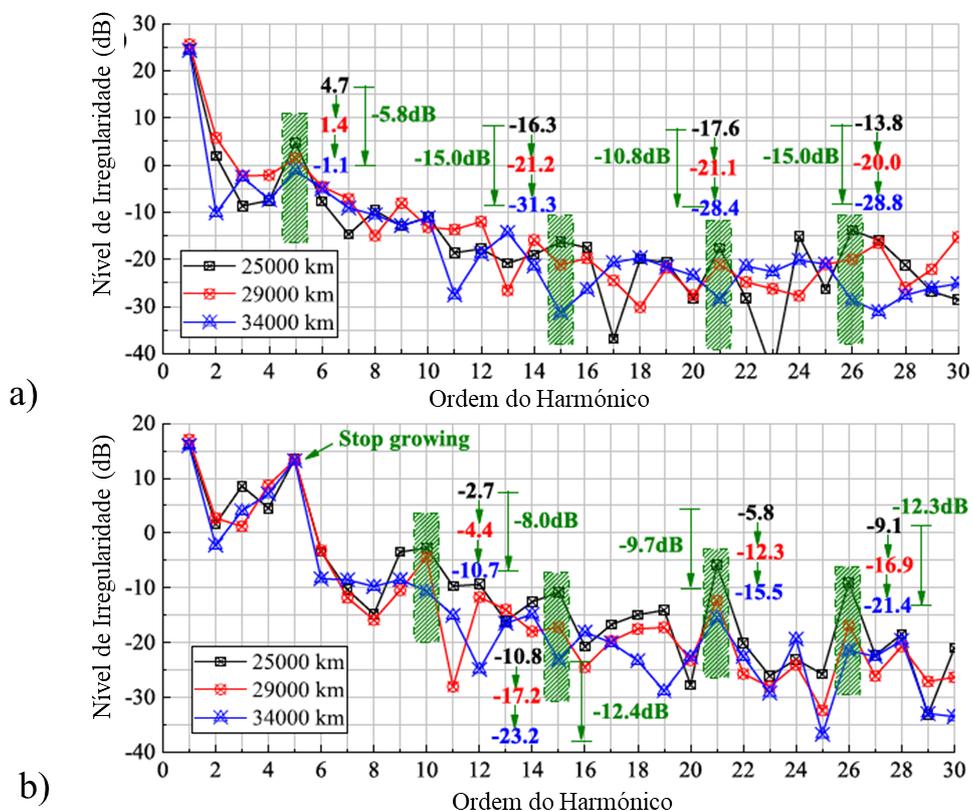


Figura 2-11 – Resultados experimentais de desgaste poligonal: (a) roda esquerda; (b) roda direita (Wu et al., 2022).

Este tipo de análises e consequentes resultados permitem perceber a importância em controlar as condições a que os rodados são sujeitos ao longo da sua vida útil. Técnicas de reperfilagem das rodas são vagamente utilizadas para remover o desgaste poligonal desenvolvido, porém nunca é totalmente eliminado, devido às variações ao longo da irregularidade que desenvolvem um novo perfil, possivelmente com amplitudes reduzidas. Através este tipo de informação é possível modelar corretamente este tipo de irregularidades de forma a serem aplicadas em simulações numéricas de forma a entender qual os fenómenos dinâmicos causados pelos diferentes tipos de ordens em diversas velocidades de circulação, prevenindo a ocorrência de efeitos ressonantes. As frequências de excitação ( $f$ ) originadas por este tipo de desgaste dependem diretamente do número de harmónicos dominante ( $N$ ), da velocidade de circulação ( $V$ ) e do raio da roda ( $R_w$ ), expressas pela equação (2-16), como indica Wu. et al (2022):

$$f = \frac{V}{2\pi R_w} \cdot N \tag{2-16}$$

**2.4.2.1 Requisitos normativos e caracterização geométrica**

Relativamente à amplitude do defeito poligonal ( $\Delta r$ ), representada graficamente na Figura 2.12, a norma EN 15313 (2016) prevê um conjunto de valores limite a considerar consoante a velocidade de circulação e o diâmetro das rodas (Tabela 2.2).

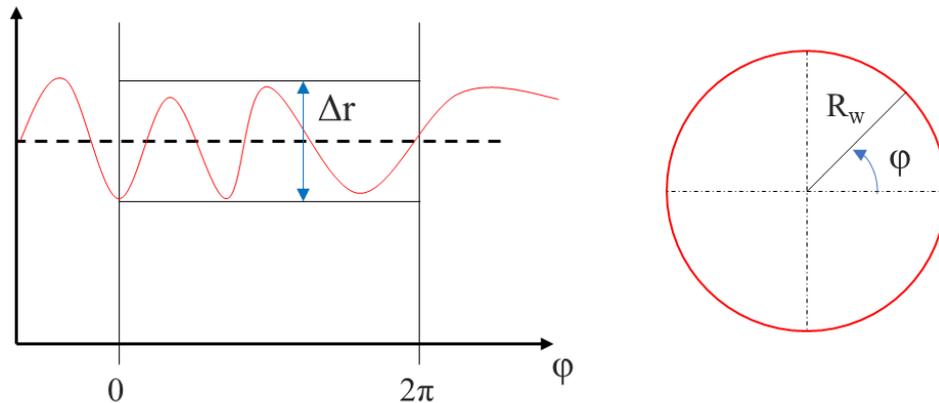


Figura 2-12 – Imperfeições circulares: excentricidade radial ( $\Delta r$ ), (Müller et al., 2013).

Tabela 2.2 - Anexo G, EN 15313 (2016): valores admissíveis para a amplitude do defeito de falta de arredondamento  $\Delta r$  (mm).

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

No contexto ferroviário, estas irregularidades manifestam-se tipicamente em 1-5 comprimentos de onda distintos em torno da circunferência que compõe a roda, apresentando amplitudes da ordem de 1 mm (Nielsen e Johansson, 2000). Diversos trabalhos desenvolvidos na literatura destacam que 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 ( $\Lambda$ ), dados por:

$$\Lambda = \frac{2\pi \cdot R_w}{\theta} \quad (2-17)$$

Onde  $\theta=1,2,3,\dots,n$  (número de harmônicos dominantes) e  $R_w$  é o raio da roda. Os perfis das rodas são caracterizados pelos comprimentos de onda nos primeiros 30 harmônicos (Guedes et al, 2023).com base na soma das funções sinusoidais ( $H = 30$ ) expressos por:

$$w(x_w) = \sum_{\theta=1}^H A_{\theta} \cdot \sin\left(\frac{2\pi}{\Lambda} \cdot x_w + \varphi_{\theta}\right), 0 \leq x_w \leq 2\pi R_w \quad (2-18)$$

Onde  $x_w$  é a distância ao longo da circunferência da roda e  $A_{\theta}$  é a amplitude da função seno para cada  $\Lambda$ , que é calculada por:

$$A_{\theta} = \sqrt{2} \cdot 10^{L_w/10} \cdot w_{ref} \quad (2-19)$$

Com  $w_{ref} = 1 \mu\text{m}$ . Os valores do nível de irregularidade da roda  $L_w$  são selecionados com base em espectros de irregularidade medidos experimentalmente (Figura 2.11). Os diferentes ângulos de fase ( $\varphi_{\theta}$ ) das funções sinusoidais são normalmente determinados aleatoriamente no intervalo 0 a  $2\pi$ .

## 2.5 METODOLOGIAS DE DETEÇÃO DE DANOS

Após a aquisição das respostas dinâmicas de um sistema, através dos dispositivos de monitorização adequados, é possível tratá-las com recurso a técnicas computacionais, métodos científicos e algoritmos, permitindo alcançar um certo nível de conhecimento do sistema monitorizado. A ciência dos dados é uma temática intrínseca à Inteligência Artificial (IA), sendo que esta última garante uma melhor compreensão e interpretação dos dados, proporcionando tomadas de decisão inteligentes baseadas nos padrões extraídos. As técnicas e os algoritmos utilizados para a tomada de decisão inteligente são cada vez mais diversificados e complexos.

De uma forma organizada e sucinta, Saraiva (2018) define inteligência artificial como “o agente que sente, raciocina, atua e adapta-se, por outras palavras, contempla qualquer técnica que permite ao computador igualar a inteligência humana”. A aprendizagem de máquina (AM), do inglês *machine learning* (ML), é um subconjunto da inteligência artificial onde se concentram os algoritmos cuja sua eficácia melhora à medida que é exposto a um maior número de dados. Dentro das técnicas de AM inclui-se a aprendizagem profunda (AP), do inglês *deep learning* (DL), composto por algoritmos baseados em redes neuronais que aprendem a executar tarefas a partir de inúmeras quantidades de dados com recurso a rotinas de treino.

Estes tipos de algoritmos têm sido amplamente usados para identificação e classificação de danos estruturais.

Com base na literatura, a presente secção dispõe de uma revisão de diferentes técnicas e metodologias aplicadas na identificação de danos estruturais. Estas abordagens de monitorização da integridade estrutural (MIE) contemplam vastas soluções para monitorizar e analisar o comportamento das infraestruturas de transporte, com recurso a diversas técnicas de IA.

### 2.5.1 Considerações iniciais

Segundo Figueiredo e Santos (2018), as técnicas inovadoras de MIE representam uma estratégia promissora que têm como objetivo potenciar a identificação de danos estruturais em estado precoce, o que possibilita uma tomada de decisão com base em ações preventivas de forma minimizar os custos das operações. Na maioria destes trabalhos, a análise de dados para a deteção de danos consiste na recolha das 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 em infraestruturas. As estratégias de identificação de danos têm sido amplamente classificadas de acordo com os cinco níveis hierárquicos de Rytter (Rytter, 1993):

- i. deteção do dano;
- ii. localização;
- iii. tipo de dano;
- iv. nível de severidade;
- v. previsão do tempo de vida útil;

Para uma correta estratégia de identificação de danos, é necessário executar um conjunto de procedimentos capazes de extrair características a partir dos dados obtidos e processá-los corretamente de forma a atingir um nível ótimo de credibilidade. Os algoritmos de ML usam métodos computacionais para “aprender” informações diretamente dos dados, sem depender de uma equação predeterminada como modelo. Os algoritmos melhoram o seu desempenho de forma adaptativa à medida que a amostragem aumenta. O ML consiste em dois tipos de técnicas: i) aprendizagem supervisionada que treina um modelo com base nos dados de entrada e saída conhecidos para que ele possa prever saídas futuras (como a classificação para encontrar uma fronteira de decisão que melhor distinga classes e a regressão para definir a equação que descreva a relação entre duas ou mais variáveis); ii) aprendizagem não supervisionada, que encontra padrões ocultos ou estruturas intrínsecas nos dados de entrada (Figueiredo e Santos, 2018). No que diz respeito à aplicação de DL, este é entendido como um processo

de modelação robusta de informações representativas dos dados por meio de aproximações mais complexas de funções e transformações lineares e não lineares. Na maioria dos métodos de DL são aplicadas as arquiteturas das redes neuronais, correntemente designadas por redes neuronais profundas. Sendo o termo “profundo” diretamente relacionado com o número de camadas ocultas da rede. A Figura 2.9 representa esquematicamente a arquitetura de uma rede neuronal, com duas camadas ocultas, cada uma delas composta por quatro neurónios.

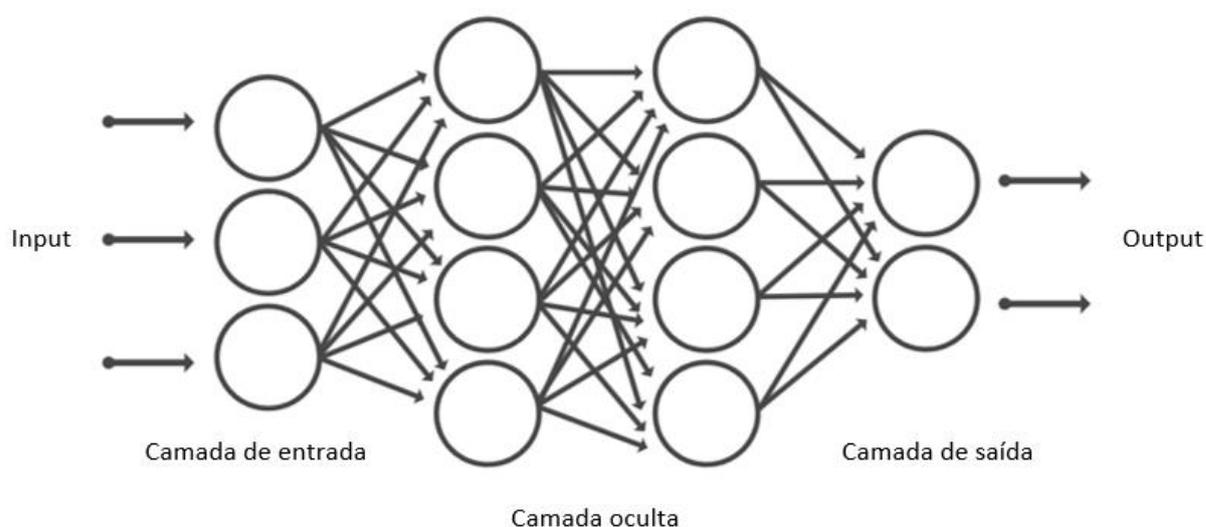


Figura 2-13 - Arquitetura de uma rede neuronal tradicional (adaptado de MATLAB, 2018)

### 2.5.2 Técnicas aplicadas

Todas as abordagens de MIE, devem ser desenvolvidas hierarquicamente por (Figueiredo e Santos, 2018):

- i. Avaliação operacional;
- ii. Aquisição de dados;
- iii. Extração de indicadores;
- iv. Modelação estatística para classificação de indicadores;

O principal objetivo deste processo passa por reconhecer e distinguir os padrões relacionados com a condição de estrutura não danificada, sob influência de condições operacionais e ambientais, daquelas associadas à mesma estrutura com condições de dano. Este processo compromete medições temporais da estrutura monitorizada de forma a avaliar o estado estrutural do sistema. As abordagens não supervisionadas para deteção de danos estruturais são desenvolvidas através da combinação de diferentes técnicas de ML. Esta combinação é muitas vezes realizada através de algoritmos com capacidade de reconhecer padrões estatísticos dos dados medidos, normalmente processados em duas etapas:

- i. Processo de aprendizagem de um modelo que compreende dados da estrutura sem características de danos, considerando quase todos os aspetos operacionais e ambientais.
- ii. Teste do modelo estabelecido com o objetivo de classificar novos dados, não utilizados em i), com ou sem a presença de danos.

Atendendo à reflexão descrita sobre as etapas envolvidas para a elaboração de uma metodologia de deteção de danos, a restante secção contempla uma revisão teórica detalhada das técnicas utilizadas na presente dissertação, assim como um apanhado das metodologias desenvolvidas na literatura.

### 2.5.2.1 Autoencoder Esperso

Em conformidade com estudos recentes, quando as metodologias de deteção de dano em sistemas estruturais são elaboradas com recurso a redes neuronais, são estabelecidas as seguintes etapas:

- i. Aquisição das respostas dinâmicas;
- ii. Pré-processamento das respostas;
- iii. Processo de treino da rede (70-80% dos dados obtidos usados nesta fase);
- iv. Previsão de respostas não treinadas, através da passagem das mesmas no ambiente da rede treinada (restantes 20-30% não treinados);

Haykin (1999), caracteriza uma rede neuronal artificial como “um processador massivo paralelamente distribuído composto por unidades de processamento simples com uma orientação natural para armazenar conhecimento experimental e torná-lo disponível para uso. Semelhante ao cérebro humano em dois aspetos: i) o conhecimento é adquirido pelo ambiente da rede através de um processo de aprendizagem; ii) as forças de conexão entre neurónios, conhecidas como pesos sinápticos, são usadas para armazenar o conhecimento adquirido.”. Um neurónio é uma unidade de processamento de informações fundamental para a operação da rede neuronal. O diagrama presente na Figura 2.14 ilustra um modelo de um neurónio artificial, identificando os três elementos básicos de um modelo neuronal: i) um conjunto de sinapses, caracterizadas individualmente por um peso  $w$ ; ii) uma função soma  $\Sigma$  para somar os inputs através de uma combinação linear; iii) uma função de ativação para limitar a amplitude do output de um neurónio. É apresentado ainda um parâmetro externo, designado por viés,  $b_k$ , que tem como principal objetivo aumentar ou diminuir o input na função ativação  $\varphi(\cdot)$  consoante o seu valor, positivo ou negativo, respetivamente.

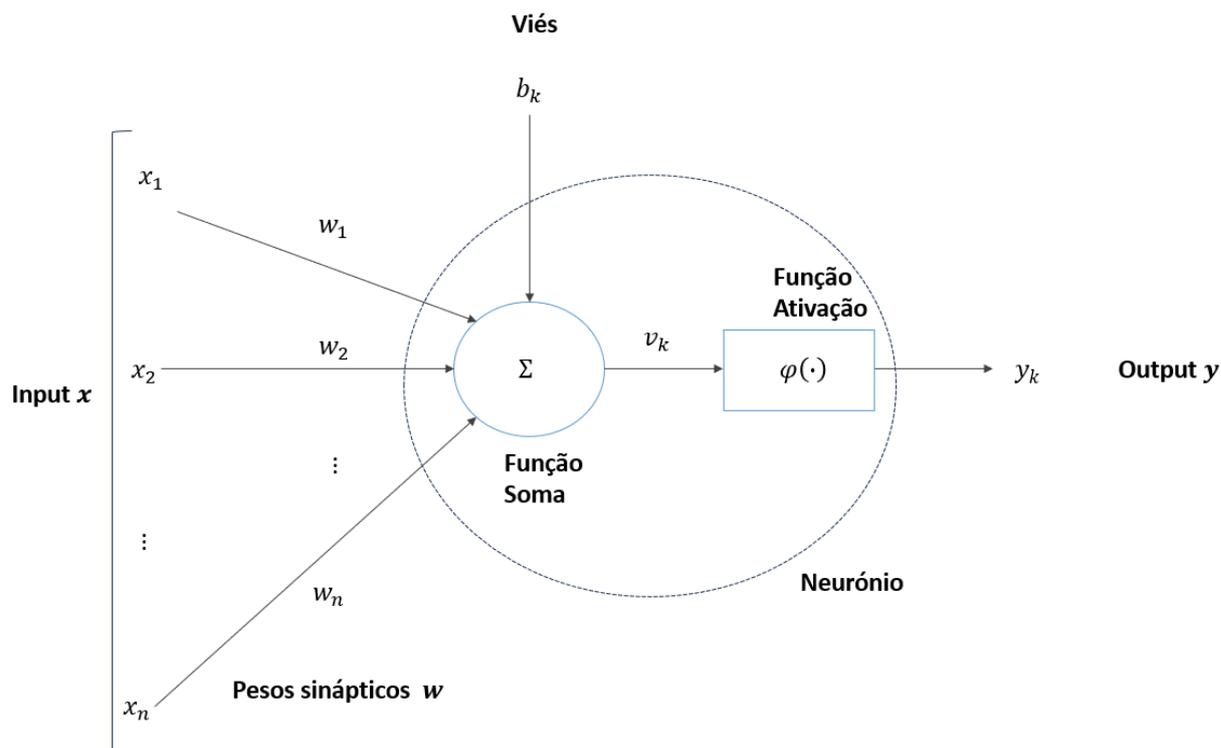


Figura 2-14 – Modelo não linear de um neurónio artificial (adaptado de Haykin, 1999)

Em termos matemáticos, um neurónio  $k$  é descrito através do seguinte par de equações, Haykin (1999):

$$u_k = \sum_{j=1}^n w_{kj} \cdot x_j \quad (2-20)$$

$$y_k = \varphi(u_k + b_k) \quad (2-21)$$

Onde  $x_1, x_2, \dots, x_n$  correspondem aos inputs, inseridos vectorialmente ou matricialmente;  $w_1, w_2, \dots, w_n$  são os pesos sinápticos de um neurónio  $k$ ;  $u_k$  é o produto entre  $w_j$  e  $x_j$ ;  $b_k$  corresponde ao viés;  $\varphi(\cdot)$  é a função de ativação; e  $y_k$  é o output do neurónio. A soma do viés  $b_k$  com o input  $u_k$  é representada por:

$$v_k = u_k + b_k \quad (2-22)$$

$$v_k = \sum_{j=0}^n w_{kj} \cdot x_j \quad (2-23)$$

Com  $x_0 = +1$  e  $w_{k0} = b_k$ , originando um output dado por:

$$y_k = \varphi(v_k) \quad (2-24)$$

As funções de ativação,  $\varphi(v)$ , vulgarmente utilizadas no processamento de uma rede neuronal, podem ser de carisma linear (i e ii) e não linear (iii e iv):

- i. Função limite:

$$\varphi(v) = \begin{cases} 1, & v \geq 0 \\ 0, & v < 0 \end{cases} \quad (2-25)$$

ii. Função linear Piecewise:

$$\varphi(v) = \begin{cases} 1, & v \geq +0.5 \\ v, & +0.5 > v > -0.5 \\ 0, & v \leq -0.5 \end{cases} \quad (2-26)$$

iii. Função Sigmoide:

$$\varphi(v) = \frac{1}{1 + e^{-v}} \quad (2-27)$$

iv. Tangente Hiperbólica:

$$\varphi(v) = \tanh v \quad (2-28)$$

Dentro das diversas tipologias de redes neuronais existentes, destacam-se os autoencoders, com a capacidade de reconhecer padrões com base em processos de treino. Este algoritmo tem como principal objetivo reconstruir os dados de entrada com a maior precisão possível. A Figura 2.15 ilustra o esquema de um autoencoder, composto por duas partes, o encoder e o decoder. O encoder é a parte da rede que compacta os dados num espaço latente, codificando-os, representado por uma função de ativação codificadora. O decoder é a parte do final do processo que tem como objetivo reconstruir os dados compactados, originando uma reconstrução dos dados, representado por uma função de ativação decodificadora (Ng, 2011).

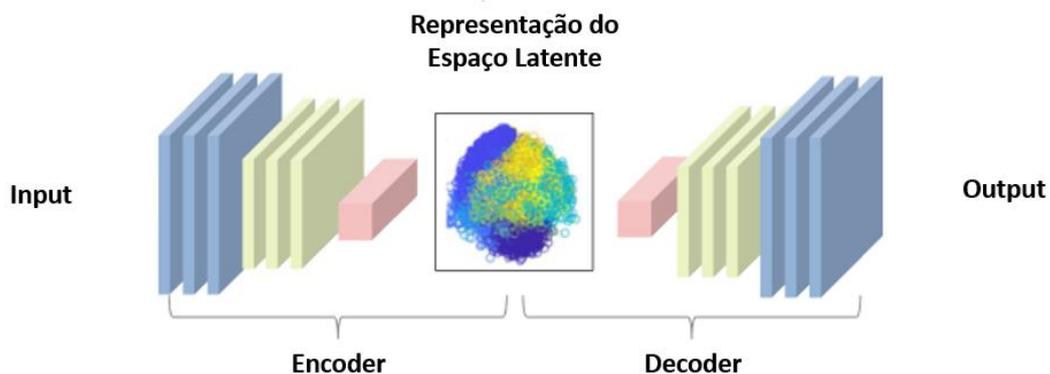


Figura 2-15 – Arquitetura geral de um autoencoder (MATLAB®, 2018)

O objetivo de um autoencoder é minimizar o erro de reconstrução, adquirindo as características consideradas necessárias para resolver um problema de decisão ou de regressão. Dado que quanto maior é o erro significa que o autoencoder não tem informação suficiente para reconstruir corretamente os dados de entrada. Por outro lado, quanto menor é o erro, melhor é a reconstrução do input, pois

apresenta as informações necessárias para tal reconstrução. Este processo possibilita que os autoencoders aprendam e retenham as informações mais importantes presentes nos dados (Ng, 2011). Existem diversos tipos de autoencoders, todos com o mesmo objetivo, mas com diferentes tipos de processamento numérico, sendo que no desenvolvimento do presente trabalho apenas foi alvo de estudo o Autoencoder Esparso (AEE). No processo de treino de um AEE, a função de encode proporciona a compactação e uma redução de dimensionalidade dos dados. Em geral, a dimensionalidade da camada oculta é menor que a camada de entrada. No entanto, para os casos em que a camada de entrada apresenta uma dimensão reduzida, a camada oculta deve ser maior que a camada de entrada (Wang et al., 2023).

Atendendo à formulação matemática que caracteriza o processamento do neurónio, é possível caracterizar de forma equivalente o processamento do AEE. Tendo em conta que este tipo de rede se processa por duas etapas, é conveniente perceber que ocorre uma transformação intermédia entre as variáveis de cada neurónio  $k$ . Isto é, o input  $x_j$  é codificado para  $y_k$  e posteriormente decodificado originando o output final dado por  $\hat{x}_j$ . Sendo na fase de codificação do input que se realiza uma normalização dos dados de entrada. Neste tipo de rede neuronal, o processo de encode e decode em cada neurónio  $k$  de cada camada oculta é dado por:

$$y_k = \varphi(v_k) \quad (2-29)$$

$$y_k = \varphi \left( \sum_{j=1}^n w_{kj} \cdot x_j + b_{kj} \right) \quad (2-30)$$

$$\hat{x}_j = \varphi' \left( \sum_{k=1}^n w'_{kj} \cdot y_k + b'_{kj} \right) \quad (2-31)$$

Onde  $n$  é o número de elementos do input,  $x_j$  é o  $j$ -ésimo elemento do input original e  $\hat{x}_j$  é o respetivo  $j$ -ésimo elemento reconstruído;  $w_k$ ,  $w'_k$ ,  $b_k$ ,  $b'_k$  e  $\varphi$ ,  $\varphi'$  são as matrizes de peso, os vetores correspondentes ao viés e as funções de ativação para o encode e decode, respetivamente.

O número de épocas (iterações) de um processo de treino permite ajustar os pesos e o viés ao longo do processo. Nesse período o autoencoder tenta aprender uma representação compacta na camada oculta ( $y_k$ ), permitindo-lhe reconstruir os dados de entrada com o menor erro possível (Meng et al., 2017). Um autoencoder esparso é uma variante do autoencoder original que inclui uma restrição de dispersão nas ativações da camada oculta. A restrição de dispersão incentiva o autoencoder a aprender uma representação mais concisa e esparsa dos dados de entrada. Matematicamente, a principal diferença do autoencoder esparso está no termo de regularização adicionado à função de custo para impor a restrição de esparsidade (Olshausen e Field, 1997). Sendo que a atualização dos pesos ( $w$ ) e do viés ( $b$ ) é realizado

através da minimização do erro, iniciando-se com valores aleatórios. A adição de parâmetros regularizadores à função de custo, permite obter outro tipo de informações aquando da compressão no espaço latente (MATLAB®, 2018):

$$E = \frac{1}{n} \sum_{j=1}^n \sum_{k=1}^K (x_{kj} - \hat{x}_{kj})^2 + \lambda \cdot \Omega_{\text{pesos}} + \beta \cdot \Omega_{\text{esparsidade}} \quad (2-32)$$

Sendo que a primeira parcela da expressão corresponde ao erro médio quadrático, que representa a função de custo de grande parte das redes neuronais; a segunda à regularização dos pesos,  $\Omega_{\text{pesos}}$ , afetada de um coeficiente  $\lambda$ , designado por regularizador dos pesos; a terceira parcela representa a regularização de esparsidade,  $\Omega_{\text{esparsidade}}$ , afetada de um coeficiente  $\beta$ , caracterizado pelo regularizador de esparsidade. Para cada camada oculta da rede, os regularizadores são dados por:

$$\Omega_{\text{pesos}} = \frac{1}{2} \sum_{j=1}^n \sum_{k=1}^K (w_{kj})^2 \quad (2-33)$$

$$\Omega_{\text{esparsidade}} = \sum_{k=1}^K KL(\rho | \hat{\rho}_j) \quad (2-34)$$

$$\Omega_{\text{esparsidade}} = \sum_{k=1}^K \rho \cdot \log\left(\frac{\rho}{\hat{\rho}_j}\right) + (1 - \rho) \cdot \log\left(\frac{1 - \rho}{1 - \hat{\rho}_j}\right)$$

A regularização da esparsidade é realizada com recurso à função de divergência de Kullback-Leibler (KL), que permite determinar a diferença entre duas distribuições, assumindo valor nulo quando  $\rho = \hat{\rho}_j$ . Sendo  $\rho$  caracterizado pela proporção de esparsidade, que permite controlar a atividade dos neurónios  $k$  na camada oculta. Por exemplo quando  $\rho = 0.01$ , significa que apenas 1% dos neurónios estão ativados (Wang, et al., 2023). Já  $\hat{\rho}_j$  corresponde à medida média do output de um neurónio  $k$ , definida por:

$$\hat{\rho}_j = \frac{1}{n} \sum_{j=1}^n \varphi_e(w_k^T \cdot x_j + b_k) \quad (2-35)$$

Wang et al. (2023b) indicam que o (AEE) deve ser escolhido para aprender características presentes nos dados, em comparação com os autoencoders automáticos comuns, visto que o AEE permite obter melhores resultados, devido às restrições de esparsidade. Por analogia com o mecanismo do cérebro humano, quando o cérebro é estimulado por um determinado estímulo, a maioria dos neurónios são inibidos, logo torna-se evidente que um pequeno número de neurónios  $k$  poderá originar uma melhor extração das características essenciais dos dados.

### 2.5.2.2 Extração de indicadores

O processo de extração de indicadores consiste em transformar os dados recolhidos num certo espaço dimensional num outro espaço de dimensão reduzida, contendo características que poderão evidenciar a presença de dano nos dados iniciais. Por outras palavras, uma característica sensível a danos remete a alguma quantidade extraída das respostas estruturais que estão correlacionadas com a presença de danos nos elementos (parâmetros modais, deformações quase estáticas e flexões locais).

De acordo com Figueiredo e Santos (2018), durante a etapa de extração de indicadores, é crucial obter características que estejam correlacionadas com a gravidade dos danos detetados na monitorização das estruturas, com o propósito de reduzir a ocorrência de falsas avaliações nas fases procedentes de classificação. Dado que um indicador de dano se altera à medida que o nível do dano aumenta, presume-se que a distinção entre uma estrutura danificada e uma não danificada seja realizada com uma boa precisão. Estes índices podem ser garantidos com base no ajuste de algum modelo, seja físico ou baseado em dados, aos dados de resposta dinâmica obtidos. Os parâmetros dos modelos, ou os erros preditivos associados a estes, tornam-se evidentemente sensíveis a danos. Ainda assim, é possível identificar características que comparem diretamente as formas de onda extraídas dos sensores (linhas de influência e séries temporais) ou espectros dessas formas de onda (densidade de espectro de potência) medidos em cenários de dano e sem dano (Guedes, 2022).

Em aplicações de MIE, os efeitos ambientais podem transpor-se a efeitos relacionadas com os danos, assim como alterar a correlação entre a magnitude dos indicadores e o nível de dano. Normalmente, quanto mais sensível for um indicador, mais sensível será às mudanças das condições operacionais e ambientais (temperatura, vento e velocidade de circulação). Para combater estes fenómenos, as propriedades primárias dos indicadores de danos são:

- Sensibilidade: um recurso deve ser sensível a danos e completamente insensível a todo o resto, o que raramente ocorre em aplicações práticas de MIE.
- Dimensionalidade: um vetor de indicadores deve ter a dimensão mais baixa possível; uma grande dimensionalidade induz complexidade indesejável no modelos estatísticos e mecanismos de armazenamento.
- Requisitos computacionais: suposições mínimas e processador com ciclos reduzidos, proporcionando um eficiente processamento.
- Consistência: a magnitude dos indicadores deve mudar monotonamente com nível de dano.

### 2.5.2.3 Fusão dos dados

As técnicas de fusão dos dados possibilitam a redução dimensional preservando a informação relevante contida nos dados, caracterizando-se por um processo de combinação de informações de vários indicadores, da mesma natureza ou de natureza distinta, de forma a aumentar a confiabilidade do fenómeno medido. O processo de fusão dos dados permite combinar indicadores relativamente a várias fontes, como por exemplo a informação contida em vários sensores distribuídos ao longo do espaço e até os mesmos indicadores relativos a grandezas físicas distintas (Meixedo et al., 2021b; Meixedo et al., 2021a).

Dentro do conjunto das técnicas aplicadas na deteção de danos, destaca-se a distância de Mahalanobis, que consiste numa fusão de indicadores que mede a distância entre indicadores sem dano e indicadores sensíveis a danos. A distância de Mahalanobis é genérica o suficiente para ser usada para detetar qualquer cenário de dano, sem necessidade de intervenção humana, consistindo numa ponderação do indicador de dano em que os pesos são determinados pela estrutura da covariância. Além disso, e mais importante, a ponderação proporcional à estrutura de covariância fornece uma camada adicional de modelagem de indicadores que, quando definida para ações regulares, permite delinear com alta sensibilidade aqueles que não foram utilizados para a definição da estrutura de covariância (Meixedo, 2021). A fim de expressar a semelhanças entre os indicadores (com e sem dano), distâncias mais curtas representam uma maior semelhança entre os dados e vice-versa, o que permitirá evidenciar os indicadores com dano. A expressão analítica da distância de Mahalanobis ( $DM$ ) para cada simulação  $i$ , caracterizada por  $DM_i$ , é dada por:

$$DM_i = \sqrt{(t_i - \bar{t}) \cdot S_x^{-1} \cdot (t_i - \bar{t})^T} \quad (2-36)$$

Onde  $t_i$  é a matriz que representa os indicadores com potenciais danos,  $\bar{t}$  é a matriz com a média dos indicadores estimados nos cenários sem dano e  $S_x$  é a matriz de covariância dos indicadores relativos a cenários sem dano.

Este tipo de técnica tem sido amplamente utilizado em diversos trabalhos de deteção de danos estruturais (Mosleh et al. 2021a; Meixedo et al., 2022b, Mosleh et al. 2022b, Mohammadi et al. 2023; Mosleh et al., 2023; Guedes et al., 2023; Silva et al., 2023). Ainda assim, existem outros tipos de técnicas de fusão de dados correntemente utilizados na literatura, como por exemplo a distância euclidiana e a distância de Manhattan (Talaie et al. 2023).

### 2.5.2.4 Discriminação dos dados

A discriminação de indicadores contempla a categorização dos mesmos em cenários de dano e sem dano. Dado que as análises de séries temporais permitem um correto tratamento dos dados de forma a destacar a existência de diferentes comportamentos estruturais dentro de um conjunto de dados, torna-se

indispensável o desenvolvimento de estratégias de MIE para destacar esses diferentes comportamentos. Os algoritmos de ML com capacidade de decisão autónoma possibilitam a identificação dos demais comportamentos a partir dos padrões extraídos pelos indicadores. Assim sendo, nesta secção são abordados os algoritmos de decisão não supervisionados, correntemente utilizados na deteção de danos estruturais. Primeiramente procede-se a uma avaliação da existência do dano, pelo que, habitualmente, é imposto um limite com base nos dados que contenham informações não correlacionadas com o dano (Meixedo, 2021; Prawin e Bhaskara, 2023). Após essa distinção é possível classificar os dados com base na sua natureza com recurso a técnicas de agrupamento automático dos dados, denominado de técnicas de clusters (Wang et al., 2023; Silva et al. 2023).

#### 2.5.2.4.1 Deteção de danos - Análise de Ouliers

Esta técnica de análise de dados 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. O funcionamento deste tipo de ferramenta permite demonstrar se um determinado comportamento do sistema é por consequência de uma condição normal ou anormal de operação (Guedes, 2022). Com isto, é possível estabelecer uma comparação entre ambos os cenários e determinar se existe algum tipo de excentricidade por parte do sistema. Para tal, é vulgarmente utilizado um limite de confiança estatístico (*CB - confidence boundary*), baseado na função de distribuição cumulativa inversa gaussiana (ICDF), de forma a discriminar automaticamente cada indicador de dano. Devido à sua simplicidade e eficiência, esta técnica de análise de dados é amplamente utilizada em diversos trabalhos. O *CB* é calculado considerando o valor médio ( $\bar{\mu}$ ) e o desvio padrão ( $\sigma$ ) do vetor dos indicadores correspondentes aos cenários normais de circulação:

$$CB = invF_x(1 - \alpha) \quad (2-37)$$

Onde:

$$F(x|\bar{\mu}, \sigma) = \frac{1}{\sigma \cdot \sqrt{2\pi}} \int_{-\alpha}^x e^{-\frac{1}{2} \cdot \left(\frac{x-\bar{\mu}}{\sigma}\right)^2} dy, x \in \mathbb{R} \quad (2-38)$$

Consequentemente, quando o ID obtido é igual ou superior a *CB*, o indicador é denominado como um outlier.

#### 2.5.2.4.2 Classificação do dano – Análise de Clusters

A principal função da análise de agrupamento (*clustering*) é agregar os dados com alta similaridade e separar os dados com baixa homogeneidade, correntemente designado por divisão da estrutura dos dados. Esta divisão do conjunto de dados é efetuada através da formação de *k* clusters de acordo com a proximidade dos dados num conjunto  $N \times D$ , sendo *N* o número de amostras e *D* a dimensão dos dados (Hu

et al., 2023). O agrupamento dos dados em  $k$  clusters é determinado com base em distâncias vetoriais entre os diferentes  $N$  elementos (Mosleh et al., 2022a).

No trabalho realizado por Hu et al. (2023) foi realizada uma análise de sensibilidade a diferentes algoritmos de agrupamento, tais como o  $k$ -means,  $LK$ -means,  $XK$ -means,  $DDK$ means e  $Canopyk$ -means. Os resultados apresentados pelos autores demonstraram uma melhor aquisição de resultados com aplicação do algoritmo  $LK$ -means. Porém, alguns dos algoritmos avaliados compõem uma combinação híbrida entre o  $k$ -means e outras funções matemáticas que possibilitam melhorias no agrupamento de dados e no processo iterativo do algoritmo. Para Mosleh et al. 2022a), o processo de agrupamento com recurso ao  $k$ -means é amplamente utilizado devido ao seu princípio simples e alta eficiência, caracterizando-se por uma técnica de aprendizado de máquina não supervisionada correntemente aplicada na literatura para o processamento de sinais. O objetivo do clustering  $k$ -means é dividir  $N$  dados em  $k$  clusters, onde cada dado pertence ao cluster mais próximo, consoante a distância ao centro de cada cluster, designado como centroide. O algoritmo  $k$ -means é definido da seguinte forma: dada a matriz dos dados  $N \times D$  e uma série de  $k$  clusters arbitrários, a ideia é encontrar  $k$  centroides que minimizem a distância de cada vetor ao seu centroide mais próximo. Para calcular  $k$ -médias, devem ser consideradas as seguintes etapas:

- i. Escolha aleatória de  $k$  centroides do conjunto matricial dos dados;
- ii. Extração vetorial dos dados de entrada;
- iii. Atribuição de cada vetor ao centroide mais próximo;
- iv. Cálculo de novos centroides a partir dos clusters previamente formados.

Por outras palavras, em conformidade com Hu et al. (2023), dada uma amostragem  $(x_1, x_2, \dots, x_N)$ , em que cada amostra corresponde a um vetor real de dimensão  $D$ , o agrupamento  $k$ -means subdivide as  $N$  observações em  $k$  grupos ( $k \leq N$ ) definindo-se os grupos  $S = S_1, S_2, \dots, S_k$  de modo a minimizar a soma dos quadrados dentro do cluster, ou seja, a variância. Formalmente, o objetivo é encontrar:

$$\arg \min = \sum_{i=1}^k \sum_{x \in S_i} \|x - u_i\|^2 = \arg \min \sum_{i=1}^k |S_i| \text{Var}(S_i) \quad (2-39)$$

Onde  $\mu_i$  é a média dos pontos em  $S_i$ . Dado que durante o cálculo do agrupamento,  $u_i$  é usado como centro do cluster (centroide) para o cálculo da distância vetorial, gradualmente otimizado iterativamente. Este algoritmo tem sido amplamente utilizado em diversos trabalhos de deteção de danos (Meixedo, 2021; Mosleh et al., 2022a; Silva et al., 2023).

De forma a entender melhor a capacidade do algoritmo  $k$ -means, foi avaliado o estudo feito por Akhter e Mohanty (2023) com o objetivo de perceber a sua sensibilidade face aos diversos dados a que poderão estar sujeitos. Os investigadores desenvolveram um algoritmo de agrupamento híbrido baseado em duas

etapas, uma composta por repartições balanceadas de algoritmos de agrupamento e outra pela fusão das diferentes repartições. Este tipo de estratégia definida permite reduzir o processamento computacional aumentando assim a sua eficiência e mantendo a qualidade do agrupamento automático. Através dos resultados apresentados, o algoritmo de cluster que atinge uma melhor performance é o algoritmo proposto pelos autores. Uma vez que a etapa de repartições balanceadas evidencia os *subclusters* através da dispersão dos dados ao longo das diferentes dimensões, e na etapa da fusão são usadas técnicas de gráficos semelhantes para fundir as repartições. A Figura 2.16 apresenta somente os resultados obtidos com o algoritmo *k-means* para quatro conjuntos de dados numéricos analisados (S1, S2, S3 e S4), diferindo-se em termos de forma, tamanho, geometria e nível de dispersão. No conjunto S1 (Figura 2.16a) existem três clusters com diferentes densidades e alguns ruídos. O principal desafio com este conjunto de dados foi conseguir formar clusters tendo em conta uma dispersão dos dados relativamente à forma, tamanho e densidade, presenciando-se uma má classificação. Relativamente ao conjunto S2 (Figura 2.16b), este contém quatro clusters ligeiramente próximos com densidades variadas, incluindo ruído, observando-se uma enorme dificuldade em formar corretamente os quatro diferentes grupos. Para o conjunto S3 (Figura 2.16c) são apresentados três clusters separados por uma distância significativa, um tem a forma de meia-lua, enquanto os outros dois apresentam uma retangularidade. Neste conjunto de dados realça-se a impossibilidade de produzir clusters apropriados devido à incapacidade de localizar com precisão os centroides. Por fim, o conjunto S4 (Figura 2.16d) é composto por quatro clusters, aparentemente circunferenciais, com a presença de alguns ruídos, destacando-se a dificuldade em agrupar corretamente os quatro grupos distintos. Com esta reflexão é possível perceber que quanto mais próximos estiverem os dados de um centroide e quanto mais afastados tiverem os diferentes centroides, maior será a eficácia do algoritmo *k-means*.

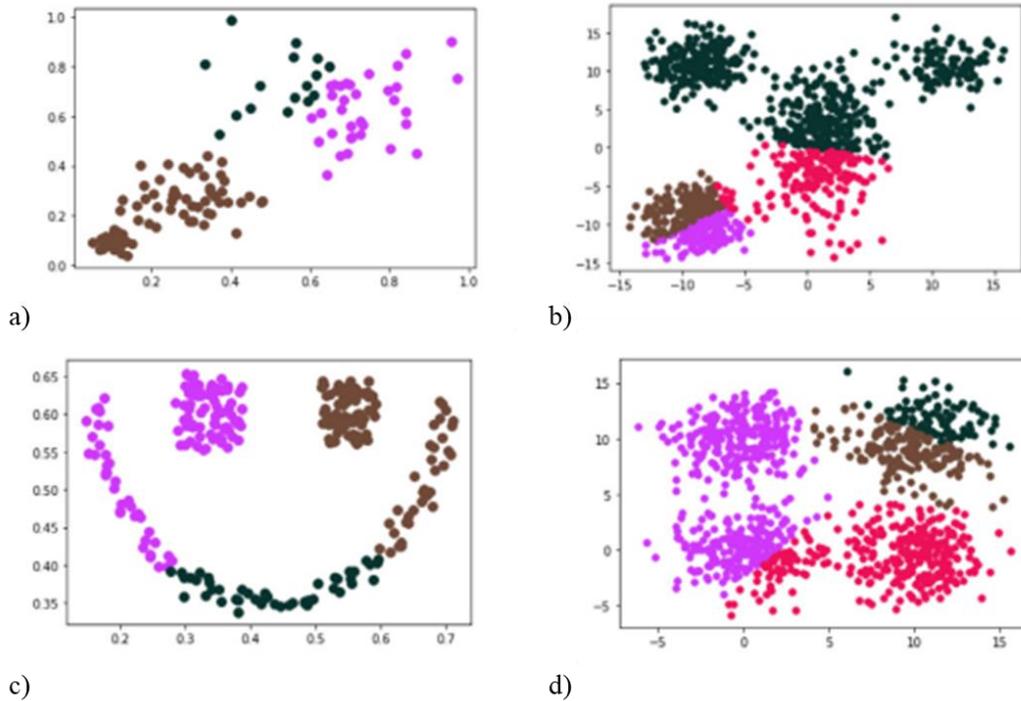


Figura 2-16 – Aplicação da técnica de *clustering* com o algoritmo *k-means* (Akhter e Mohanty ,2023):  
 a) conjunto de dados S1 com  $k=3$  clusters; b) conjunto de dados S2 com  $k=4$  clusters;  
 c) conjunto de dados S3 com  $k= 3$  clusters; d) conjunto de dados S4 com  $k=4$  clusters.

### 2.5.3 Metodologias desenvolvidas na literatura

Meixedo (2021) desenvolveu um algoritmo em ML que consiste numa combinação híbrida de métodos de análise de séries temporais e técnicas estatísticas multivariadas. A estratégia de MIE não supervisionada desenvolvida pela autora permite detetar danos em pontes ferroviárias com base nas respostas de acelerações induzidas pelos veículos. A metodologia envolve as seguintes etapas:

- i. Extração de indicadores: Processo de transformação dos dados temporais adquiridos em informação alternativa com evidente correlação com o dano.
- ii. Normalização dos indicadores: Técnica que previne a presença de falsos indicadores de dano devido aos efeitos ambientais (temperatura) e operacionais (velocidade de circulação) que poderão induzir variações maiores do que os cenários de dano.
- iii. Fusão de indicadores: Estratégia que permite reduzir o volume dos dados de modo a serem preservadas características relevantes, alcançando-se assim um tipo de informação mais concentrada.
- iv. Classificação dos indicadores: Etapa final do processo que envolve uma classificação binária dos dados analisados, classe sem dano e classe com dano.

A Figura 2.17 apresenta esquematicamente as diferentes fases da metodologia juntamente com o tipo de técnicas utilizada em cada etapa.

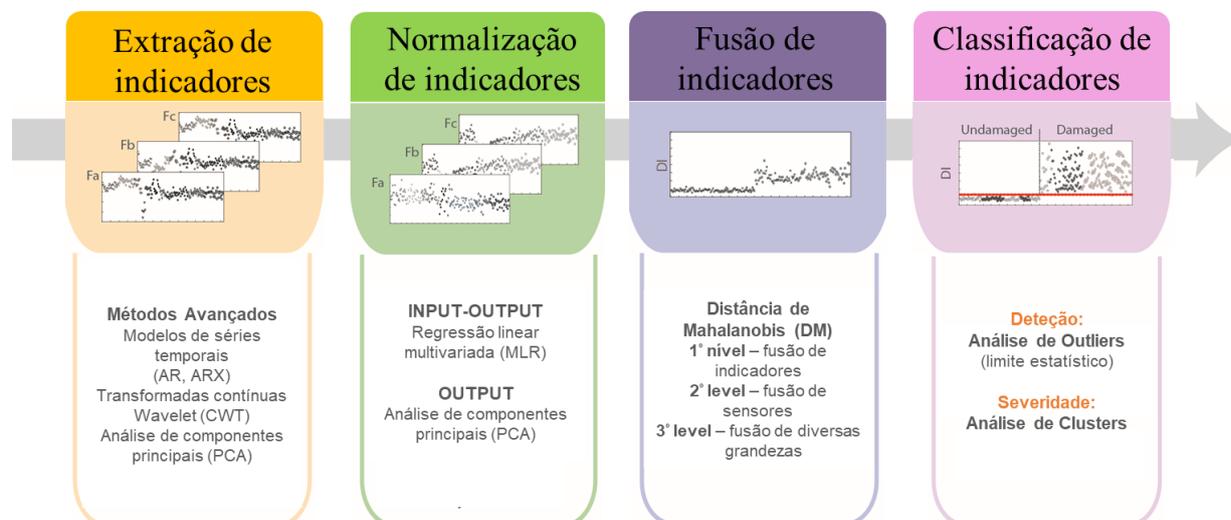


Figura 2-17 - Fluxograma da metodologia desenvolvida por Meixedo (2021) (adaptado de Meixedo, 2021).

Diversos autores adaptaram a metodologia desenvolvida por Meixedo (2021) de forma a detetar diferentes defeitos geométricos ao nível das rodas e identificar desequilíbrio de cargas nos veículos de transporte de mercadorias. As respostas dinâmicas numéricas utilizadas em cada um dos estudos seguidamente mencionados foram obtidas através do método de interação dinâmica roda-carril desenvolvido por Montenegro (2015), descrito na secção 2.3.3. As metodologias regem-se todas pelo mesmo seguimento na perspetiva das diversas etapas que as compõe, divergindo-se nas técnicas utilizadas em cada etapa de forma a serem atingidos os objetivos propostos. Numa reflexão global de todas as metodologias, uma possível agregação das mesmas corresponde a uma ferramenta em ML com um enorme potencial para a deteção de diversos tipos de anomalias correntes na circulação ferroviária.

Em Guedes et al. (2023) a metodologia foi adaptada de forma a detetar a presença de rodas com desgaste poligonal. O principal objetivo do estudo foi comparar o desempenho entre duas das técnicas de extração de indicadores, nomeadamente o modelo exógeno autorregressivo (ARX) e transformada contínua de wavelet (CWT). Com os resultados obtidos foi realizada uma análise de sensibilidade para averiguar a influência do número de sensores e da sua localização na precisão do sistema de deteção dos defeitos poligonais. Nos trabalhos desenvolvidos por Mosleh et al. (2023) e Mohammadreza et al. (2023) o estudo consistiu em adequar a metodologia para detetar a presença de superfícies lisas nas rodas dos veículos. Em Mosleh et al. (2023), a extração de indicadores foi executada com recurso um modelo autorregressivo (AR), sendo avaliado a influência do número de sensores usados para detetar e classificar os diferentes tipos de lisos modelados. No estudo realizado por Mohammadi et al. (2023) foram comparadas quatro técnicas de extração de indicadores, modelo autorregressivo (AR), modelo exógeno autorregressivo

(ARX), análise de componentes principais (PCA) e transformada contínua de wavelet (CWT). O autor concluiu que os métodos de extração AR e ARX são técnicas mais eficientes do que CWT e PCA para detecção superfícies planas nas rodas dos veículos, sendo que em todas as técnicas a presença de um sensor é suficiente para a detecção de dano. Silva et al. (2023) ajustou a metodologia de forma a ser capaz de identificar automaticamente o desequilíbrio transversal e longitudinal de cargas verticais, com base nas respostas de acelerações verticais e nas respostas de extensões. Neste estudo, o autor comparou o desempenho de duas técnicas de extração de indicadores, modelo exógeno autorregressivo (ARX) e análise de componentes principais (PCA). Os resultados apresentados comprovam que a metodologia é capaz de detetar e classificar com precisão desequilíbrios longitudinais e transversais com um número reduzido de sensores.

Em Ye et al. (2022) foi elaborada uma técnica com recurso a uma rede neuronal profunda para detetar efeitos poligonais nas rodas de veículo ferroviário de alta velocidade. O desempenho da rede neuronal foi testado com recurso a uma base de dados que contempla simulações de respostas de acelerações verticais do rodado, obtidas para 2000 diferentes perfis de irregularidade poligonal previamente gerados aleatoriamente. Destes 2000 perfis obtidos, foram usados 70% para a fase de treino e os restantes 30% para a fase de teste, com o principal objetivo de identificar as passagens com dano, sendo considerado dano as passagens que apresentem perfis de irregularidade superiores a um perfil limite. Os autores concluíram que a rede neuronal é extremamente sensível à velocidade de circulação dos veículos devido à relação existente entre esta e a ordem do harmónico dominante de cada perfil de irregularidade. Num outro trabalho, Ye et al. (2023), o mesmo autor desenvolveu uma metodologia híbrida que permite identificar a presença de lisos nas rodas de veículos ferroviários com base nas respostas dinâmicas obtidas num sistema *onboard*. A metodologia desenvolvida pelos autores combina um método de extração de indicadores com recurso a imagens de domínio temporal ativada (ATDI) com um método baseado numa rede neuronal profunda (DNN) para reconhecimento de padrões. A metodologia foi aplicada a passagens experimentais com diferentes velocidades de circulação permitindo concluir que o modelo ATDI-DNN treinado com uma certa amostragem de velocidades possa ser aplicado diretamente a velocidades não presentes na amostragem. Sarwar e Cantero (2021) desenvolveram um método com recurso a uma ferramenta de DL que permite determinar anomalias numa ponte rodoviária. Este método utiliza as respostas dinâmicas da ponte induzidas pelos veículos para treinar um modelo de autoencoder profundo de forma a extrair indicadores sensíveis a danos na ponte. A técnica para detecção de danos proposta pelos autores compreende principalmente três fases: i) obtenção das respostas de aceleração vertical de diversos tipos de veículos; ii) os dados adquiridos são usados para treinar um autoencoder profundo de forma a extrair indicadores sensíveis à presença do dano. iii) modelo DAE treinado é usado para calcular o erro de reconstrução das respostas de veículos não usadas na fase do treino.

## CAPÍTULO 3

### MODELAÇÃO NUMÉRICA

Este capítulo apresenta uma descrição dos modelos dinâmicos utilizados no âmbito da presente dissertação, compreendendo o material circulante, a via e a interação dinâmica entre estes sistemas. A modelação de um veículo, do comboio Alfa-Pendular, e da via (balastro, travessas, palmilhas, carril) foi realizada com recurso ao programa ANSYS® (2018). Já as irregularidades da via e os defeitos geométricos das rodas são simulados através do MATLAB® (2018), assim como a própria interação dinâmica entre os dois sistemas.

#### 3.1 MODELAÇÃO DE UM VEÍCULO DO COMBOIO ALFA PENDULAR

O comboio CP série 4000, conhecido, em Portugal, por Alfa Pendular, tem um comprimento total de 158,9 m e pode atingir a velocidade máxima de 220 km/h, permitindo a realização de trajetos de norte a sul do território nacional. Trata-se de um comboio elétrico com sistema de pendulação ativa constituído por seis veículos, quatro motores (BAN, BBN, BBS e BAS) e dois reboques (RNH e RNB) (Ribeiro, 2012). Este sistema de pendulação permite a circulação do veículo a velocidades mais elevadas devido à redução dos efeitos da força centrífuga, através de um sistema mecânico que permite a inclinação do comboio nas curvas. Na Figura 3.1 apresenta-se uma perspetiva do comboio Alfa Pendular com a identificação de todos os veículos.



Figura 3-1 - Comboio Alfa Pendular 4000 (Fonte: Silva, 2018)

Os veículos BBN, RNH, RNB e BBS são geometricamente equivalentes e detêm de uma maior capacidade de carga comparativamente com o BAN e BAS (Figura 3.1). Dado esse pormenor, o veículo utilizado como base para a modelação do comboio completo é um veículo BBN, replicando-se seis vezes no desenvolvimento do modelo numérico do comboio. A Figura 3.2a ilustra uma perspetiva longitudinal do veículo BBN e a Figura 3.2.b uma perspetiva transversal, onde as respetivas dimensões são legendadas na Tabela 3.1.

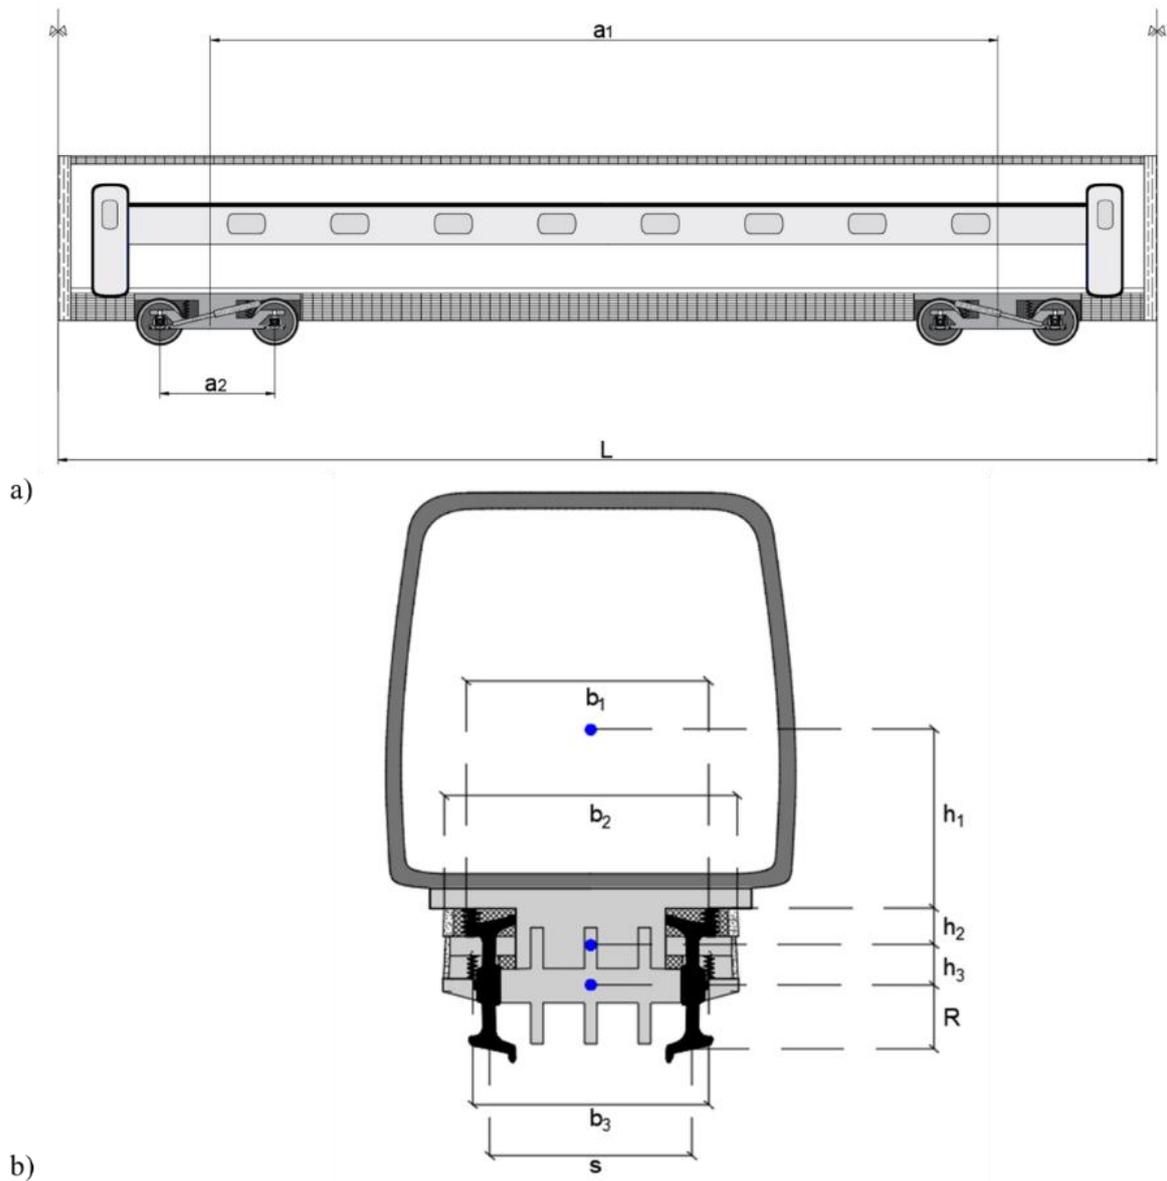


Figura 3-2 - Geometria do veículo BBN: a) perspetiva longitudinal; b) perspetiva transversal

Tabela 3.1 - Propriedades geométricas do modelo numérico de um veículo do comboio Alfa pendular (Mosleh et al., 2021a).

Parâmetros	Unidades	Valor
Comprimento total do veículo	L (m)	25,000
Distância Longitudinal entre bogies	$a_1$ (m)	19,000
Distância Longitudinal entre eixos	$a_2$ (m)	2,700
Distância transversal entre as suspensões secundárias verticais	$b_1$ (m)	2,144
Distância transversal entre as suspensões secundárias longitudinais	$b_2$ (m)	2,846
Distância transversal entre as suspensões primárias	$b_3$ (m)	2,144
Distância vertical entre o centro da caixa e a suspensão secundária	$h_1$ (m)	0,936
Distância vertical entre o centro do bogie e a suspensão secundária	$h_2$ (m)	0,142
Distância vertical entre o centro do bogie e o centro dos rodados	$h_3$ (m)	0,065
Diâmetro da roda	R (m)	0,430
Distância transversal entre rodados	S (m)	1,670

O modelo dinâmico do veículo é desenvolvido como um modelo de associação de corpos rígidos com elementos de mola-amortecedor para simular as suspensões (primária e secundária) em todas as direções e elementos de massa pontual para representar a massa e os efeitos de inércia no centro de gravidade da caixa. Todos os corpos incluídos na modelação são ligados por elementos de viga. O modelo do veículo utilizado no presente caso de estudo é o modelo desenvolvido no trabalho de Montenegro et al. (2015). Na Figura 3.3 é apresentado o esquema do modelo numérico tridimensional do veículo, incluindo a localização das várias suspensões e os parâmetros que as definem em termos de rigidez,  $k$ , amortecimento,  $c$ , massa,  $m$ , e inércia,  $I$ . Os valores dos parâmetros relativos às grandezas dinâmicas utilizadas para a respetiva modelação constam na Tabela 3.2.

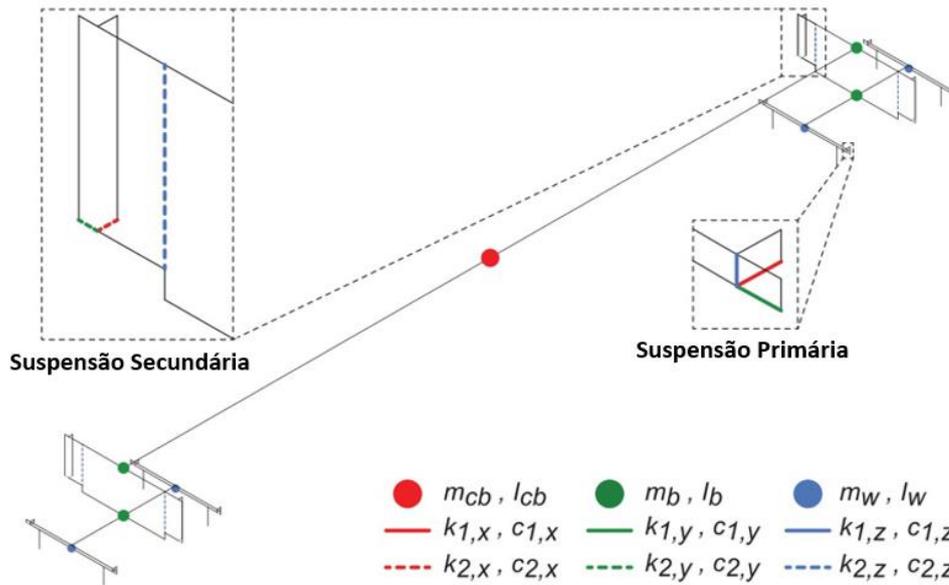


Figura 3-3 - Modelo numérico em elementos finitos do veículo BBN (Saramago et al. (2022)).

Tabela 3.2 – Propriedades mecânica do modelo numérico do veículo BBN do comboio Alfa pendular (Mosleh et al., 2021a).

Elemento	Parâmetros	Unidades	Valor
Caixa	Massa da caixa	$m_c$ (kg)	3,56E+04
	Momento de inércia xx	$l_{c,x}$ (kg.m <sup>2</sup> )	5,51E+04
	Momento de inércia yy	$l_{c,y}$ (kg.m <sup>2</sup> )	1,48E+06
	Momento de inércia zz	$l_{c,z}$ (kg.m <sup>2</sup> )	1,48E+06
Bogie	Massa do bogie	$m_b$ (kg)	2,83E+03
	Momento de inércia xx	$l_{b,x}$ (kg.m <sup>2</sup> )	2,70E+03
	Momento de inércia yy	$l_{b,y}$ (kg.m <sup>2</sup> )	1,93E+03
	Momento de inércia zz	$l_{b,z}$ (kg.m <sup>2</sup> )	3,88E+03
Rodado	Massa do rodado	$m_w$ (kg)	1,71E+03
	Momento de inércia xx	$l_{w,x}$ (kg.m <sup>2</sup> )	7,33E+02
	Momento de inércia zz	$l_{w,z}$ (kg.m <sup>2</sup> )	7,33E+02
Suspensão Primária	Rigidez longitudinal	$k_{1,x}$ (N/m)	4,50E+07
	Rigidez transversal	$k_{1,y}$ (N/m)	3,09E+07
	Rigidez vertical	$k_{1,z}$ (N/m)	1,65E+06
	Amortecedor vertical	$c_{1,z}$ (N.s/m)	1,67E+04
Suspensão Secundária	Rigidez longitudinal	$k_{2,x}$ (N/m)	4,91E+06
	Rigidez transversal	$k_{2,y}$ (N/m)	2,50E+06
	Rigidez vertical	$k_{2,z}$ (N/m)	7,35E+05
	Amortecedor longitudinal	$c_{2,x}$ (N.s/m)	4,00E+05
	Amortecedor transversal	$c_{2,y}$ (N.s/m)	1,75E+04
	Amortecedor vertical	$c_{2,z}$ (N.s/m)	3,50E+04

### 3.2 MODELAÇÃO DA VIA

O modelo numérico da via utilizado foi desenvolvido em Mosleh et al. (2021a), baseando num esquema de múltiplas camadas, simulando todos os seus elementos constituintes, conforme apresentado na secção 2.3.2. Os carris foram modelados como elementos de viga (assim como as travessas) com propriedades equivalentes ao UIC60 (EN 13674-1, 2002). O balastro é simulado como elementos de massa discretos e a fundação com recurso a uma série de molas independentes com um comportamento elástico linear. As palmilhas, apoiadas nas travessas sob o carril, assim como todas as restantes ligações entre os elementos constituintes da via, são simuladas como elementos elásticos, representado o comportamento mecânico de interface (Figura 2.4a). As propriedades do modelo da via, incluindo a descrição das variáveis apresentadas na Figura 2.4, são apresentadas na Tabela 3.3.

Tabela 3.3 - Propriedades mecânicas da via (Mosleh et al., 2021a).

Elemento	Parâmetros	Unidades	Valor
Carril	Área da secção transversal	$A_r$ (m <sup>2</sup> )	7.67E-04
	Peso volúmico	$\rho_r$ (kg.m <sup>3</sup> )	7.85E+03
	Momento de Inércia yy	$I_r$ (m <sup>4</sup> )	3.04E-05
	Módulo de elasticidade	$E_r$ (N/m <sup>2</sup> )	2.10E+11
Palmilhas	Rigidez longitudinal	$k_{p,x}$ (N/m)	2.00E+07
	Rigidez transversal	$k_{p,y}$ (N/m)	2.00E+07
	Rigidez vertical	$k_{p,z}$ (N/m)	2.00E+05
	Amortecedor longitudinal	$c_{p,x}$ (N.s/m)	2.00E+07
	Amortecedor transversal	$c_{p,y}$ (N.s/m)	2.00E+07
	Amortecedor vertical	$c_{p,z}$ (N.s/m)	2.00E+05
Travessas	Peso volúmico	$\rho_s$ (kg.m <sup>3</sup> )	2.59E+03
	Módulo de elasticidade	$E_s$ (N/m <sup>2</sup> )	4.09E+10
Balastro	Rigidez longitudinal	$k_{b,x}$ (N/m)	9.00E+05
	Rigidez transversal	$k_{b,y}$ (N/m)	2.25E+06
	Rigidez vertical	$k_{b,z}$ (N/m)	3.00E+07
	Amortecedor longitudinal	$c_{b,x}$ (N.s/m)	1.50E+04
	Amortecedor transversal	$c_{b,y}$ (N.s/m)	1.50E+04
	Amortecedor vertical	$c_{b,z}$ (N.s/m)	1.50E+04
Fundação	Rigidez longitudinal	$k_{f,x}$ (N/m)	2.00E+07
	Rigidez transversal	$k_{f,y}$ (N/m)	2.00E+07
	Rigidez vertical	$k_{f,z}$ (N/m)	2.00E+07
	Amortecedor longitudinal	$c_{f,x}$ (N.s/m)	5.01E+02
	Amortecedor transversal	$c_{f,y}$ (N.s/m)	5.01E+02
	Amortecedor vertical	$c_{f,z}$ (N.s/m)	5.01E+02

As imperfeições nos carris em condições reais de via-férrea são muito pequenas, e os seus efeitos no contacto roda-carril não podem ser desprezados (Vale, 2010). Estas irregularidades desempenham um

papel fundamental na geração de cargas dinâmicas ao longo do movimento de circulação, que caso fossem ignoradas, simplificar-se-iam em cargas quase-estáticas.

Com base no processo descrito na subsecção 2.3.2, assim como em dados reais, foram simuladas numericamente em MATLAB® (2018), irregularidades de via distribuídas com recurso por funções de densidade espectral de potência. Primeiramente foram formadas curvas de densidade espectral de potência e de seguida criados perfis artificiais de irregularidades, nas direções vertical e lateral. Adotaram-se comprimentos de onda ( $\lambda$ ) entre 1m a 75 m, com os subgrupos: D1 (3m a 25m) e D2 (25m a 70m) definidos pela norma EN 1384-2 (2006), com uma discretização de amostragem de 0,001m. Mais detalhes sobre a geração de perfis de irregularidades são fornecidos por Mosleh et al. (2020).

No presente trabalho foram considerados quatro tipos de perfis de irregularidade (1-4), em cada uma das direções, vertical (V) e lateral (L), em ambos os carris. A Figura 3.4 ilustra graficamente os tipos de irregularidades consideradas em cada direção relativamente a um carril. A amostragem dos perfis desenvolve-se ao longo de um troço reto de 350 m, sendo este o comprimento total da via nas simulações numéricas. Os perfis de irregularidades gerados apresentam os valores de pico indicados na NP EN 13848-5 (2015) (Quadro B.3 do Anexo B) relativamente ao nivelamento longitudinal (B.2.2).

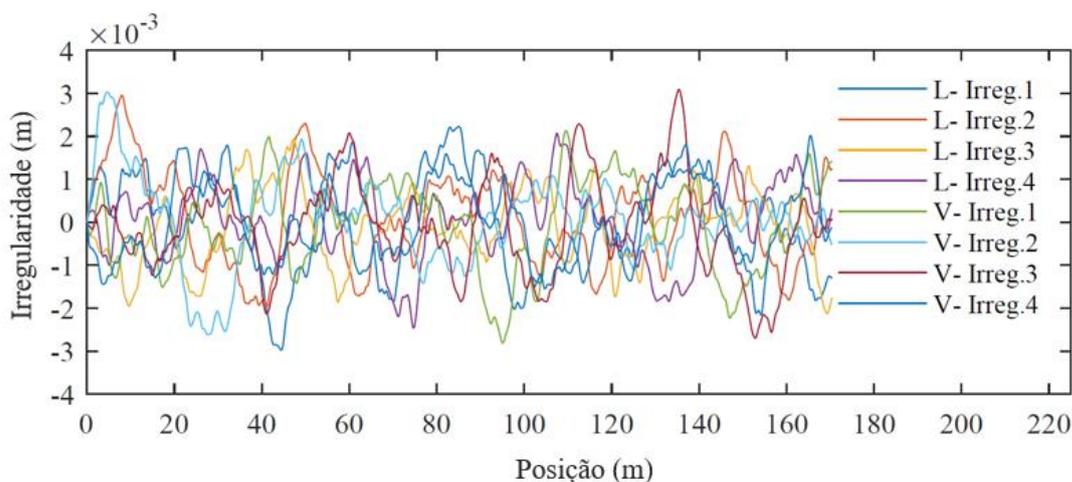


Figura 3-4 - Irregularidades de via (L- lateral; V- vertical).

### 3.3 MODELAÇÃO DAS IRREGULARIDADES NAS RODAS

A influência do efeito geométrico da roda na interação do sistema resolve-se através da modelação do perfil da roda sobreposto ao do carril. Para isso foram recolhidas informações sobre as características geométricas vulgarmente detetadas em cada tipo de dano permitindo simular diferentes cenários através da respetiva caracterização matemática detalhada na secção 2.4.1 e 2.4.2, para os cenários de lisos e

desgaste poligonal, respetivamente. A Figura 3.5 ilustra uma representação da localização de cada tipo de dano simulado, tendo em conta o fator localização nos cenários simulados.



Figura 3-5 - Localização do tipo de dano.

### 3.3.1 Lisos

Tendo em conta que os defeitos geométricos superficiais lisos são caracterizados geometricamente pela sua profundidade ( $D$ ) e pelo seu comprimento ( $L$ ), conforme apresentado na secção 2.4.1 foram admitidos três grupos de severidade (L1-L3). A cada grupo de severidade L1, L2 e L3 foram atribuídos os intervalos geométricos, L1 [10-20] (mm) / D1 [0.02-0.06] (mm), L2 [25-35] (mm) / D2 [0.09-0.16] (mm) e L3 [40-50] (mm) / D3 [0.23-0.36] (mm), respetivamente. Para cada intervalo considerado foram geradas dez passagens aleatórias definidas a partir de uma função com distribuição normal, perfazendo um total de trinta passagens. As características dos lisos foram seleccionadas de acordo com diversos estudos da bibliografia (Chang et al., 2022; Mohammadi et al., 2023; Mosleh et al., 2023; Mosleh et al., 2022a). Um exemplo gráfico do desvio vertical do perfil da roda ( $Z$ ), sobreposto na modelo numérico da via, obtido através da expressão 2-15, é apresentada na Figura 3.6 para cada um dos três grupos considerados.

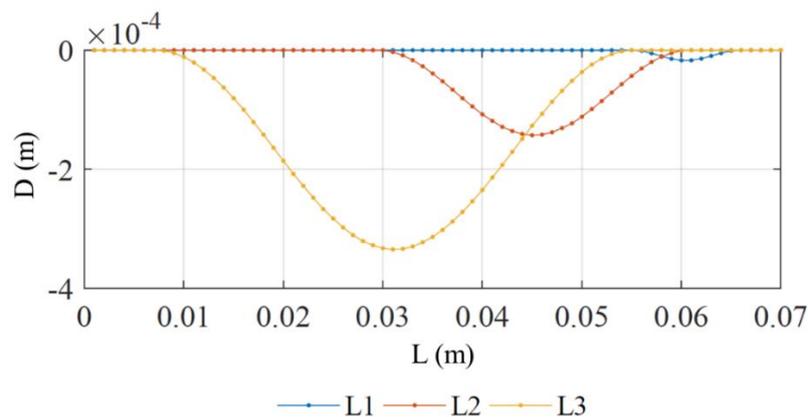


Figura 3-6 – Características dos lisos modelados.

### 3.3.2 Poligonização

Dado que a forma poligonal da roda é caracterizada pelo número de harmónicos dominante no perfil de irregularidade, foram considerados diferentes ordens de harmónicos em função das medições experimentais evidenciadas em diversos trabalhos da literatura. Respeitando as condições de circulação

do veículo Alfa pendular, nomeadamente a variável velocidade, utilizou-se espectros de irregularidades formados quando os veículos ferroviários são sujeitos a velocidade de 120 km/h e a 200 km/h ou superior. Os espectros de irregularidade com harmónico dominante de H6\_8 e H12\_14 foram adquiridos através dos resultados obtidos por Mu et al. (2022) e Tao et al. (2021), respetivamente. Já os espectros com harmónicos dominantes de uma ordem mais elevada, H19\_20 e H29\_30, provieram das medições adquiridas por Zhang et al. (2018) e Cai et al. (2019), respetivamente. Os espectros de irregularidade de cada ordem dominante são representados graficamente na Figura 3.7a. Estes perfis de irregularidade ( $L_w$ ) permitiram modelar corretamente o perfil da roda ( $w$ ) através das expressões numéricas apresentadas na secção 2.4.2, sobrepondo o defeito no modelo numérico da via. Referente à amplitude do defeito ( $A$ ) foram considerados dois intervalos, A1[0.25-0.35] mm e A2 [0.65 e 0.75] mm, com base no estudo de Nielsen e Johansson (2000), permitindo simular cinco passagens para cada intervalo. Os perfis de irregularidade da roda para cada tipo de ordem de harmónico dominante são representados graficamente na Figura 3.7a para amplitude A1 e Figura 3.7b para a amplitude A2, com um exemplo para cada ordem de harmónico dominante.

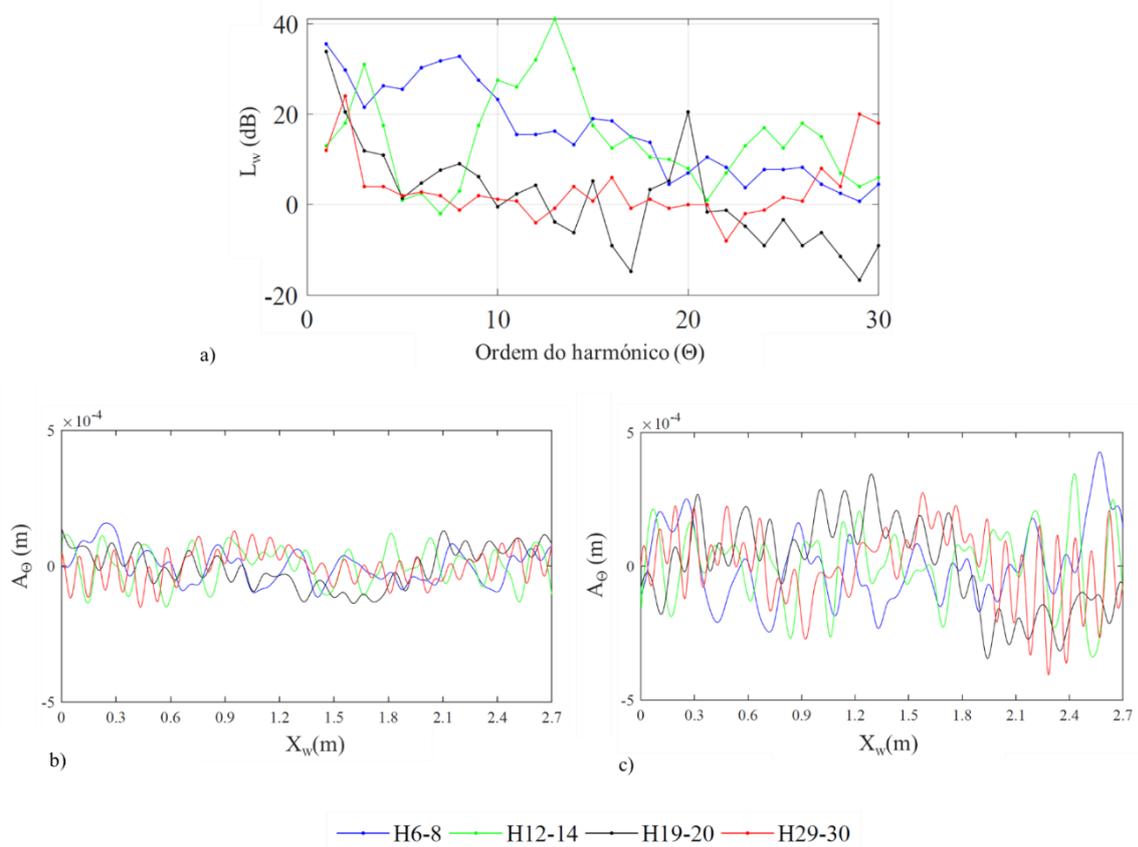


Figura 3-7 – Características do efeito poligonal modelado: a) medições experimentais do espectro de irregularidade; b) exemplo de um perfil de irregularidade da roda para uma amplitude de defeito A1; c) exemplo de um perfil de irregularidade da roda para uma amplitude de defeito A2.

### 3.4 INTERAÇÃO DINÂMICA

Neste estudo, as simulações numéricas foram garantidas através do algoritmo de interação dinâmica veículo-via, designado por *VSI-Vehicle-Structure Interaction Analysis*, desenvolvido por Montenegro (2015), citado na secção 2.3.3. Este software incorpora a interação lateral através de um modelo de contacto roda-carril, considerando tanto as forças normais como as forças tangenciais que ocorrem na superfície de contacto. 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 modelação numérica do sistema possibilita a validação da metodologia adotada para identificação de dano, antes do seu teste em ambiente real.

O procedimento utilizado para a obtenção das respostas dinâmicas consiste em exportar as matrizes de massa, rigidez e amortecimento dos modelos numéricos da via e do comboio, previamente modelados no ANSYS® (2018), para o MATLAB® (2018). Com os perfis de irregularidade das rodas (lisos e desgaste poligonal) também modelados em MATLAB® (2018), estes são sobrepostos ao carril nos nós correspondentes à passagem da roda onde foi considerado o defeito. A interação dinâmica veículo-estrutura é executada em MATLAB® (2018), extraíndo-se as respostas dinâmicas uma frequência de amostragem de 10 kHz.

A análise da interação entre veículo e a via é detalhadamente explicada e validada no trabalho de Montenegro et al. (2015) tendo sido aplicada com sucesso em diversas outras aplicações (Guedes et al., 2023; Silva et al., 2023, Gonçalves et al. 2023). A Figura 3.8 apresenta esquematicamente o procedimento numérico da interação dinâmica veículo-via que permitiu extrair corretamente as respostas dinâmicas da via.

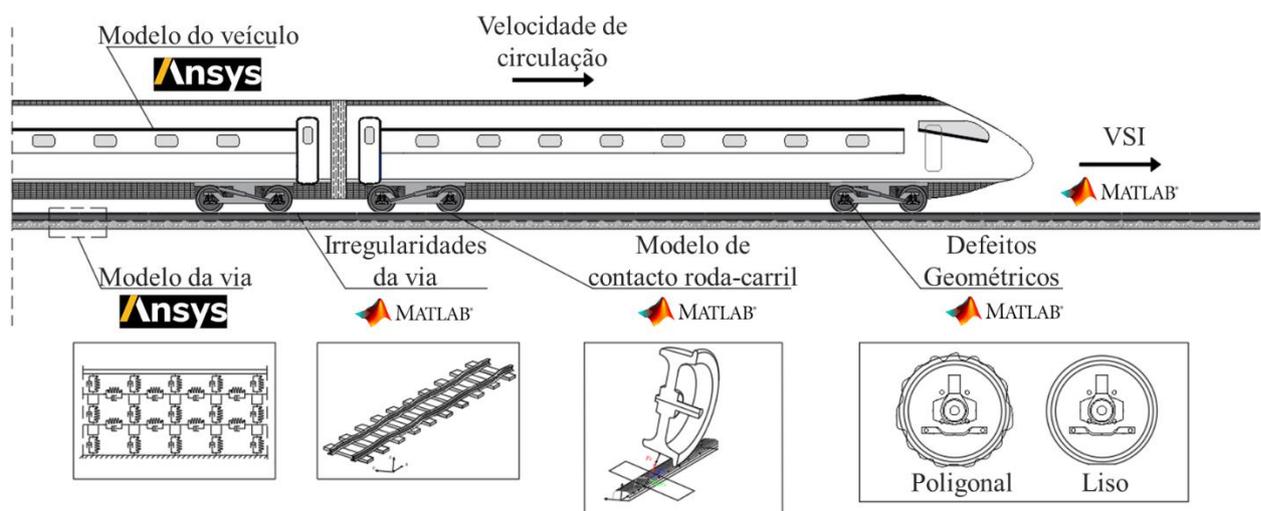


Figura 3-8: Modelo de interação dinâmica veículo-via



## CAPÍTULO 4

### **METODOLOGIA DE IDENTIFICAÇÃO DE DANO**

No âmbito da presente dissertação foi desenvolvida, em MATLAB® (2018), uma metodologia identificação de danos nas rodas do veículo Alfa pendular, com o objetivo de identificar diferentes cenários de dano.

O ponto de partida para o desenvolvimento deste capítulo consistiu na aplicação de um autoencoder esparso (AEE) para a extração de indicadores. O principal objetivo da sua potencialidade foi determinar o modelo de autoencoder mais adequado aos dados de forma a resolver o problema imposto. Com isto foram executados vários processos de treino com recurso a uma amostragem de cenários sem dano, sendo os restantes, além dos cenários com dano não treinados, submetidos a uma reconstrução das respostas por parte da rede artificial criada. A conclusão desta etapa permitirá adquirir um indicador de dano (DI), através da diferença cumulativa entre a resposta original e a resposta reconstruída. Posteriormente, este indicador é melhorado com a aplicação da distância de Mahalanobis (DM) de forma a realçar a presença de passagens com dano. Na fase final da metodologia efetua-se uma deteção e classificação do dano, através de uma análise de outliers e uma análise de clusters, respetivamente. A etapa correspondente à classificação compreende uma identificação do tipo de dano e, posteriormente, realiza-se uma classificação quanto ao nível de severidade do dano identificado. Uma classificação da severidade do dano após a identificação da tipologia do mesmo possibilita uma tomada de decisão no que toca à manutenção da roda.

Este capítulo apresenta uma estratégia híbrida das técnicas detalhadas na secção 2.5, tendo por base unicamente resultados de medições da resposta dinâmica na via adquiridas por análises numéricas, através dos modelos dinâmicos descritos no Capítulo 3. Assim sendo, foram simuladas diversas passagens com diferentes características, tanto para os cenários de base (sem dano) como para os cenários de dano. Estipulados os cenários, as respostas dinâmicas são devidamente organizadas e aplicadas sequencialmente, de forma automática, na metodologia desenvolvida no trabalho.

## 4.1 CENÁRIOS SIMULADOS

No que se refere aos cenários de base consideraram-se diferentes tipos de cargas, velocidades e irregularidades de via, de forma a serem criados cenários abrangentes formando uma linha de referência bastante robusta, permitindo uma maior proximidade com o contexto real de circulação. Para cada uma das velocidades de circulação, dez no total, são considerados os quatro diferentes tipos de irregularidades de via apresentados na secção 3.2 para os três diferentes tipos de carga a que o veículo poderá estar sujeito (vazio, meio cheio e cheio). Combinando todas as possibilidades de circulação, obtêm-se um total de cento e vinte simulações de passagens sem dano.

Relativamente aos cenários de dano foram usadas as características apresentadas na secção 3.3, para simular passagens com uma velocidade de circulação de 120 e 200 km/h. Relativamente às passagens com lisos, foram simuladas dez para cada tipo de severidade, representando um total de sessenta passagens. Já para os cenários de poligonização, a formação de cinco perfis de irregularidades para cada amplitude em cada tipo de harmónico, perfaz um total de oitenta passagens. A Tabela 4.1 traduz a organização de toda esta informação.

Tabela 4.1 - Características de operabilidade dos cenários simulados.

	<b>Cenários de base</b>	<b>Cenários de dano</b>
Veículo	Alfa pendular	Alfa pendular
Tipos de carregamento	3 (cheio, meio, vazio)	1 (cheio)
Perfis de irregularidade de via	1-4	1
Velocidade	40-220 km/h	120 e 200 km/h
Características do liso	-	Comprimento/Profundidade (mm): L1 [10-20] / D1 [0,02-0,06] L2 [25-35] / D2 [0,09-0,16] L3 [40-50] / D3 [0,23-0,36]
Características da poligonização	-	Ordem do harmónico: H6-8, H12-14, H19-20, H29-30 Amplitude do defeito (mm): A1[0,25-0,35], A2[0,55-0,65]
Número total de análises	120	140

## 4.2 PROCEDIMENTO DA METODOLOGIA

Primeiramente, as respostas de acelerações verticais são adquiridas através de simulações numéricas, sendo os cenários de base organizados da seguinte forma: 80% são utilizados para treinar o modelo AEE e 20% usadas para testar o modelo treinado. Referente ao processo de treino, garantiu-se que todas as velocidades e esquemas de carga foram incluídos, pelo que a divisão dos dados teve em consideração as irregularidades de via. A seleção dos melhores hiperparâmetros do modelo AEE consistiu numa análise de

sensibilidade com diferentes tipos de hiperparâmetros combinados de forma a determinar o modelo AEE otimizado. As respostas referentes a cenários de base não treinados e a cenários de dano são previstas no modelo AEE de forma a extrair um indicador de dano (ID). Este ID é estabelecido através do erro de reconstrução, com recurso ao erro quadrático médio (MSE) e ao erro médio absoluto (MAE). Estas diferenças cumulativas entre as respostas dinâmicas originais e as respostas dinâmicas reconstruídas pela rede só poderão ser comparadas se a amostragem for equivalente em todos os cenários. Isto é, a duração de cada passagem aumenta quando ocorrem passagens de veículos com velocidades baixas e diminui para velocidades mais altas, evidenciando-se na dimensão vetorial das respostas obtidas. Para contornar este comportamento físico, as respostas dinâmicas obtidas foram cortadas a partir do mesmo ponto de origem e transformadas para valores de aceleração em função da distância percorrida. Após esta extração, a distância Mahalanobis é aplicada para fundir os indicadores de dano extraídos com o MSE, aumentando a sensibilidade do dano. Para a deteção automática de danos é aplicado um limite estatístico e, posteriormente, uma análise de clusters é realizada em duas etapas. A primeira etapa do consiste em avaliar o tipo de dano com a fusão dos dados adquiridos, já a segunda permite a classificação quanto à severidade de cada dano identificado, utilizando somente o MAE. Na Figura 4.1 apresenta-se o fluxograma da metodologia desenvolvida.

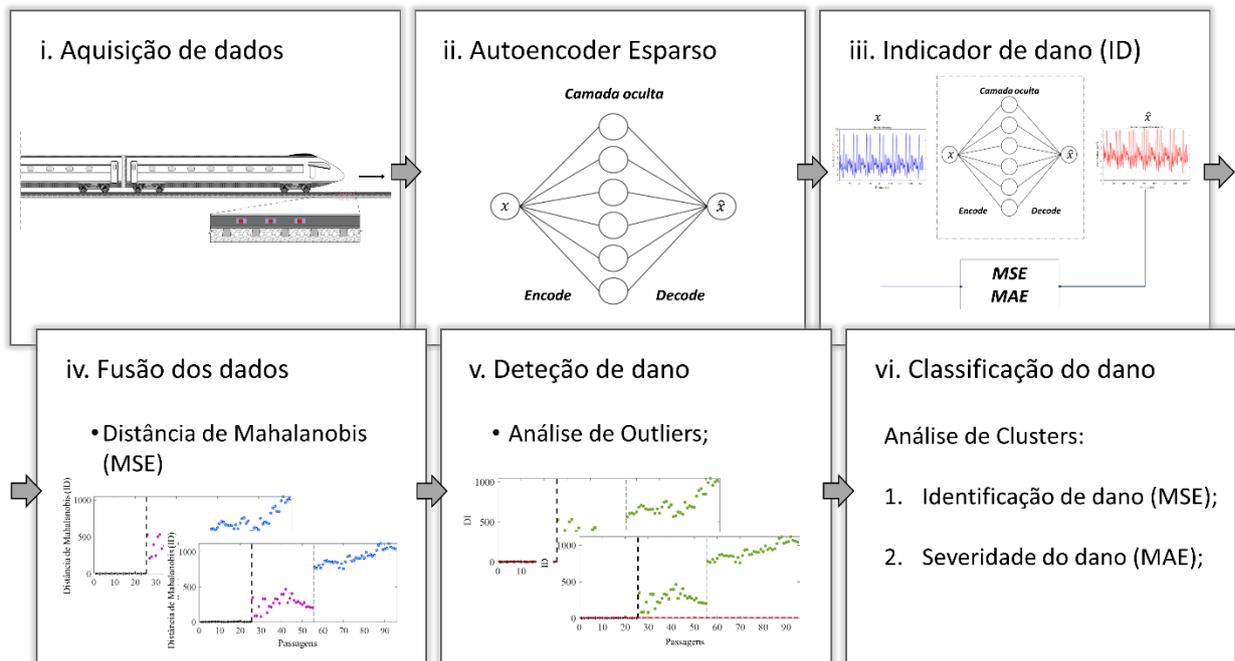


Figura 4-1- Fluxograma da metodologia de identificação de dano.

#### 4.2.1 Aquisição das respostas dinâmicas

O sistema de aquisição é composto por um conjunto de seis acelerómetros virtuais situados no carril a meio vão entre travessas, conforme ilustrado na Figura 4.2, com uma frequência de amostragem de 10

kHz. Os números de 1 a 6 representam as posições dos pontos de medição, à direita (1-3) e à esquerda (4-6), onde são adquiridas as respostas de acelerações verticais. Um filtro digital passa-baixo Chebyshev tipo II com frequência de corte de 1500 Hz é aplicado para filtrar as séries temporais obtidas. Adicionalmente, um ruído artificial equivalente a 5% da amplitude é incorporado no sinal numérico. O número de acelerómetros virtuais advém do número de acelerómetros utilizados na campanha experimental (capítulo 5), sendo um dos requisitos definido no desenvolvimento deste trabalho.

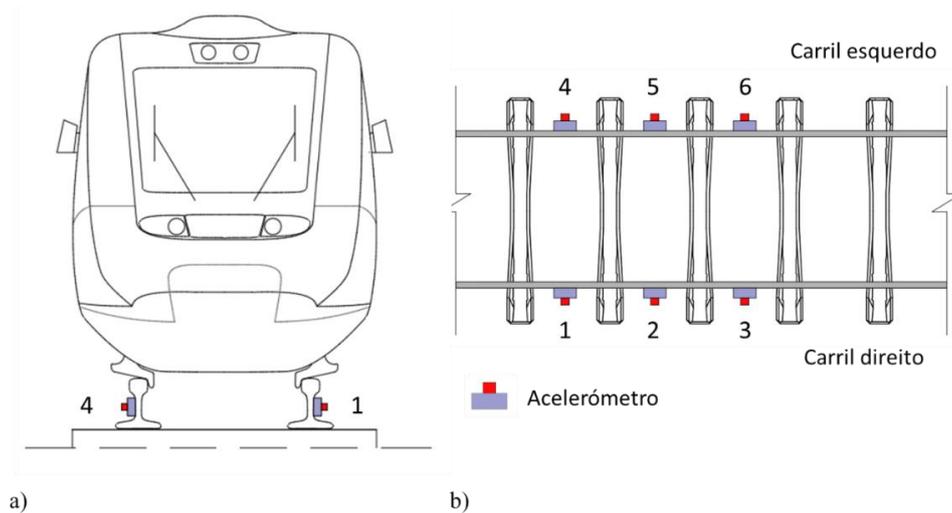


Figura 4-2 - Esquema de monitorização: a) vista transversal; b) vista de topo.

Atendendo que os valores da resposta de acelerações,  $a(t)$ , são extraídos com um incremento temporal de 0,0001 s, é possível determinar o valor da distância percorrida  $d$  a cada 0,0001 s, admitindo que a velocidade de circulação  $v$  é previamente conhecida:

$$v(t) = \frac{d(t)}{t} \text{ (m/s)} \quad (4-1)$$

O valor da distância percorrida que cada passagem contém é tanto maior quando menor for a velocidade de circulação. Sabendo que o comprimento do Alfa tem aproximadamente 160 m, os sinais extraídos em  $a(t)$  são passados para  $a(d)$ , cortados a partir do mesmo ponto inicial, até que sejam percorridos os 165 metros, englobando o comprimento do veículo com uma folga de 5 metros. O facto de a velocidade originar dimensões diferentes da resposta dinâmica, impossibilita a uniformização da amostragem, para isso é necessário estabelecer um incremento espacial em função da maior velocidade de circulação (220 km/h) para todas as passagens, invocando a equação 4-1:

$$\frac{220}{3.6} = \frac{\Delta d(t)}{0.0001} \equiv \Delta d(t) = 0.00611(1) \text{ m} \cong 0.0062 \text{ m} \quad (4-2)$$

Estabelecido o incremento espacial, todas as respostas obtidas foram sujeitas a uma interpolação caso não fosse sabido o valor da aceleração correspondente a cada 0.0062 m percorrido. Esta transformação

do espaço das variáveis possibilita a obtenção de todas as respostas com a mesma dimensão vetorial, recurso imprescindível para a extração de indicadores com base num erro cumulativo.

As Figuras 4.3, 4.4 e 4.5 apresentam o aspecto gráfico dos sinais de acelerações extraídos no acelerómetro 1. Na Figura 4.3 destaca-se a influência dos diferentes esquemas de carregamento (Figura 4.3.a) e perfis de irregularidades da via (Figura 4.3.b) para a velocidade de 160 km/h. De acordo com o tipo de carga considerada durante a operação do veículo, esta induz alterações insignificantes na resposta dinâmica, ao contrário dos perfis de irregularidade de via que demonstram algumas variações ao longo da resposta. A Figura 4.3.c compreende as respostas de aceleração para três diferentes velocidades distintas, destacando-se o impacto significativo da velocidade.

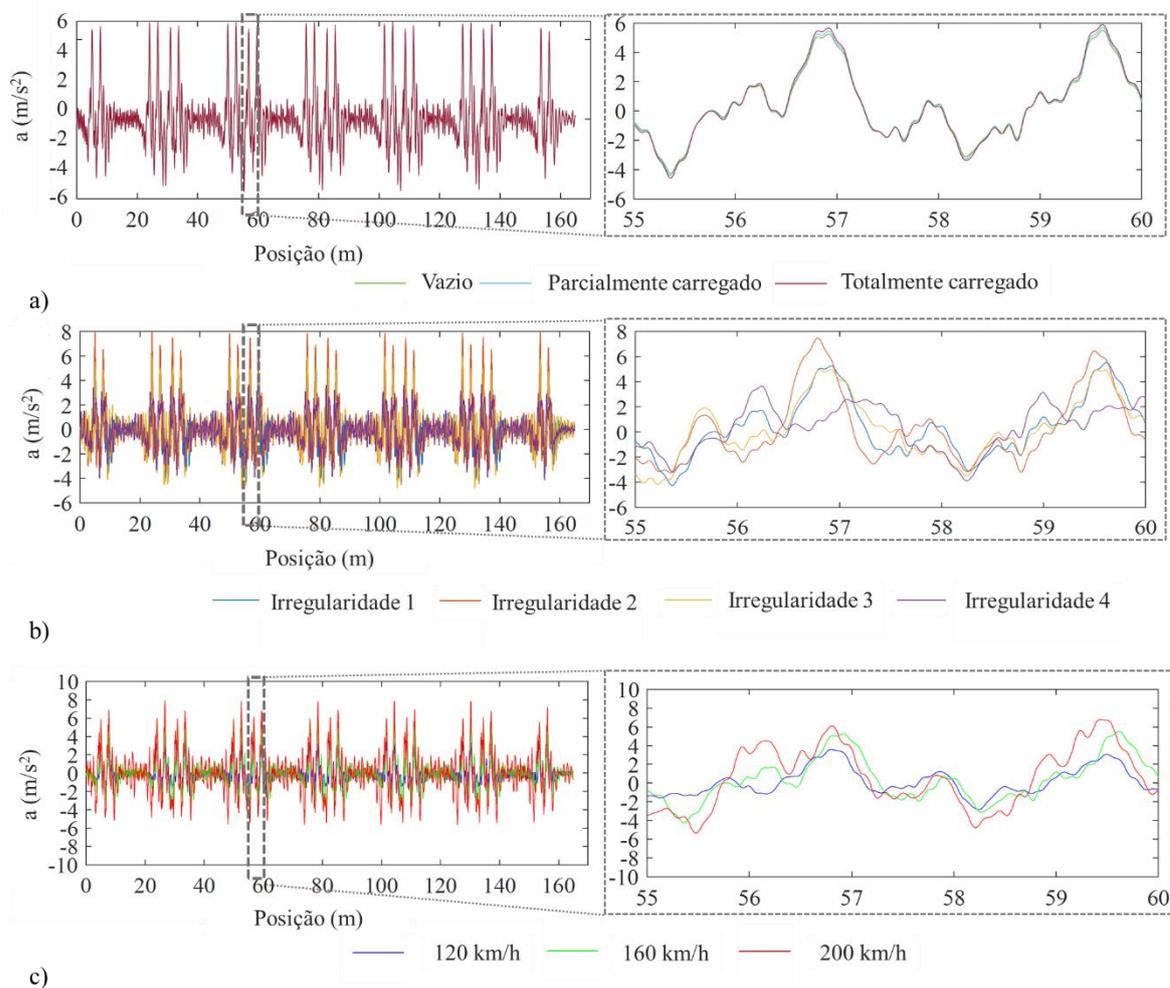


Figura 4-3 – Respostas de acelerações medidas no acelerómetro 1 para diferentes condições de base: a) tipos de carregamento; b) irregularidades da vida; c) velocidade de circulação.

Atendendo aos cenários de dano criados, as suas representações gráficas, também obtidas no sensor 1, são comparadas nas Figuras seguintes. A Figura 4.4 compreende um exemplo de cada intervalo de lisos

considerados (L1-L3), enquanto a Figura 4.5 dispõe de um exemplo de cada ordem de harmónico simulada (H6-8, H12-14, H19-20 e H29-30) para cada uma das amplitudes de defeito (A1 e A2).

Nos casos em que há a presença de lisos na roda (Figura 4.4), é evidente que o grupo L3 exibe amplitudes de resposta dinâmica consistentemente mais altas em ambas as velocidades (Figura 4.4a e Figura 4.4b). Os diferentes picos referentes ao momento da pancada do liso são visíveis de acordo com a respetiva gravidade. Porém, a influência destes defeitos é menos relevante na resposta em relação a uma passagem de rodas poligonais (Figura 4.5). Nesse tipo de irregularidade, a periodicidade do defeito produz um impacto mais evidente na resposta dinâmica. De acordo com os perfis poligonais simulados, a ordem harmônica H29-30 é das que produz maior amplitude na resposta dinâmica, sobretudo a 120 km/h (Figura 4.5a), pois para 200 km/h (Figura 4.5b) a ordem H12-14 adquire amplitudes relevantes. Os harmónicos de ordem H6\_8 e H19\_20 assemelham-se em ambas as velocidades, face às características das respostas dinâmicas que cada um representa. Manifesta-se ainda a sensibilidade deste tipo de desgaste face às mudanças na velocidade.

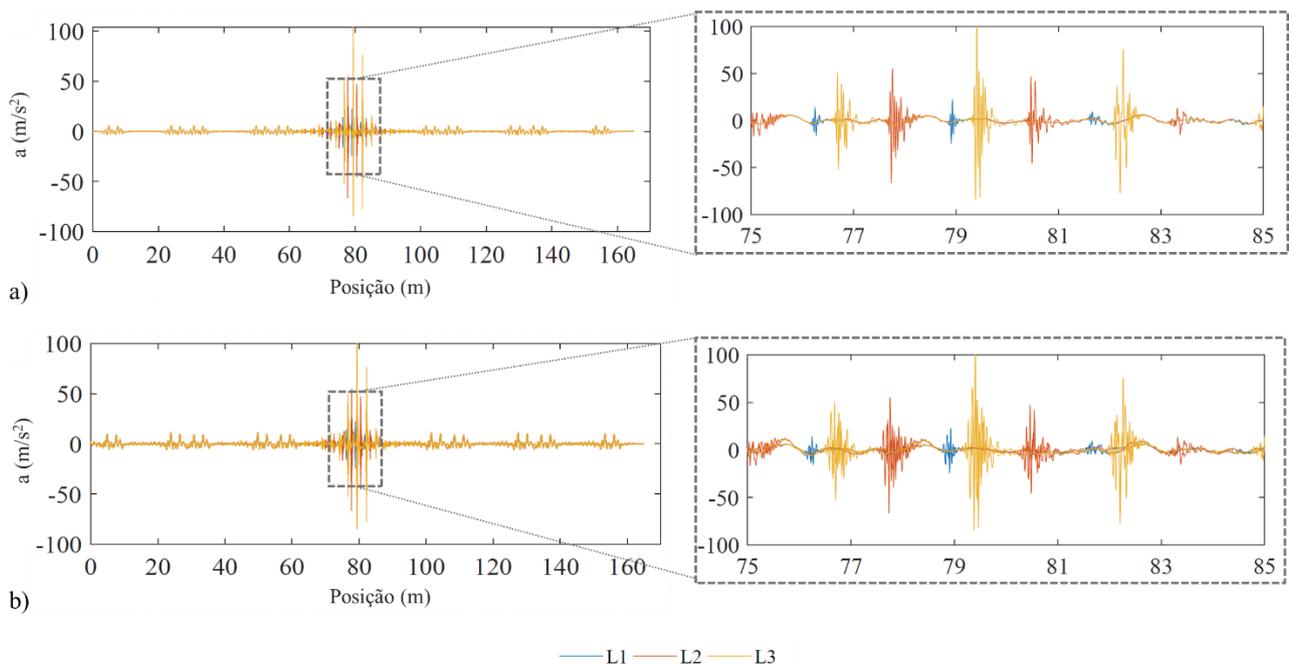


Figura 4-4 – Respostas de acelerações dos diferentes cenários de lisos nas rodas, medidas na posição 1 para: a) 120 km/h; b) 200 km/h.

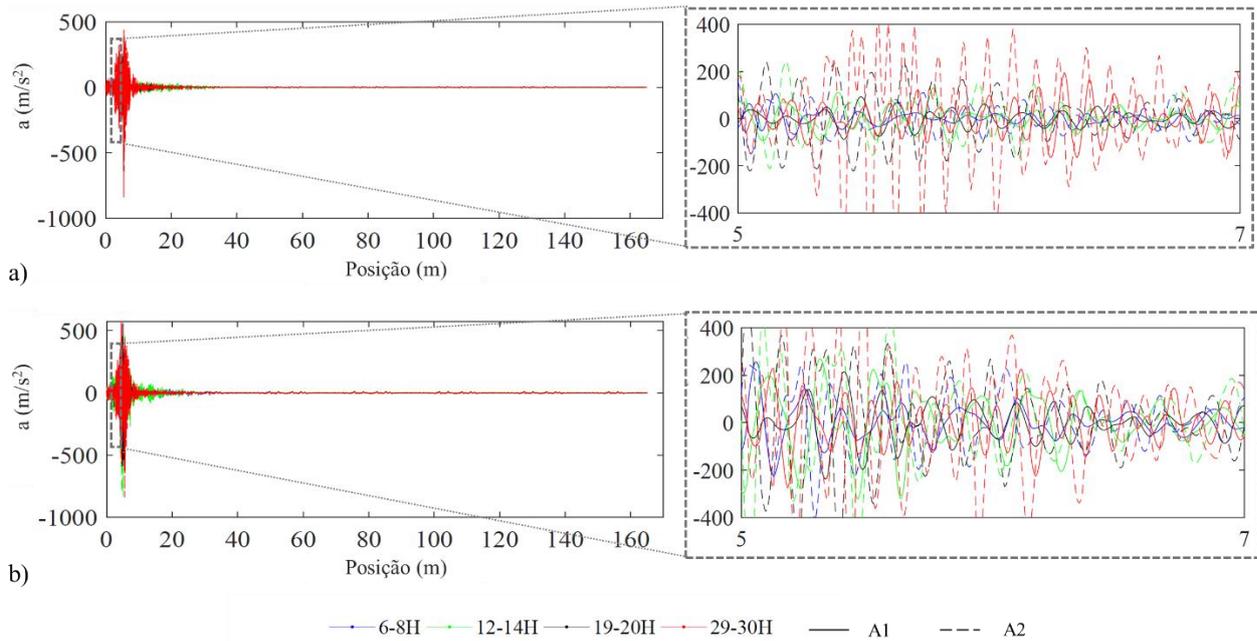


Figura 4-5 - Respostas de acelerações dos diferentes cenários rodas poligonais, medidas na posição 1 para: a) 120 km/h; b) 200 km/h.

Os fenómenos desenvolvidos por cada um dos defeitos geométricos dependem, essencialmente, da amplitude do defeito e da velocidade. É de realçar a distinção entre a energia de um sinal referente a uma passagem com um liso e uma passagem com um efeito poligonal. Este fenómeno permitirá tratar os dados de forma a ser possível distinguir os dois tipos de dano modelados. Referente à variável velocidade, esta induz comportamentos distintos para cada tipo de dano, num dano superficial ocorre a relação demonstrada na secção 2.4.1, quanto maior a velocidade menor será o valor da aceleração. Já no caso de um efeito poligonal, secção 2.4.2, o efeito da velocidade na resposta dinâmica varia consoante o número de harmónicos dominantes do perfil.

#### 4.2.2 Aplicação de um Autoencoder Esparso

A arquitetura do Autoencoder Esparso (AEE) é realizada com recurso ao algoritmo 'trainAutoencoder' do MATLAB (2018), com o objetivo de treinar respostas sem dano de forma a extrair características relacionadas com condições normais de circulação. O processo de treino foi efetuado apenas com respostas sem dano, alternando-se a irregularidade de via deixada para teste. Foram realizados vários processos de treino com combinações de irregularidade de via (1-2-3, 1-3-4, 1-2-4, 2-3-4) sendo as respostas dinâmicas com a outra irregularidade (4,2,3,1) utilizadas para a fase de teste. Os resultados foram equivalentes face à alternância dos casos, dado que se optou por demonstrar os resultados referentes a um dos processos, treino com respostas sem dano com irregularidade de via 1,2,3 e a as respostas com irregularidade 4 deixadas para treino.

Após realizado o processo de treino, com 95 passagens sem dano, a reconstrução das respostas sem dano não usadas na fase de treino, restantes 25, assim como todas as respostas com características de danos (140 passagens no total), são reconstruídas através do algoritmo 'predict'. Este processo de reconstrução, através de um processo de treino previamente estabelecido, permite obter a diferença entre as respostas originais e as respostas reconstruídas, denominando-se por erro de reconstrução.

Um processo de treino otimizado permitirá a obtenção dos erros mais esclarecedores para a identificação de danos. Para a seleção desse processo foi realizada uma análise de sensibilidade a dezasseis diferentes tipos de arquitetura AEE, com o objetivo de encontrar o processo de treino que mais se adequa ao objetivo do presente trabalho, permitindo uma correta deteção e classificação de dano. Várias possibilidades de treino foram testadas, pelo que a melhor opção foi criar um conjunto lógico de possibilidades.

#### **4.2.2.1 Configuração do modelo**

A Tabela 4.2 exhibe os vários casos que foram considerados para a seleção do AEE otimizado, usando funções de ativação sigmoide em todas as instâncias. A configuração do modelo consistiu na aplicação de toda a metodologia apresentada no fluxograma da Figura 4.1 com cada um dos AEE modelados, sendo que o B4 foi o que apresentou uma melhor performance para os resultados pretendidos.

Os diferentes tipos de modelos AEE considerados são divididos em quatro grupos (A-D) e cada um deles em quatro subgrupos (1-4). Primeiramente, a dimensão da camada oculta ( $k$  nº de neurónios) e as épocas de treino (nº de iterações) são incrementadas ao longo dos quatro grupos formados. O aumento da grandeza destas variáveis permitem compreender a influência do aumento dos neurónios com o aumento do número de iterações envolvidas no processo, permitindo perceber qual a necessidade de iterações face ao número de neurónios existentes. Ainda assim, em cada grupo são analisados os resultados obtidos em cada subgrupo, onde o coeficiente regularizador dos pesos ( $\lambda$ ) diminui à medida que o coeficiente de esparsidade ( $\beta$ ) e a proporção de esparsidade ( $\rho$ ) aumentam. A utilização da função de ativação não linear, sigmoide, deve -se essencialmente ao facto de a velocidade de circulação apresentar um efeito não linear nas respostas dinâmicas obtidas, além disso é das funções mais correntemente utilizadas na literatura. Os restantes parâmetros arbitrados tiveram como ponto de partida os parâmetros utilizados por defeito pelo próprio algoritmo do software e os correntemente utilizados na literatura.

Tabela 4.2 – Diferentes tipos de arquitetura de rede e hiperparâmetros considerados.

Grupo	Neurónios (k)	Epócas	$\lambda$	$\beta$	$\rho$	Subgrupo	Grupo	Neurónios (k)	Epócas	$\lambda$	$\beta$	$\rho$	Subgrupo
A	3	250	$10^{-2}$	6	0.15	A1	C	9	750	$10^{-2}$	6	0.15	C1
			$10^{-3}$	9	0.3	A2				$10^{-3}$	9	0.3	C2
			$10^{-4}$	12	0.6	A3				$10^{-4}$	12	0.6	C3
			$10^{-5}$	15	0.9	A4				$10^{-5}$	15	0.9	C4
B	6	500	$10^{-2}$	6	0.15	B1	D	12	1000	$10^{-2}$	6	0.15	D1
			$10^{-3}$	9	0.3	B2				$10^{-3}$	9	0.3	D2
			$10^{-4}$	12	0.6	B3				$10^{-4}$	12	0.6	D3
			$10^{-5}$	15	0.9	B4				$10^{-5}$	15	0.9	D4

#### 4.2.2.2 Previsão das respostas no modelo AEE otimizado

Na Figura 4.6 são apresentados os sinais de acelerações originais e reconstruídos de passagens de teste, apenas para a velocidade de 120 km/h, adquiridos no primeiro par de sensores (1 e 4). Os resultados apresentados provêm do processo de reconstrução com o autoencoder otimizado (B4). É de realçar que nas passagens sem dano, a rede é capaz de realizar uma boa reconstrução da resposta, notando-se ligeiras imperfeições. Para as passagens com a presença de lisos, a resposta apresenta uma reconstrução considerável, exceto nos picos de amplitude correspondentes às pancadas. Nas passagens com efeito poligonal, a reconstrução do sinal é reduzida num maior conjunto de pontos do domínio, devido à periodicidade do defeito. Em cada tipo de cenário os valores dos erros serão indiscutivelmente diferentes, dado que a diferença entre um sinal original e um sinal reconstruído de uma passagem com liso será inferior à diferença entre um sinal original e um sinal reconstruído para uma passagem com efeito poligonal.

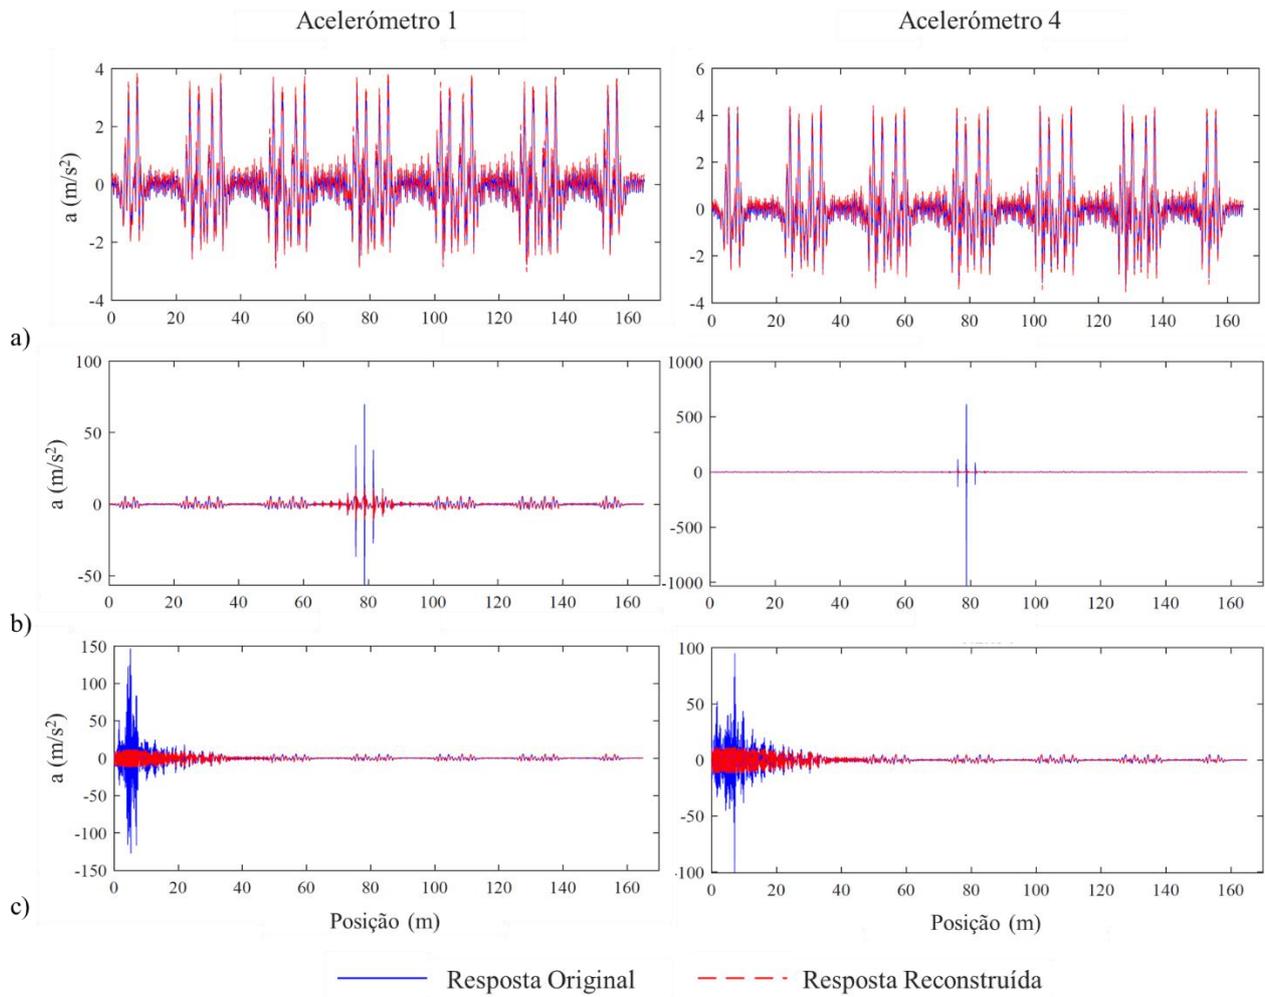


Figura 4-6 - Respostas de acelerações usadas para teste medidas no primeiro par de sensores: a) sem dano; b) presença de um liso; c) desgaste poligonal.

### 4.2.3 Indicador de dano

O indicador de dano (ID) é calculado individualmente para cada passagem em cada sensor, quantificando a diferença cumulativa entre a resposta medida e a resposta reconstruída. Os resultados foram avaliados para cada modelo AEE (Tabela 4.2), sendo que nesta etapa da metodologia todos modelos apresentaram um desempenho equivalente. Este cálculo desenvolve a seguinte correlação direta: erros mais elevados refletem maiores amplitudes de resposta e conseqüentemente uma maior severidade do dano.

Numa fase inicial o ID é calculado com o erro médio absoluto (MAE) entre a resposta original  $x_j$  e a resposta reconstruída  $\hat{x}_j$ :

$$MAE = \frac{1}{n} \cdot \sum_{j=1}^n |x_j - \hat{x}_j| \tag{4-3}$$

Com este indicador de dano, a presença de lisos não é tão evidente como nas rodas poligonais, conforme ilustrado na Figura 4.7. No entanto, uma tendência linear no *MAE* para casos de lisos torna-se perceptível em sensores situados no lado correspondente ao dano (sensores 4-6). A tendência mostra o aumento do ID com aumento da severidade dos danos simulados. Estes resultados revelam um grau de consistência do *MAE* nos sensores do mesmo lado. Já nas passagens com defeitos periódicos, estes são evidentes em ambos os lados, porém com intensidade reduzida no lado oposto ao dano (sensores 4-6). Nos casos que envolvem passagens normais de circulação, ocorre um crescimento do ID com o aumento da velocidade para cada tipo de carga, dado ao impacto significativo da velocidade na resposta dinâmica. Uma forma de alterar o espaço das variáveis é usar o erro quadrático médio (*MSE*) como ID, permitindo obter outra dispersão das variáveis originando novas conclusões relativas à evidência do dano. O erro quadrático médio entre a resposta original  $x_j$  e a resposta reconstruída  $\hat{x}_j$  é dado por:

$$MSE = \frac{1}{n} \cdot \sum_{j=1}^n (x_j - \hat{x}_j)^2 \quad (4-4)$$

Este ID é apresentado na Figura 4.8 tornando mais evidente os indicadores referentes às passagens com lisos. Nestes casos, os sensores posicionados no carril oposto ao lado com dano (1-3) apresentam valores de ID relativamente semelhantes aos valores da linha de base. Ao contrário dos ID obtidos no lado correspondente ao dano (4-6), onde para uma velocidade de 120 km/h (Figura 4.8.a) há passagens com ID superior ao ID de rodas poligonais, o que não se verificou com o *MAE*. Em cenários de rodas poligonais, os efeitos dos danos são sentidos em ambos os carris, embora com intensidade mais reduzida no lado oposto. Este facto já foi analisado com o *MAE*, o que estabelece uma uniformidade relativamente aos resultados obtidos. Os ID referentes a passagens sem dano apresentam um comportamento equivalente aos ID obtidos com o *MAE*, embora não sejam visíveis na janela gráfica apresentada, devido à mudança do espaço das variáveis.

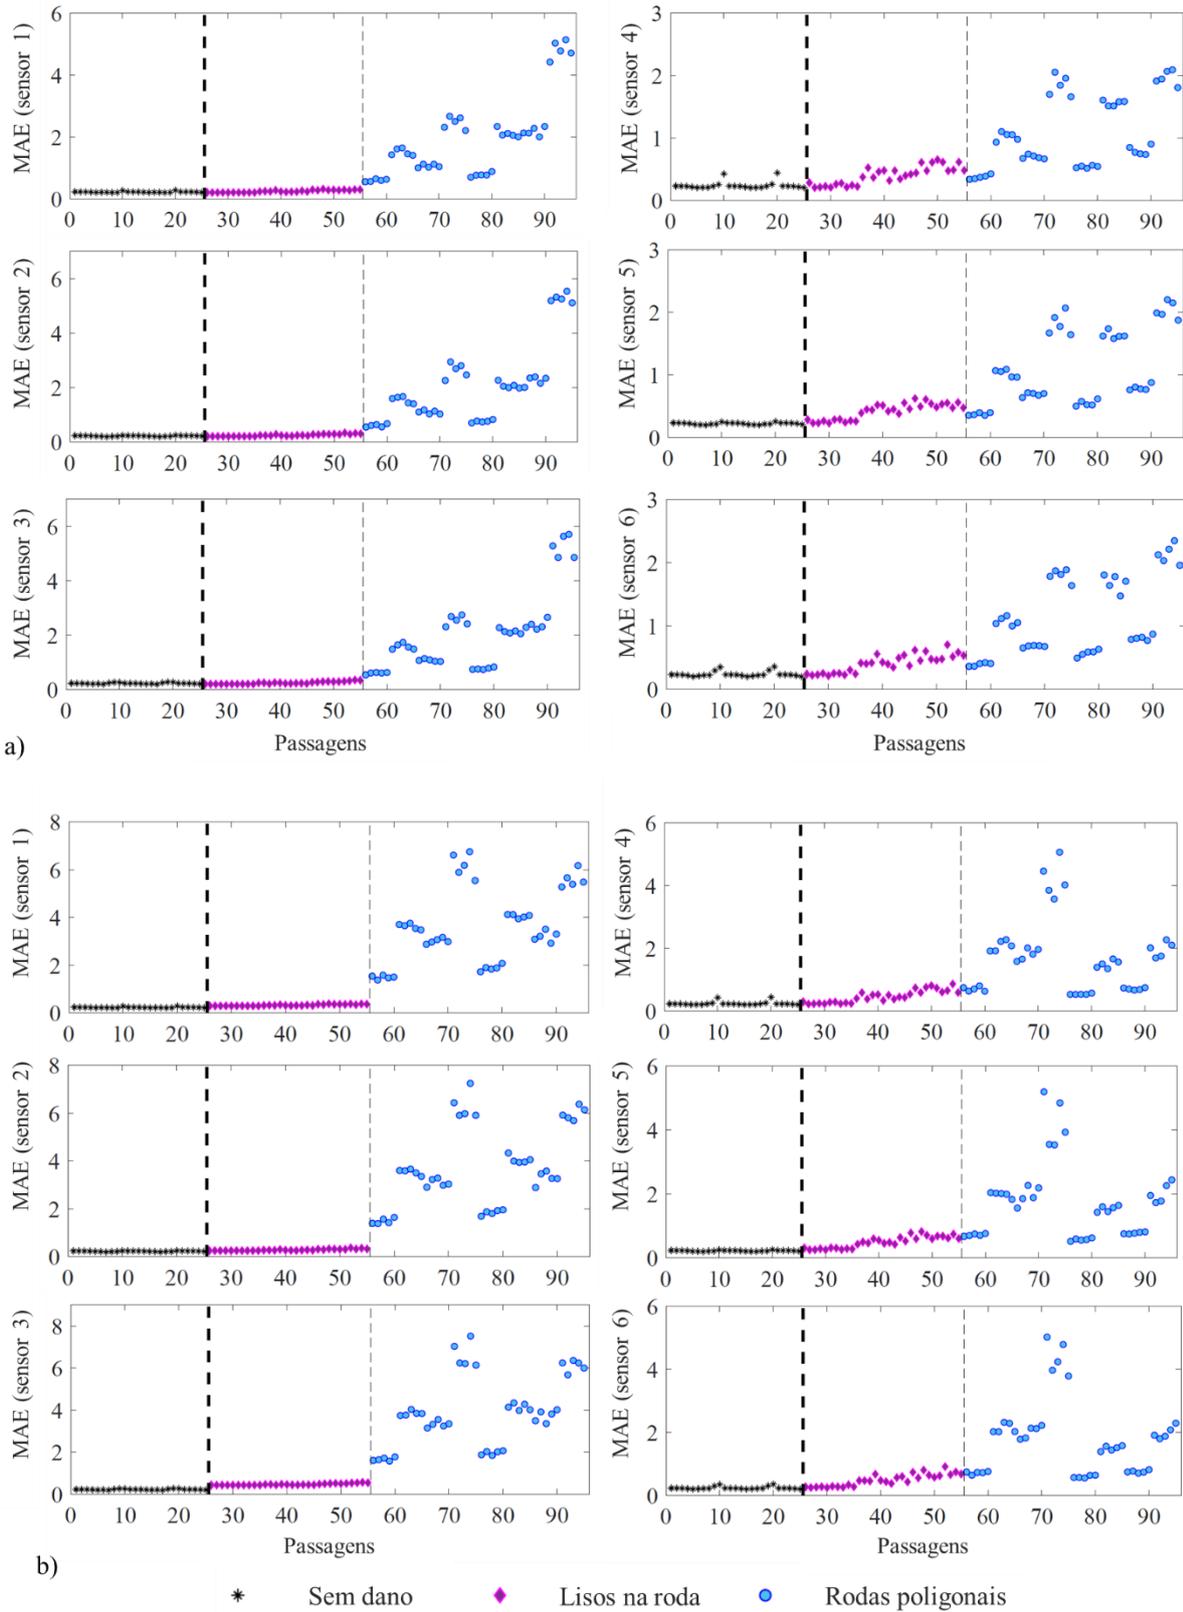


Figura 4-7 – Índice de dano (MAE) para passageiros com dano a uma velocidade de: a) 120 km/h; b) 200 km/h.

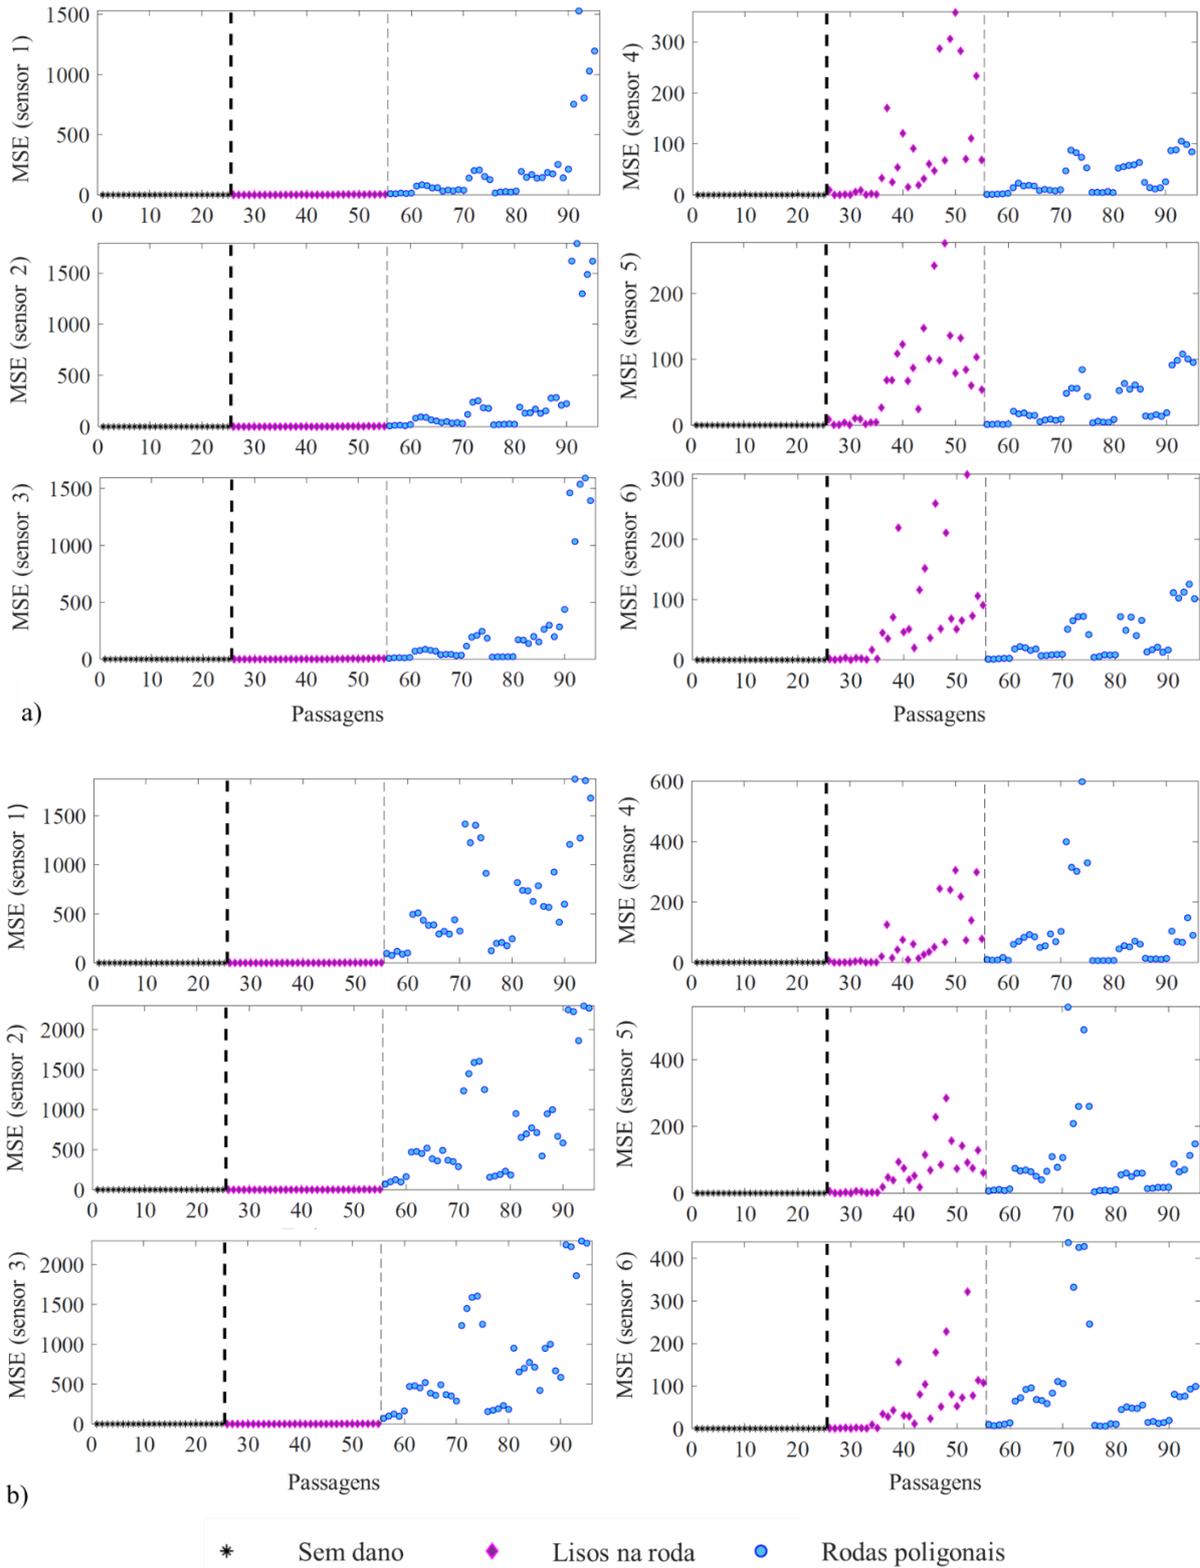


Figura 4-8 – Índice de dano (*MSE*) para passagens com dano a uma velocidade de: a) 120 km/h; b) 200 km/h.

#### 4.2.4 Fusão dos dados

O ID obtido com base nos dois tipos de erros cumulativos, demonstrou que os defeitos geométricos considerados induzem diferentes comportamentos dinâmicos ao longo do movimento. Atendendo que os efeitos poligonais provocam vibrações em ambos os carris, ao contrário de uma roda com lisos, onde este fenómeno não é tão evidente. Por consequência, foi necessário avaliar quantos pares de sensores permitem o correto desenvolvimento da metodologia.

O objetivo principal da fusão de dados é condensar os indicadores de dano extraídos, retendo as informações mais pertinentes. Para isso, a distância de Mahalanobis ( $DM$ ), descrita na secção 2.5.2, é aplicada para transformar os ID obtidos em cada sensor num único indicador, melhorando a capacidade de caracterizar rodas geometricamente imperfeitas. A aplicação desta técnica permite quantificar as semelhanças entre cenários de base e cenários com dano, sendo que quanto mais baixos forem os valores de  $DM$ , maiores são as semelhanças entre os cenários, contrariamente, quanto maior for a distância  $DM$ , maior é a distinção entre cenários. Inicialmente foram testadas várias possibilidades de fusão de dados, tanto para o  $MAE$  como para o  $MSE$ . Inicialmente foram fundidos os valores absolutos dos dois tipos de erros, o que não produziu resultados favoráveis. Seguidamente foram alterados espaço das variáveis com a aplicação de funções exponenciais, reais e polinomiais, sendo que a melhor solução encontrada foi colocar os valores do  $MSE$  numa escala logarítmica de base 10.

Para cada  $k$  sensor e para cada  $n$  passagem, é calculada a distância Mahalanobis resultando o escalar  $DM$ , caracterizado por um novo indicador de dano (ID) para cada simulação. A Figura 4.9 dispõe os resultados obtidos para a fusão de 1,2 e 3 pares de sensores, observando-se que quanto maior for o número de sensores, maiores são as distâncias entre cenários (Figura 4.9.c). Os resultados demonstrados foram obtidos com o modelo do autoencoder otimizado B4, contudo foram analisados os três tipos de fusão de sensores para todos os modelos AEE criados, concluindo-se que em todos os modelos AEE o aumento do número de sensores produz maiores distâncias entre cenários. A aplicação desta técnica de fusão demonstrou uma certa delicadeza quando a sua aplicação é efetuada através dos diferentes ID obtidos em cada modelo AEE, visível nas secções seguintes.

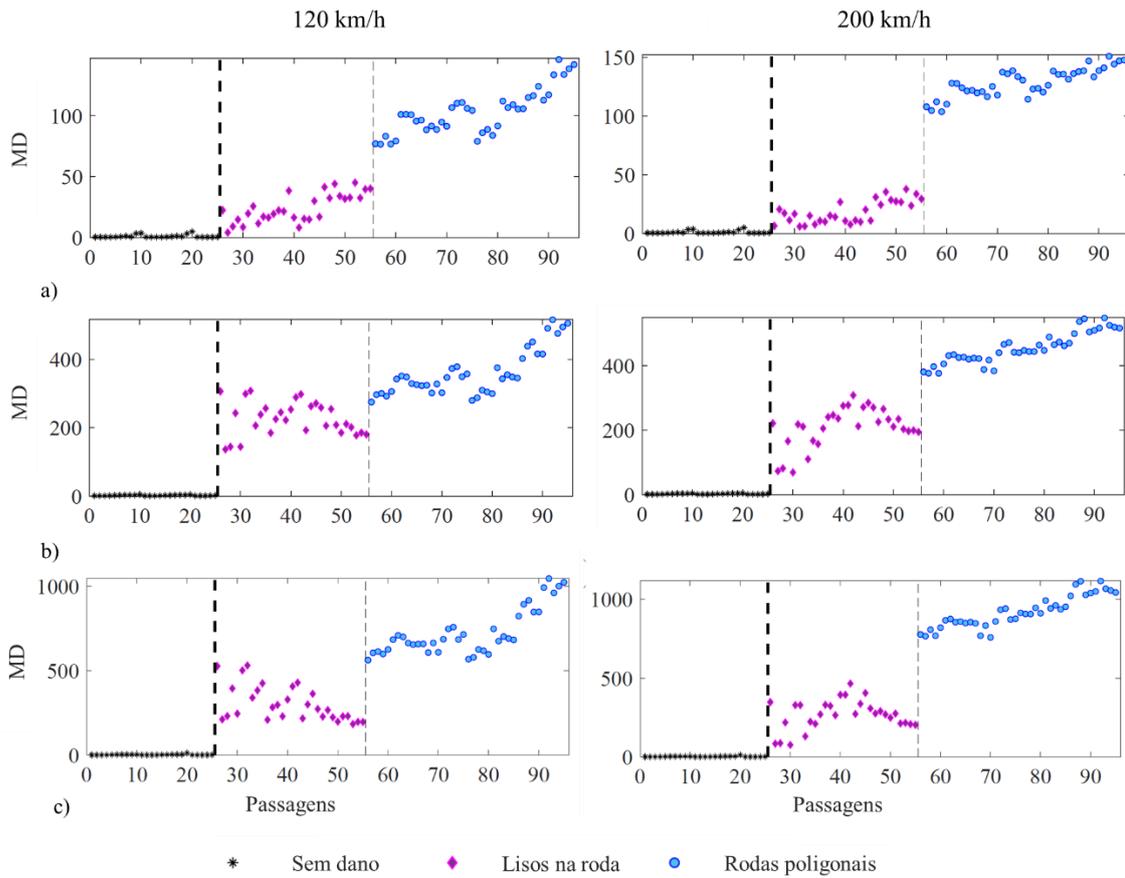


Figura 4-9 -Aplicação da distância de Mahalanobis para a fusão do MSE dos sensores: a) 1 e 4; b) 1,2,4 e 5; b) 1-6.

#### 4.2.5 Detecção do dano

Esta etapa da metodologia envolve uma correta detecção do dano com recurso à análise de outliers apresentada na secção 2.5.2.4.1. Neste processo foi utilizado o vetor *DM* correspondente à fusão do indicador de dano *MSE* de todos os sensores (1-6). Para uma correta distinção entre cenários estabeleceu-se o limite de confiança (*CB*), em função das vinte e cinco passagens de base, considerando que quando o *ID* é igual ou superior a *CB*, o indicador é caracterizado por um outlier. O nível de significância foi fixado em 1%, tendo em conta a aplicação desta técnica em vários estudos de detecção de danos (Mosleh et al., 2022a; Guedes et al., 2023; Silva et al., 2023, Mohammadi et al. 2023). Na Figura 4.10 apresentam-se os resultados obtidos nos melhores modelos AEE de cada grupo (A4, B4, C1, D1), verificando-se quais os *ID* situados acima ou abaixo do *CB* (representado como uma linha vermelha). Em nenhum modelo se verificou a presença de falsos negativos, somente falsos positivos. Nas Figuras 4.10a e 4.10b é visível a presença um falso positivo, exibido por uma passagem a 220 km/h com o veículo sujeito a metade da sua capacidade de carga. Nas Figuras 4.10c e 4.10d a identificação de rodas imperfeitamente circulares é realizada com um alto grau de sucesso.

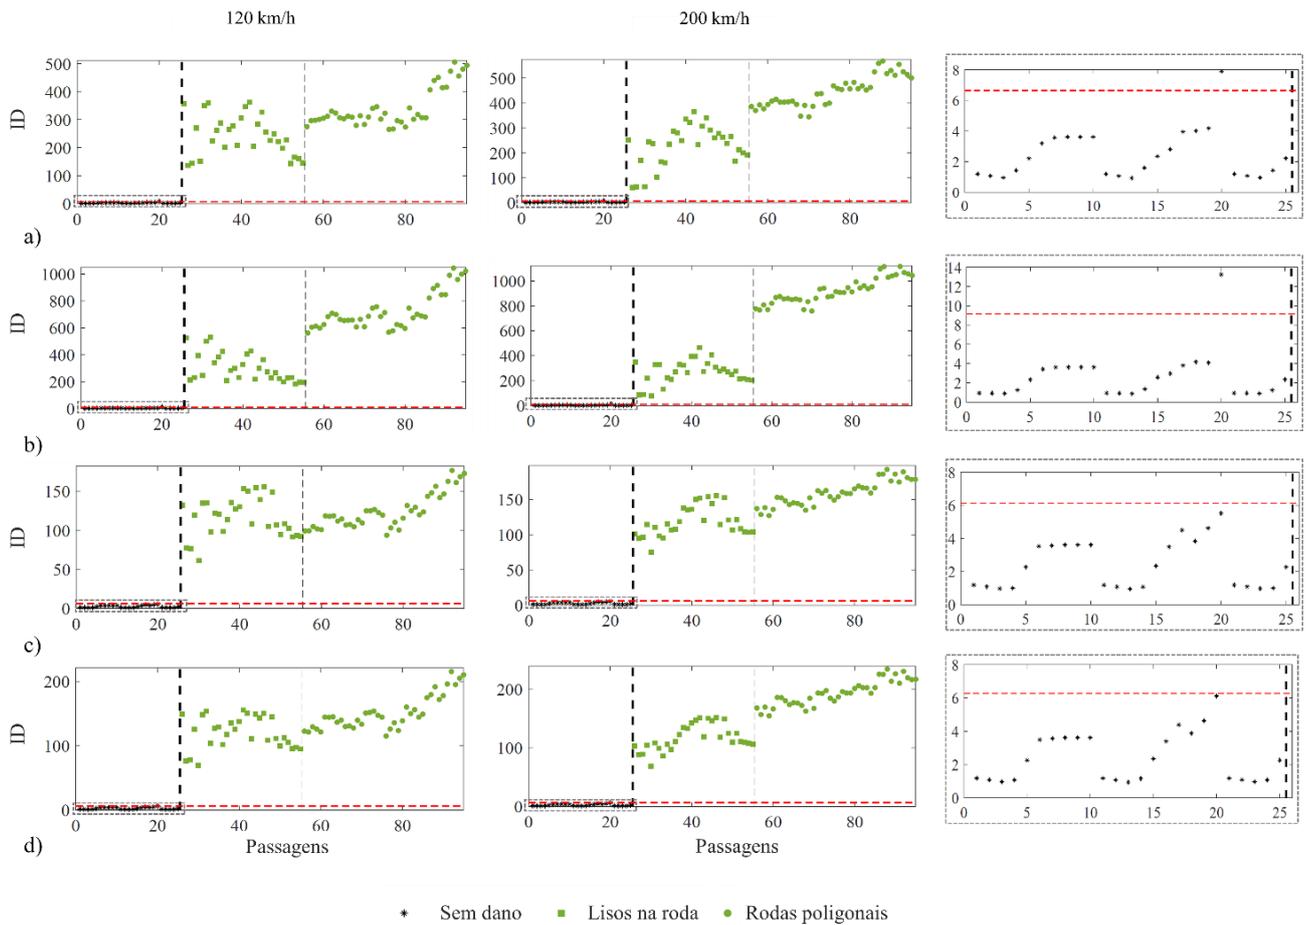


Figura 4-10 – Análise de outliers consoante o ID obtido no modelo AEE: a) A4; b) B4; c) C1; d) D1.

#### 4.2.6 Classificação do dano

Para a classificação de danos, é proposto um processo de agrupamento para dividir o conjunto de dados em grupos compactos e bem separados. Neste estudo, é adotada a técnica de agrupamento *k-means*, relatada na secção 2.5.2.4.2, utilizando a métrica de distância ‘city-block’. O agrupamento *k-means* opera como uma técnica de quantificação vetorial, com o objetivo de separar um conjunto de N pontos de dados em k clusters, com cada ponto de dados atribuído ao centroide mais próximo. Esta técnica de classificação automática é amplamente empregada em diversos trabalhos (Mosleh et al., 2022a; Akhter e Mohanty, 2023; Hu et al., 2023;).

A classificação do dano é executada em duas fases: i) aos dados provenientes da etapa anterior, análise de outliers, de forma a agrupar corretamente os três cenários existentes (sem dano, com lisos e com desgaste poligonal), designada como fase de identificação do tipo de dano; ii) após a identificação de cada tipo de dano, estes são avaliados individualmente através da aplicação da técnica de clusters à média do MAE obtido para cada passagem, permitindo uma classificação em função da severidade do dano.

#### 4.2.6.1 Identificação do tipo de dano

Os valores dos dados de entrada são inseridos matricialmente, caracterizados pelo ID obtido na fusão dos seis acelerómetros para as duas velocidades de circulação (120 e 200 km/h). Conforme abordado na secção 2.5.2.4.2 a definição do número de *k clusters* pode ser previamente definida, porém em trabalhos de monitorização de danos é impossível previamente conhecer quais os tipos de danos que ocorrerão. De forma a tornar o processo automático alguns índices de validação automática são vulgarmente utilizados, nomeadamente o índice de validação global ‘*Silhouette*’ (SIL) (Lars e Schubert, 2023). A Figura 4.11 mostra os clusters obtidos, em cada modelo AEE avaliado na análise de outliers.

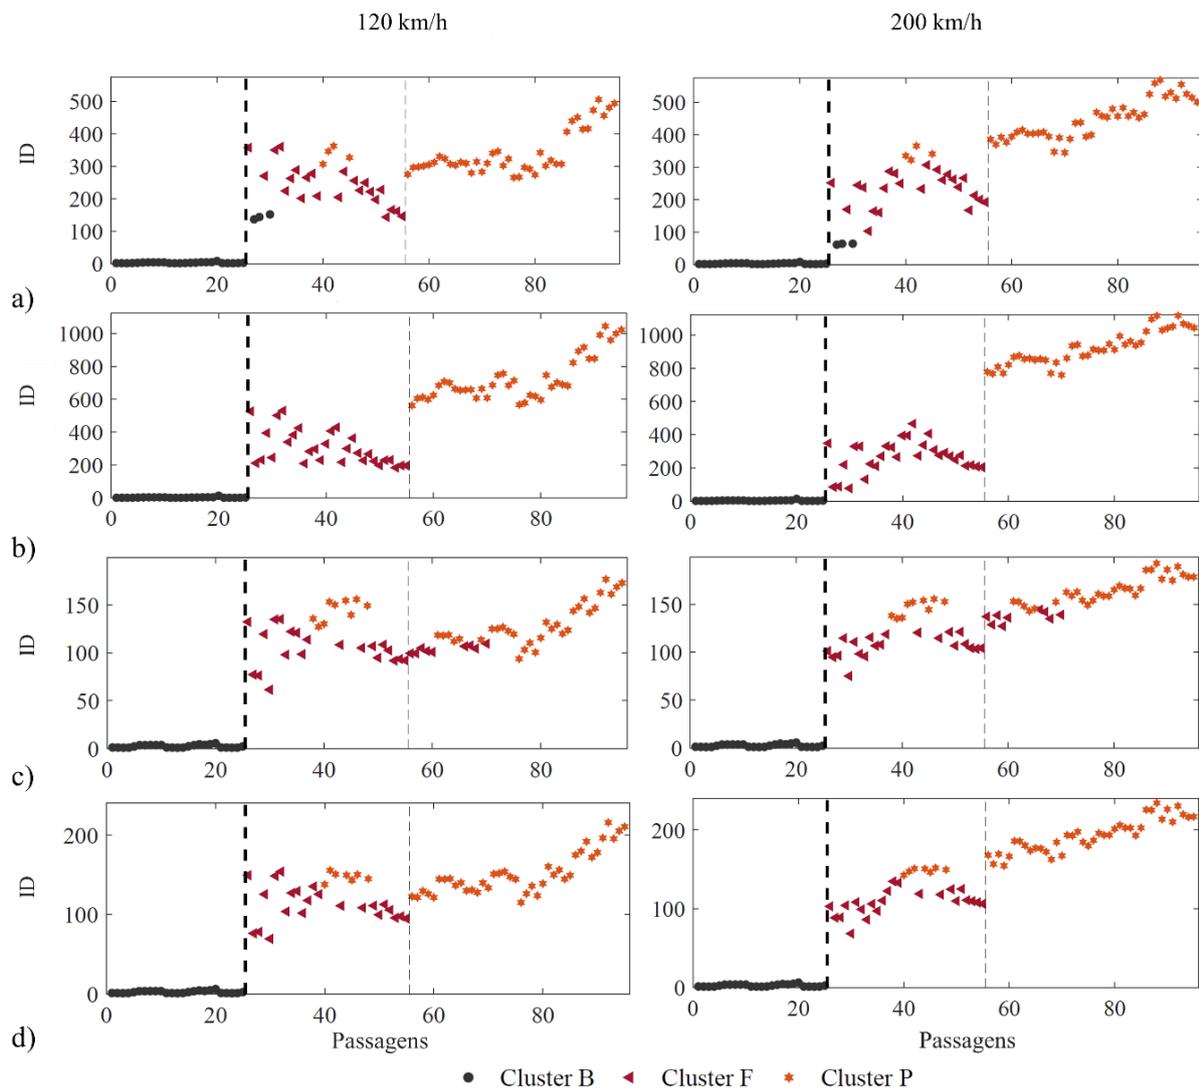


Figura 4-11 – Análise de Clusters consoante o ID obtido no modelo AEE: a) A4; b) B4; c) C1; d) D1.

Nas Figuras 4.11a e 4.11d identificam-se 6 e 7 falsas classificações nos indicadores de passagens com lisos (Grupo F), respetivamente. Referente aos indicadores de passagens com desgaste poligonal (Cluster P) destaca-se um correto agrupamento de todos os cenários. A Figura 4.11b apresenta os melhores resultados alcançados pelo algoritmo *k-means*, agrupando perfeitamente os dois tipos de dano e os

indicadores relativos a passagens sem dano (Cluster B). Este resultado foi o que permitiu decidir qual o modelo de AEE adequado para a identificação do tipo de dano. Os piores resultados foram com o AEE C1 (Figura 4.11c), apresentando-se 9 falsas classificações em ambos os cenários de dano.

#### 4.2.6.2 Nível de severidade

Após a classificação do tipo de dano é possível determinar a severidade de cada um com o modelo AEE otimizado. Nesta etapa, o processo de agrupamento também é definido matricialmente com a média do MAE (Figura 4.7) de todos os sensores em cada velocidade de circulação. O número de k clusters foi considerado como k=3 de forma a obter somente três níveis de severidade: baixa (Cluster 1), média (Cluster 2) e alta (Cluster 3), com recurso ao índice de validação global ‘CalinskiHarabasz’ (Calinski e Harabasz, 1974). Esta mudança do índice de validação, face à classificação do tipo de dano, deve-se ao espaço dimensional em que as variáveis se encontram.

A média do MAE de todos os sensores permite que a localização do dano não seja previamente conhecida, não tendo sido alvo de estudo no presente trabalho. O objetivo principal desta etapa é mostrar a influência de cada dano para a via. À medida que a amplitude da resposta dinâmica aumenta, o indicador de dano aumenta proporcionalmente, observando-se que valores superiores de ID correspondem a níveis de severidade mais altos.

Na Figura 4.12 apresenta-se a classificação referente aos casos de rodas com uma superfície lisa, com uma falsa classificação no Cluster 2, justificada pela alta amplitude da respetiva resposta dinâmica, equiparando-se a uma passagem de severidade alta (Cluster 3). A classificação dos níveis de severidade foi equivalente para as duas velocidades de circulação, identificando claramente os três cenários de lisos simulados (L1, L2, L3).

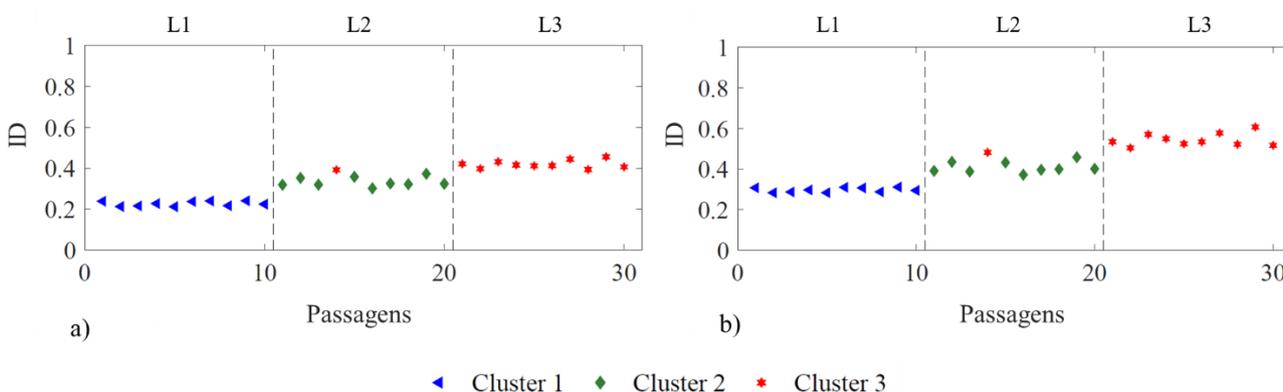


Figura 4-12 – Análise de Clusters para as passagens de lisos consoante o ID obtido no modelo AEE otimizado para uma velocidade de circulação de: a) 120 km/h; b) 200 km/h.

Nos casos de rodas com efeitos poligonais, o objetivo é entender quais ordens harmônicas que provocam maiores acelerações na via, consoante a amplitude do defeito. De acordo com os perfis poligonais apresentados na seção 3.3.2, a classificação é mostrada na Figura 4.13, onde rapidamente se observa que os harmônicos de H12-14 e H29-30 são mais prejudiciais do que os de H6-8 e H19-20 para as duas velocidades de circulação. Cada patamar de ID em cada tipo de harmônico representa cada amplitude do defeito considerada (Tabela 4.1), traduzindo que a presença de um efeito poligonal de ordem 6-8H e 19-20H, com amplitude de desgaste A2, apresenta o mesmo nível de severidade do que um efeito poligonal de ordem 12-14H e 29-30H com amplitude A1 (Cluster 2). Recordando que os perfis de irregularidades da ordem 6-8H e 12-14H foram medidos experimentalmente para uma velocidade de circulação de 120 km/h e os de 19-20H e 29-30H para uma velocidade de 200 km/h. Porém, a classificação para os níveis de severidade foi a mesma para as duas velocidades de circulação, o que permite identificar quais as ordens de harmônicos mais prejudiciais para a via. Denota-se ainda a sensibilidade do H12\_14 face ao aumento da velocidade, apresentando o ID superior ao H29\_30 para a velocidade de 200 km/h.

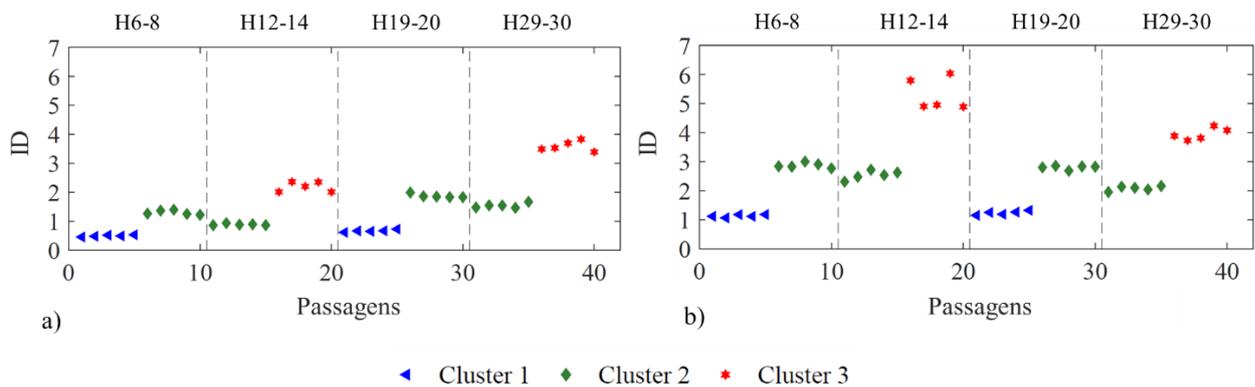


Figura 4-13 - Análise de Clusters para as passagens de desgaste poligonal consoante o ID obtido no modelo AEE otimizado para uma velocidade de circulação de: a) 120 km/h; b) 200 km/h.



## CAPÍTULO 5

### CAMPANHA EXPERIMENTAL

O presente capítulo destina-se à aplicação da metodologia desenvolvida, descrita no capítulo 4, a uma amostra de passagens experimentais. A campanha experimental consistiu na instrumentação de um troço de via, localizada em Avanca (coordenadas GPS: 40,79174° N, 8,5785° W), com o período de instalação realizado em regime noturno de modo a não comprometer a circulação ferroviária.

Primeiramente é descrito o procedimento da campanha experimental, explicando o processo de montagem dos dois tipos de sensores e a arquitetura do sistema que permite a extração das respostas dinâmicas. Seguidamente, são apresentados exemplos de respostas adquiridas pelos sensores, com uma breve comparação face às análises numéricas obtidas. Por fim, algumas das respostas extraídas são submetidas à metodologia de deteção de dano com o objetivo de validar a metodologia desenvolvida.

#### 5.1 COMPOSIÇÃO DO SISTEMA DE MONITORIZAÇÃO

Face às condições e objetivos do projeto, implementou-se um sistema de monitorização de baixo custo e com ações de manutenção independentes da circulação ferroviária. O troço de via instrumentado compreende um total de seis acelerómetros do tipo ICP modelo 356A02 da PCB Piezotronics Inc incorporados num sistema de fixação, e quatro extensómetros de colar, modelo C4A-06-125SL-350-39P da VPG Micro-Measurements.

##### 5.1.1 Acelerómetros

Os acelerómetros encontram-se associados a um sistema fixação, designado como “garra”, introduzido na base do carril, a meio vão entre travessas. Este tipo de sistema de fixação permite uma ligação completa e duradoura, de modo que as ações de manutenção futuras não resultem na suspensão da operação ferroviária. A integração destes sensores viabiliza a capacidade de transmitir os sinais de acelerações obtidos aquando de uma passagem ferroviária. A Figura 5.1 apresenta a recolha fotográfica do conjunto fixador-acelerómetro implementado in situ, assim como um desenho esquemático dos seus elementos constituintes.

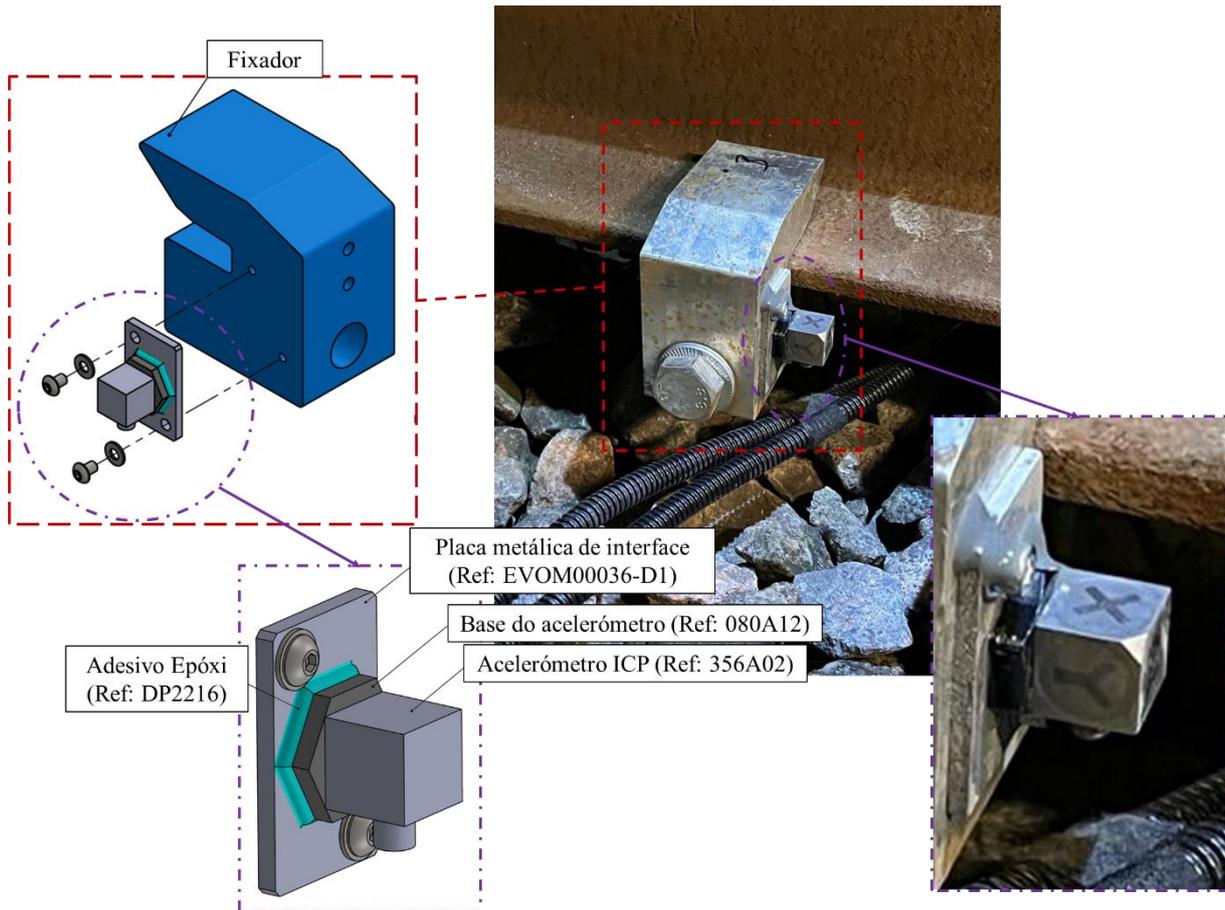


Figura 5-1 – Sistema fixador - acelerómetro.

### 5.1.2 Extensómetros

Os extensómetros foram colados no ponto correspondente ao meio vão entre travessas na base do carril, com base em duas principais etapas: a) preparação da superfície de aplicação; b) aplicação do instrumento de medição. A Figura 5.2 apresenta os materiais utilizados, compreendendo o modelo de extensómetro da Micro Measurements (Figura 5.2a), kit de colagem/adesivos (Figura 5.2b) e kit de proteção (Figura 5.2c). Na Figura 5.3 expõe-se o procedimento utilizado em cada uma das etapas:

- Preparação da superfície (Figura 5.3.a):
  - 1) polição da superfície com uma lixa mecânica; 2) limpeza da superfície polida; 3) aspeto final da superfície de medição;
- Aplicação do Extensómetro (Figura 5.3.b):
  - 1) aplicação dos adesivos; 2) medição da resistência elétrica; 3) aplicação do revestimento protetor.



Figura 5-2 – Materiais utilizados: a) Extensómetro- C4A-06-125SL-350-39P; b) Adesivos- M-Bond 200 Kit; c) Revestimento protetor- M-Coat F Kit.

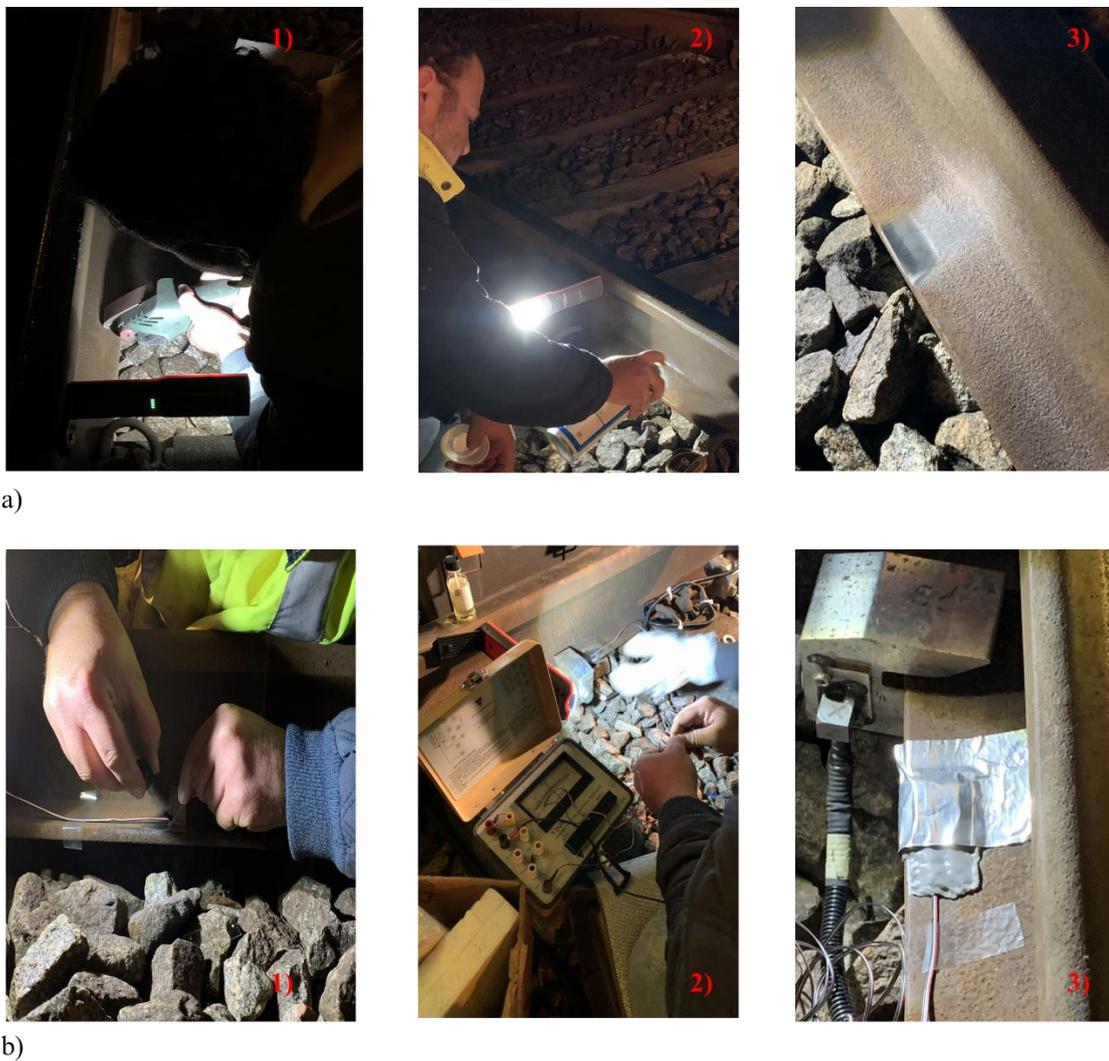


Figura 5-3 – Procedimento: a) Preparação da superfície; b) Aplicação do Extensómetro.

### 5.1.3 Arquitetura do sistema

Os acelerómetros são caracterizados de A1 a A6, três no carril direito (A1-A3) e três no carril esquerdo (A4-A6), sendo que o A1 é composto por um acelerómetro triaxial, medindo as acelerações da via nas três direções (vertical, longitudinal e transversal), já os restantes (A2-A6), são uniaxiais, medindo apenas a aceleração no sentido vertical. Os extensómetros são colocados apenas nos quatro primeiros pontos de aplicação, no carril direito E1-E2 e no carril esquerdo E3-E4. O número mínimo de sensores favorece uma redução nos custos de instalação e manutenção, assegurando-se que a qualidade dos resultados não é comprometida. Por sua vez, a configuração dos sensores foi implementada de modo flexível de forma que possa ser ajustada para melhorar o desempenho dos algoritmos de IA.

A conceptualização deste sistema de monitorização é representada esquematicamente na Figura 5.4, viabilizando a capacidade de adquirir, digitalizar, armazenar (temporariamente) e transmitir os resultados obtidos. Os diferentes aparelhos constituintes do sistema são devidamente identificados por:

- A. Acelerómetros (A) e Extensómetros (E): devidamente identificados e numerados, A1-A6 e E1-E4;
- B. Módulo de aquisição de dados: permite efetuar a conversão do sinal analógico em digital, estabilizando a interface entre os sensores, transmitindo-os para a gateway (C);
- C. Gateway: constituída por um sistema operativo interno com a principal função de agilizar as operações das aplicações que irá correr e gerir os diferentes dispositivos, sejam de armazenamento, comunicações ou processamento. As comunicações serão baseadas em 4G ou 5G (se disponível) para permitir uma transmissão contínua de dados em tempo real.
- D. Cloud: agregação das comunicações e serviço de notificações que constitui a base de dados;
- E. PC: download das respostas dinâmicas, posteriormente importadas para o MATLAB® (2018) para serem sujeitas à metodologia de identificação de dano.

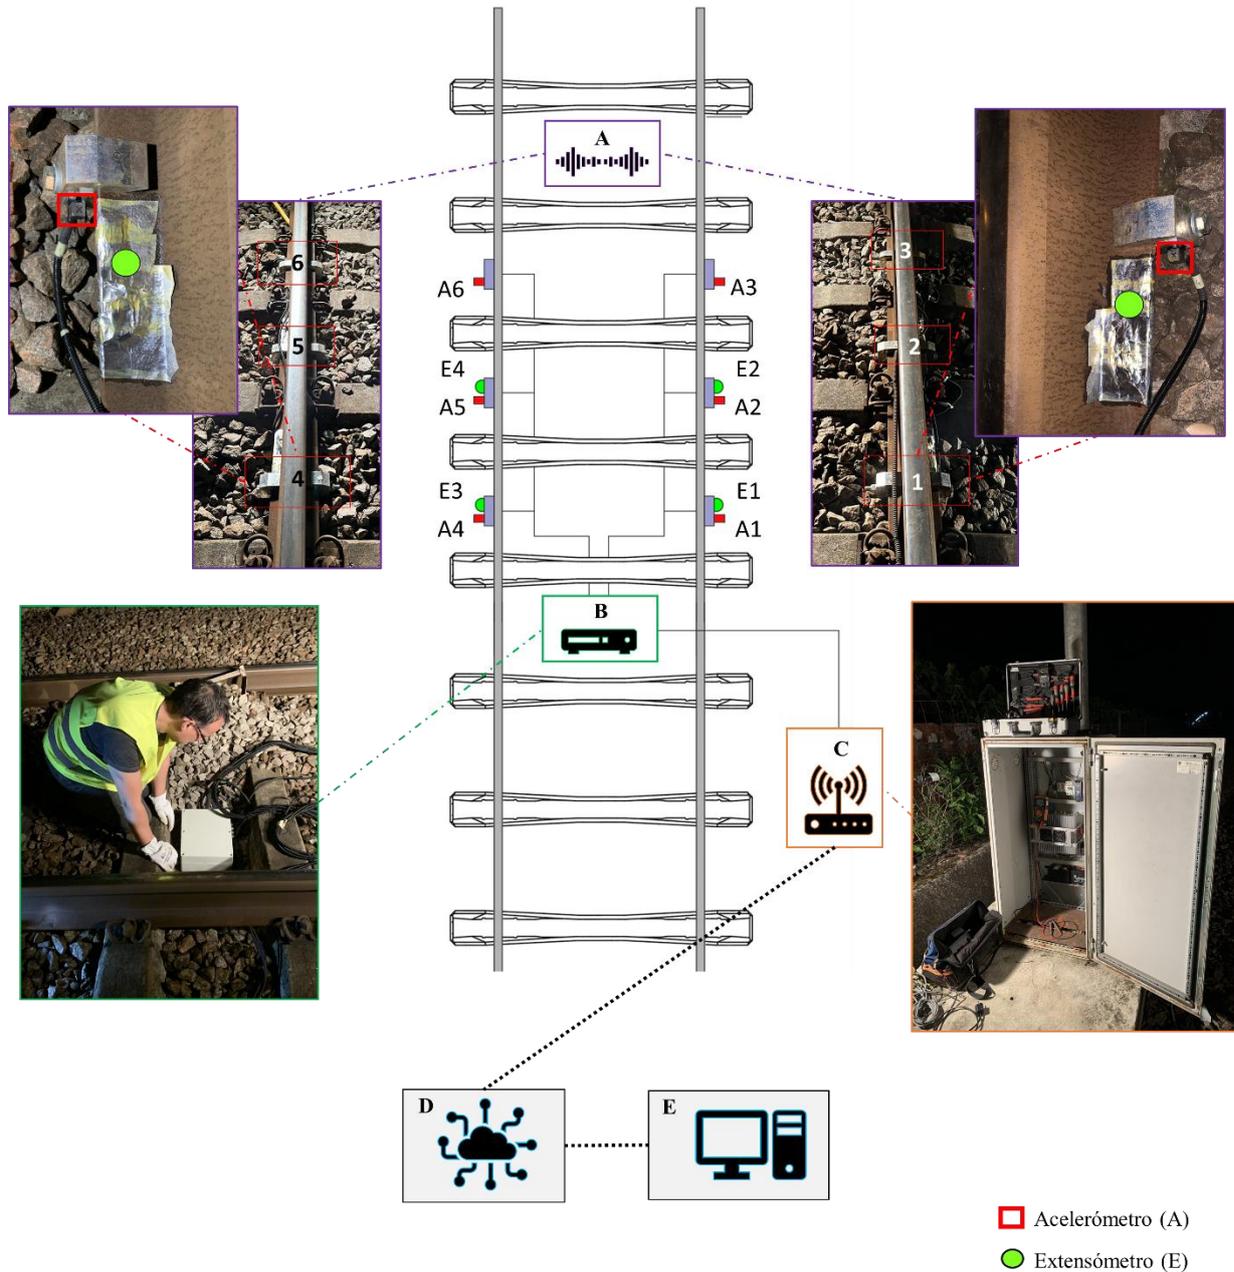


Figura 5-4 –Representação esquemática do troço de via instrumentado. A) Acelerómetros A1-A6 e Extensómetros E1-E4; B) Módulo de aquisição de dados; C) Gateway; D) Cloud; E) PC.

## 5.2 RESPOSTAS EXPERIMENTAIS

As respostas experimentais são extraídas com uma frequência de amostragem de aproximadamente 2 kHz. Sendo posteriormente cortadas e filtradas com o mesmo filtro utilizado nas respostas numéricas (filtro digital passa-baixo Chebyshev tipo II com frequência de corte de 1500 Hz). A Figura 5.5 apresenta graficamente a resposta de acelerações referente a duas passagens (5.5a e 5.5b), antes (azul) e após filtragem e corte (preto).

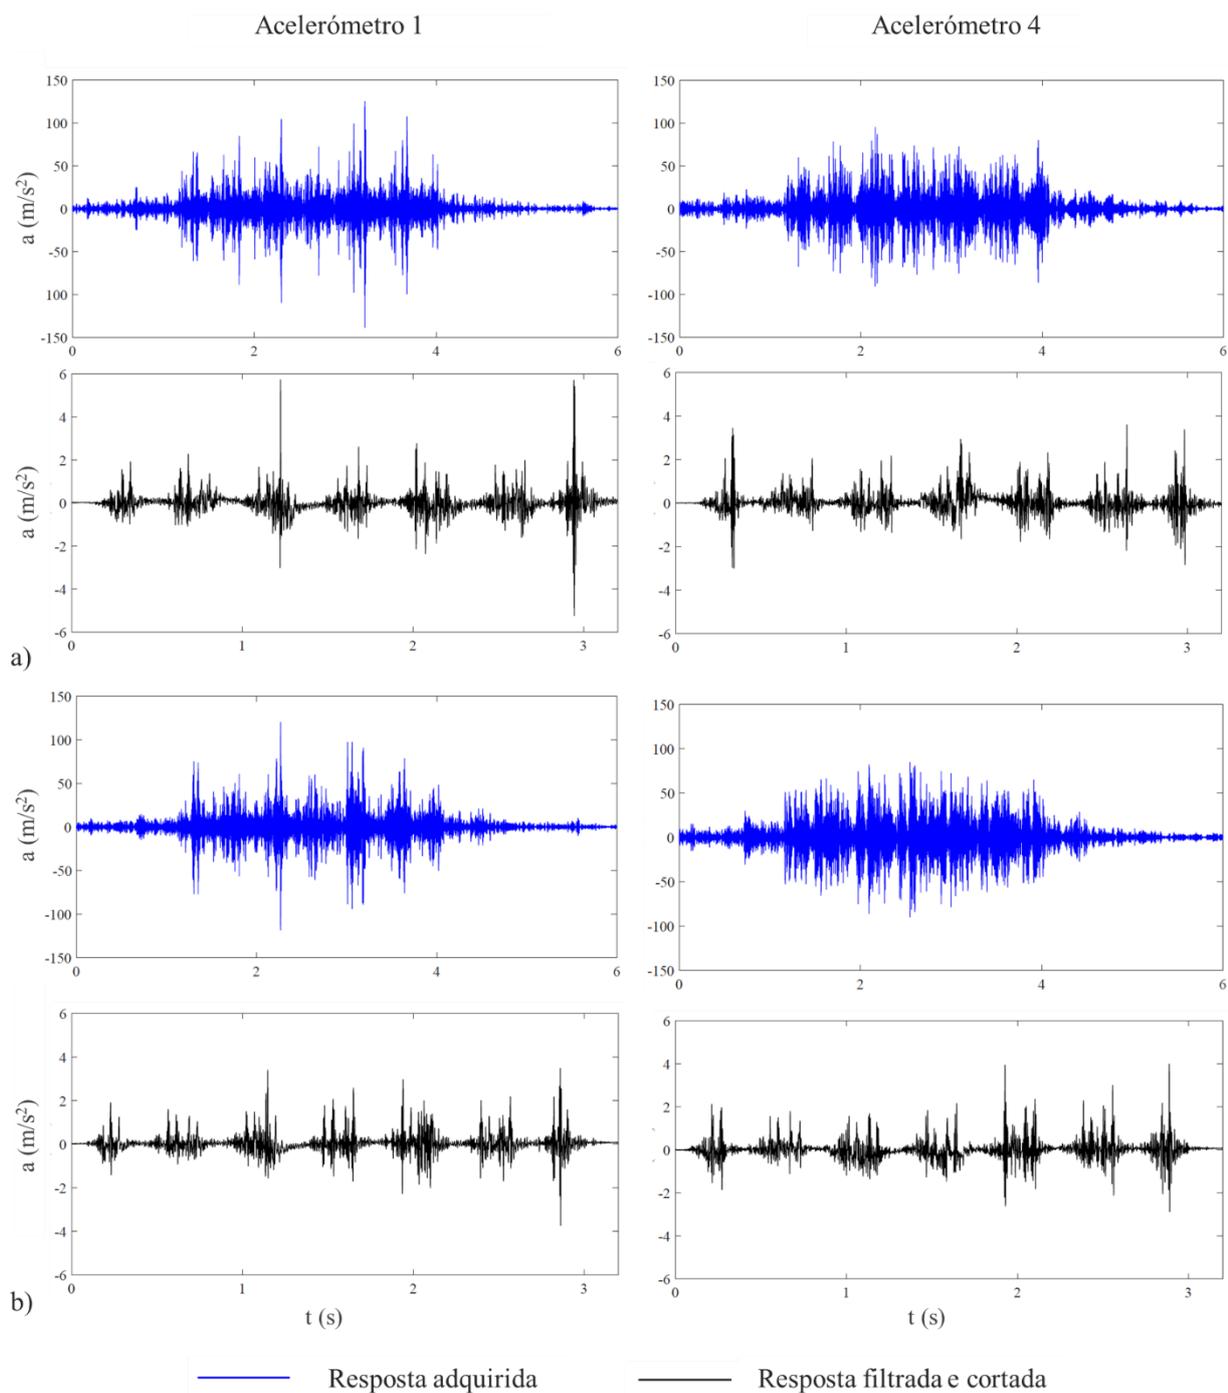


Figura 5-5 - Respostas de acelerações do veículo Alfa pendular: a) Passagem 171 (Tabela 5.1); b) Passagem 183 (Tabela 5.1).

Comparando as respostas experimentais com as repostas numéricas (Figura 4.3) destacam-se diferenças relativas ao aspeto gráfico, à amplitude da resposta e na continuidade da resposta ao longo do tempo.

### 5.3 APLICAÇÃO DA METODOLOGIA

A metodologia apresentada no capítulo 4 é aplicada a uma amostragem de diferentes respostas experimentais extraídas dos acelerómetros 1 e 4, dado que foram os acelerómetros que arrecadaram uma melhor sensibilidade de aquisição de dados ao longo do período instrumental. Tendo em conta o fluxograma da metodologia desenvolvida (Figura 4.1), as respostas experimentais adquiridas, assim como as respostas numéricas anteriormente analisadas, são sujeitas ao procedimento exigido. Apenas serão apresentados os resultados referentes às etapas: i) Aquisição de dados; v) Detecção de dano e vi) Classificação do dano.

Primeiramente, referente à etapa i) Aquisição de dados, as respostas numéricas, já processadas em função da posição (secção 4.2.1), foram sujeitas a uma decimação com a função ‘decimate’ do MATLAB® (2018) proporcionando uma redução da amostragem da resposta por um fator  $r$ , dado pela relação entre frequências de amostragens:

$$r = \frac{f_{\text{teórico}}}{f_{\text{experimental}}} = \frac{10000}{2000} = 5 \quad (5-1)$$

Em que  $f_{\text{teórico}}$  e  $f_{\text{experimental}}$  correspondem à frequência de amostragem das passagens adquiridas numericamente e experimentalmente, respetivamente.

Relativamente às respostas experimentais, estas foram sujeitas à mesma mudança do espaço das variáveis, explicado na secção 4.2.1. As respostas  $a(t)$  extraídas são passadas para  $a(d)$ , cortadas a partir do mesmo ponto inicial até que sejam percorridos 165 metros considerados na análise numérica. Porém o incremento espacial considerado destas respostas,  $\Delta d_{\text{experimental}}$ , é  $r$  vezes maior do que o incremento espacial das respostas numéricas,  $\Delta d_{\text{teórico}}$ :

$$\Delta d_{\text{experimental}}(t) = \Delta d_{\text{teórico}}(t) \cdot r = 0.0062 \cdot 5 = 0.031 \text{ m} \quad (5-2)$$

Este processo só é possível de ser implementado através de um cálculo prévio da velocidade média de circulação com o auxílio das respostas de extensões obtidas nos quatro extensómetros. Dado que o sinal é cortado imediatamente antes da passagem do comboio, através da função ‘findpeaks’ e da função ‘max’, é possível encontrar os instantes referentes à passagem do primeiro e do último eixo do veículo. Visto que a distância entre eixos é previamente conhecida (146.70 metros), é possível estimar uma velocidade média de circulação aquando da passagem. A Figura 5.6 representa esquematicamente a resolução do problema. As informações relativas às passagens analisadas encontram-se organizadas na Tabela 5.1, consoante a data e hora da passagem do veículo, assim como o valor da velocidade média de circulação calculado.

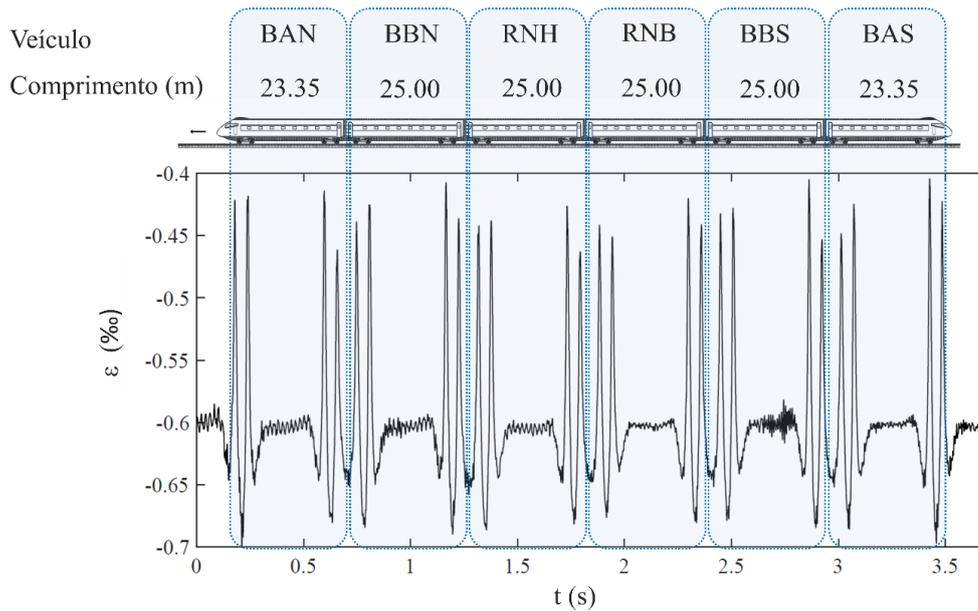


Figura 5-6 - Representação esquemática da obtenção da velocidade de circulação através da resposta de extensões referente à passagem nº23.

Tabela 5.1 – Amostragem de passagens experimentais.

Passagem nº	Data (AA_MM_DD_hh_min)	Velocidade (km/h)
166	2023_06_26_10_13	198,41
167	2023_06_26_14_16	195,41
168	2023_06_27_10_11	132,59
169	2023_06_27_12_15	195,89
170	2023_06_28_10_11	189,80
171	2023_07_06_15_12	196,10
172	2023_07_07_10_21	195,40
173	2023_07_08_10_11	196,13
174	2023_07_09_14_14	192,10
175	2023_07_10_10_13	196,03
176	2023_07_10_14_12	198,71
177	2023_07_11_14_14	197,74
178	2023_07_12_10_11	195,82
179	2023_07_13_10_14	199,07
180	2023_07_13_15_14	198,39
180	2023_07_14_15_14	193,30
182	2023_07_15_10_11	195,09
183	2023_07_15_14_11	197,60
184	2023_07_15_15_12	189,19
185	2023_07_16_14_08	198,29
186	2023_07_17_10_12	159,66
187	2023_07_17_14_14	195,63

Atendendo à amostragem apresentada na Tabela 5.1 é de notar que o Alfa pendular circula no troço de via instrumentado, numa grande parte das vezes, com uma velocidade de 200 km/h, aproximadamente. No entanto, determinou-se uma passagem a 132 km/h (passagem 3) e outra a 160 km/h (passagem 21), que evidenciam algumas restrições de operação no momento das passagens.

Este conjunto de dados adquirido via experimental são inseridos na metodologia desenvolvida em simultâneo com as simulações numéricas de modo a obter uma comparação entre os diversos cenários, tanto experimentais como numéricos. Os resultados demonstrados caracterizam-se pelas passagens numéricas referentes a: cenários sem dano (passagens 1-25), cenários de lisos (passagens 26-85) e cenários de poligonização (passagens 86-165), com as velocidades de 120 e 200 km/h agregadas para cada cenário de dano. As últimas 22 passagens (passagens 166-187) caracterizam-se pelas passagens experimentais recolhidas.

Os resultados obtidos para a etapa v) Detecção de dano, com recurso a uma análise de outliers, são apresentados na Figura 5.7. Sendo que foi efetuada uma nova análise de sensibilidade ao modelo AEE mais adequado aos dados, visto que a frequência de amostragem mudou. Os modelos A1, A3, B2 e B3 (Tabela 4.2) apresentaram os melhores resultados, face aos restantes. Atendendo que em todos se verificou a possibilidade de agrupar em  $k$  clusters os diferentes tipos de dano, somente com algumas falhas de classificação. Os resultados apresentados foram obtidos com o modelo B3, dado que é um autoencoder com uma arquitetura semelhante ao usado nas análises numéricas.

Dado que esta análise deriva do ID determinado na fusão dos sensores com a distância de Mahalanobis, esta apenas foi aplicada para fundir o primeiro par de acelerómetros (A1-A4). Este pormenor, juntamente com a redução da frequência de amostragem das respostas dinâmicas, proporcionam uma redução do indicador de dano referente às passagens de rodas com lisos, ocorrendo a presença de falsos negativos para estes cenários e dois falsos positivos referente aos cenários de base (Figura 5.7- ZOOM A). No que diz respeito às passagens experimentais, estas são caracterizados por indicadores de dano situados abaixo do limite estatístico estabelecido, caracterizando-se por passagens sem correlações com dano (Figura 5-7-ZOOM B).

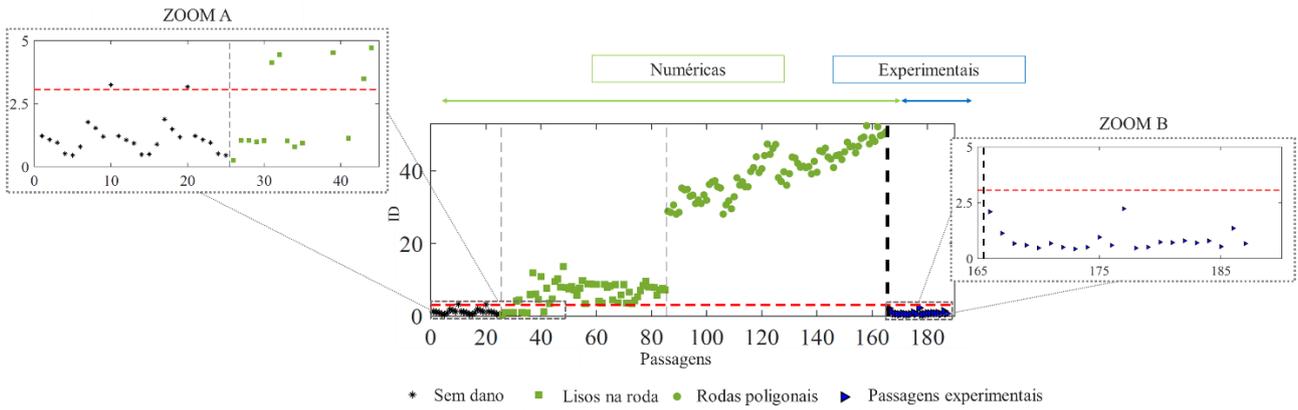


Figura 5-7 - Análise de outliers.

Posteriormente, estes resultados obtidos são sujeitos à análise de clusters da etapa vi) Classificação de danos, apresentados na Figura 5.8. Os resultados apresentados mostram que o Cluster B agrupa todos os cenários sem dano, tanto experimentais como numéricos, juntamente com alguns cenários de lisos. Já os restantes cenários de lisos são agrupados com o Cluster F e cenários de rodas poligonais são totalmente agrupados com o Cluster P. A fusão de um par de sensores compromete a sensibilidade do algoritmo *k-means* face à distância entre cenários não ser tão acentuada comparativamente ao ID obtido para a fusão dos seis acelerómetros, comprometendo uma correta classificação. Realça-se ainda a facilidade em agrupar os dados com as duas velocidades de circulação (120 km/h e 200 km/h) incluídas em simultâneo.

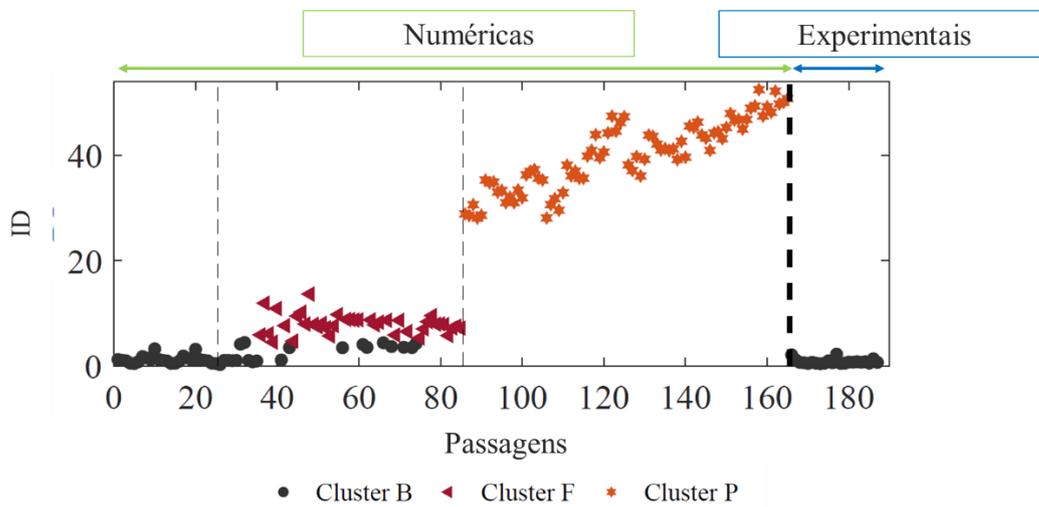


Figura 5-8 – Análise de clusters.

## CAPÍTULO 6

### CONSIDERAÇÕES FINAIS

#### 6.1 CONCLUSÕES

A presente dissertação enquadra-se no âmbito do projeto de I&D Way4SafeRail, com o objetivo de desenvolver uma metodologia não supervisionada de identificação de defeitos geométricos nas rodas do veículo Alfa pendular com base nos efeitos dinâmicos induzidos pelo veículo na via. O algoritmo desenvolvido é constituído por uma combinação híbrida de técnicas de inteligência artificial, com o potencial de ser aplicado de um modo contínuo e automático.

No Capítulo 2, “Estado da arte”, foram abordados os diferentes tipos de sistema de monitorização usualmente aplicados na engenharia ferroviária, sistemas wayside e on-board. Atendendo à revisão bibliográfica, percebeu-se que os sistemas wayside são mais vantajosos de serem aplicados por permitirem monitorizar todos os veículos que circulem sobre a via instrumentada. Ainda neste capítulo, foi apresentada uma formulação teórica relativa à dinâmica estrutural, compreendendo os tipos de modelos dinâmicos da via e do veículo, assim como o processo da interação dinâmica entre estes dois elementos constituintes do sistema. Abordaram-se os defeitos geométricos vulgarmente detetados na circulação ferroviária (lisos e poligonização) e qual o seu comportamento face as suas geometrias com o aumento da velocidade de circulação. Por fim, o capítulo foi encerrado com uma revisão teórica referente às diferentes técnicas utilizadas no desenvolvimento da metodologia com principal destaque para o Autoencoder Esparso e para a sensibilidade do algoritmo *k-means* face a dispersão dos dados a serem agrupados.

No Capítulo 3, “Modelação numérica”, foram descritos os modelos dinâmicos do veículo e da via utilizados no presente trabalho, assim como as irregularidades geométricas modeladas em diferentes rodas do veículo. Tanto o veículo como a via foram previamente modelados no ANSYS® (2010) como uma associação de corpos rígidos. Refere-se ainda o algoritmo que permitiu simular passagens ferroviárias, designado como *VSI-Vehicle-Structure Interaction Analysis*, processado em MATLAB® (2018), descrevendo-se de forma sucinta a sua formulação para a resolução do problema de interação dinâmica roda-carril.

No Capítulo 4, “Metodologia de identificação de dano”, descreveu-se toda a metodologia desenvolvida em MATLAB® (2018). Inicialmente foram apresentados os diversos cenários simulados, tanto de dano como sem dano, que serviram de input à metodologia criada. Seguidamente, o capítulo referido foi subdividido nas diferentes etapas que compõe a metodologia, identificando-se os seguintes aspetos em cada uma das etapas:

- (i) Aquisição de dados: a transformação da resposta de acelerações do domínio temporal para o domínio espacial permitiu uniformizar todas as respostas em relação à amostragem que as compõe, obtendo-se o vetor das acelerações em função do comprimento do espaço percorrido.
- (ii) Aplicação de um Autoencoder Esperso: com base nas várias arquiteturas de rede e hiperparâmetros distintos (Tabela 4.2) foi possível determinar qual a rede mais adequada ao objetivo que se enfrentava. Notou-se uma relação entre a alternância dos hiperparâmetros face ao número de neurónios e de épocas de treino (iterações). O aumento da grandeza destas últimas variáveis evidencia a não necessidade de altos coeficientes de esparsidade ( $\beta$ ), valores próximos de zero na ordem da centésima para regularizadores de pesos ( $\lambda$ ) e uma percentagem de ativação do neurónio ( $\rho$ ) relativamente baixa. Caso contrário, quanto menor for o número de neurónios e de épocas de treino, maior é a necessidade de expressar altos coeficientes  $\beta$  e  $\rho$ , juntamente com valores inferiores à ordem da milésima para  $\lambda$ . Realça-se a aleatoriedade do processo de treino deste tipo de Autoencoder, dado que existe uma infinidade de combinações possíveis, porém dentro de uma amostra de parâmetros é possível determinar aquele que mais se adequa ao contexto do problema.
- (iii) Indicador de dano: a obtenção do indicador de dano foi garantida através de uma diferença cumulativa entre as respostas (não usadas na fase de treino) originais e reconstruídas pelo modelo AEE treinado, denominado por erro de reconstrução. As diferenças cumulativas foram obtidas por dois somatórios distintos: i) MAE: dado por um erro cumulativo absoluto; ii) MSE: garantido pelo somatório das diferenças quadráticas entre respostas. Esta alternância permitiu estabelecer um princípio para a classificação do tipo de dano, dado que indicadores de dano referentes às passagens com lisos tornaram-se mais evidentes com o uso do MSE. Já o MAE, como é obtido por uma diferença absoluta, evidencia com maior facilidade a severidade do dano analisado.
- (iv) Fusão dos dados: de modo a aumentar a sensibilidade do dano, foi aplicada a distância de Mahalanobis para fundir os indicadores de dano obtidos com o MSE de todos os sensores. Nesta etapa destacou-se a necessidade de colocar previamente os valores do MSE numa escala logarítmica de modo a alterar o espaço das variáveis e aumentar a distância entre

cenários do mesmo tipo. Foi ainda realizada uma análise de sensibilidade ao número de sensores ótimos a serem utilizados, percebendo-se, claramente, que quanto maior for o número de sensores, maiores serão as distâncias entre cenários, dado ao aumento da informação;

- (v) Deteção do dano: realizada com recurso a uma análise de outliers, estabeleceu-se um limite estatístico (CB) em função dos índices de dano obtidos nos cenários de base. Foi na presente etapa que os diversos modelos AEE estabeleceram diferenças consideráveis. Mostrou-se que dois dos melhores modelos AEE (C1 e D1) foram capazes de garantir que todos os cenários de base fossem inseridos abaixo do limite estatístico estabelecido (CB) ao contrário dos outros dois modelos em que se evidenciou a presença de um falso positivo (A4 e B4). Contudo, em todos os modelos, não se detetou a presença de falsos negativos.
- (vi) Classificação do dano: etapa final da metodologia que permite classificar o dano quanto ao seu tipo e quanto à sua severidade, após a deteção do mesmo. É aplicada uma técnica de clusters com o algoritmo *k-means*, evidenciando-se as diferenças que os modelos AEE proporcionaram face a dispersão dos dados. Foi nesta etapa que se estabeleceu o modelo AEE otimizado (B4), dado que garante uma correta classificação dos dados em três grupos distintos. Realça-se ainda a necessidade de alterar o índice de validação global para aplicação do cluster, justificado pelo espaço vetorial das variáveis ID, na fase da identificação (MSE) e na fase da classificação por níveis de severidade (MAE).

Por fim, no Capítulo 5, “Campanha experimental”, apresentou-se toda a arquitetura do sistema de monitorização implementado in situ. Abordando-se ainda a aplicação da metodologia desenvolvida a uma amostra de passagens experimentais, obtendo-se, indicadores relativos a passagens sem dano. A aplicação da metodologia foi executada com a fusão do primeiro par de acelerómetros (1-4), dado que foram os aparelhos que apresentavam melhor calibração. A diferença entre frequências de amostragem levou a uma redução dimensional da resposta de acelerações, proporcionando a mudança do AEE otimizada para o modelo B3. Por consequência, a alternância da amostragem, assim como a existência de falsos negativos (passagens com lisos) dificulta o processo de cluster com base no algoritmo *k-means*.

Conclui-se ainda que o comportamento dinâmico existente entre a interação veículo-via apresenta uma grande variabilidade face às condições de circulação. Os defeitos geométricos analisados poderão originar fenómenos de instabilidade caso sejam atingidas frequências ressonantes do sistema. Referente às análises numéricas, provou-se que a metodologia apresenta bons resultados na identificação do dano, conseguindo ter uma representação bem definida da condição fronteira entre cenários de com e sem dano. Demonstrou-se a eficácia da mesma considerando defeitos geométricos em diferentes rodas do

veículo, com amplitudes de desgaste bastante reduzidas. O modelo AEE B4 mostrou, numericamente, um alto grau de eficácia nas diferentes análises a que os dados foram submetidos:

- 99 % de eficácia na detecção de dano (falso positivo);
- 100 % de eficácia na identificação de tipo de dano (velocidades inseridas matricialmente);
- 97 % de eficácia na identificação de tipo de dano (velocidades inseridas vetorialmente);
- 97 % de eficácia na classificação da severidade dos lisos;
- 100 % de eficácia na classificação da severidade da poligonização.

Relativamente à aplicação da metodologia a passagens adquiridas experimentalmente verificou-se a necessidade de entender qual o modelo AEE mais adequado aos dados, dado que a diferença da frequência de amostragem implicou uma redução da dimensão das variáveis de entrada, juntamente com a fusão dos dados executada apenas com dois sensores. Os resultados obtidos com o modelo AEE B3 mostraram:

- A inexistência de qualquer tipo de dano nos dados experimentais;
- 94 % de eficácia na detecção de dano (2 falsos positivos e 9 falsos negativos - lisos);
- 89 % de eficácia na identificação de dano (lisos).

Uma das principais características da metodologia desenvolvida é que poderá ser aplicada a qualquer tipo de comboio, desde que o mesmo seja previamente conhecido. Através da elaboração deste trabalho foi possível contribuir, de algum modo, para a melhoria do setor ferroviário, o que me proporcionou uma forte motivação ao longo da elaboração do mesmo.

## 6.2 DESENVOLVIMENTOS FUTUROS

Com o objetivo de ser alcançado um conhecimento aprofundado sobre a temática abordada, durante o desenvolvimento do presente trabalho foram observadas questões que merecem ser objeto de estudo em trabalhos futuros, permitindo aperfeiçoar a metodologia desenvolvida, caracterizadas por:

- Inclusão de uma etapa de localização do dano, permitindo adicionar análises numéricas com os dois defeitos geométricos distintos inseridos simultaneamente numa única passagem.
- Realizar simulações numéricas com modelos de desgaste das rodas menos acentuados, permitindo esclarecer o potencial da metodologia;
- Aumento da amostragem de passagens experimentais, preferencialmente com e sem características de dano, permitindo calibrar a metodologia.

## 6.3 PUBLICAÇÕES

Ao longo do desenvolvimento do presente trabalho foi possível elaborar, paralelamente, um conjunto de artigos, que contam com a participação de todos membros do grupo de investigação. Os artigos da conferência CILAMCE (2023) já foram aceites, ao contrário dos restantes.

### 6.3.1 Artigos em conferências nacionais

- “Application of a Sparse Autoencoder model for OOR damage wheels identification in a passenger train using wayside track responses” - J. Magalhães, T.Jorge, R. Silva, A. Guedes, D. Ribeiro, A.Meixedo, A. Mosleh, C.Vale, P. Montenegro and A. Cury –Conferência XLIV Ibero-Latin American Congress on Computational Methods in Engineering (CILAMCE 2023) 2023 – 13 a 16 de Novembro de 2023 no Porto (aceite para publicação).
- “Unsupervised Feature Extraction using a Stacked Sparse Autoencoder for OOR Damage Wheels identification” – T.Jorge, J.Magalhães. R. Silva, A. Guedes, D. Ribeiro, A.Meixedo, A. Mosleh, C.Vale, P. Montenegro and A. Cury – Conferência XLIV Ibero-Latin American Congress on Computational Methods in Engineering (CILAMCE 2023) 2023 – 13 a 16 de Novembro de 2023 no Porto (aceite para publicação).
- “A Deep Autoencoder approach for OOR Damage Wheels Identification in a Railway Freight Vehicle”- T. Jorge, J. Magalhães. R. Silva, A. Guedes, D. Ribeiro, A. Meixedo, A. Mosleh, C. Vale, P. Montenegro -, Proceedings of International Conference on Vehicle Body Engineering (VBE 2023), Porto, Portugal (aceite para publicação).

### 6.3.2 Artigos em revistas internacionais

- “A strategy for out-of-roundness damage wheels identification in railway vehicles based on a Sparse Autoencoder” - J. Magalhães, T. Jorge, R. Silva, A.Guedes, D.Ribeiro, A. Meixedo, A.Mosleh, C.Vale, P. Montenegro and A. Cury – in Railway Engineering Science (artigo em revisão).
- “Early Identification of out-of-roundness Damage Wheels in Railway Freight Vehicles using a Wayside System and a Stacked Sparse Autoencoder” – T. Jorge, J. Magalhães, R. Silva, A.Guedes, D.Ribeiro, A. Meixedo, A.Mosleh, C.Vale, P. Montenegro, and A. Cury - in Vehicle System Dynamics (artigo em revisão).



## REFERÊNCIAS BIBLIOGRÁFICAS

- Akhter, Mohammad Maksood, and Sraban Kumar Mohanty. "A Fast  $O(N \log N)$  Time Hybrid Clustering Algorithm Using the Circumference Proximity Based Merging Technique for Diversified Datasets." *Engineering Applications of Artificial Intelligence* 125 (2023/10/01/ 2023): 106737.
- Almeida, Pedro Aires Moreira Montenegro e. "A Methodology for the Assessment of the Train Running Safety on Bridges." Faculdade de Engenharia da Universidade do Porto. Tese de Doutoramento, 2015.
- ANSYS®; Release 19.2; Academic Research: Canonsburg, PA, USA, 2018.
- Antunes, Pedro, Hugo Magalhaes, Jorge Ambrósio, João Pombo, and João Neves Costa. "A Co-Simulation Approach to the Wheel–Rail Contact with Flexible Railway Track." *Multibody System Dynamics* 45 (02/01 2019).
- Avsievich, Alexandr, Vladimir Avsievich, and Anton Ivaschenko. "Comparative Analysis of Railway Track Depression Estimation Methods." *Transportation Research Procedia* 68 (2023/01/01/ 2023): 447-52.
- Bragança, C., J. Neto, N. Pinto, P. A. Montenegro, D. Ribeiro, H. Carvalho, and R. Calçada. "Calibration and Validation of a Freight Wagon Dynamic Model in Operating Conditions Based on Limited Experimental Data." *Vehicle System Dynamics* 60, no. 9 (2022/09/02 2022): 3024-50.
- Cai, Wubin, Maoru Chi, Xingwen Wu, Fei Li, Zefeng Wen, Shulin Liang, and Xuesong Jin. "Experimental and Numerical Analysis of the Polygonal Wear of High-Speed Trains." *Wear* 440-441 (2019/12/15/ 2019): 203079.
- Calçada, Rui Artur Bártolo. "Efeitos Dinâmicos Em Pontes Resultantes Do Tráfego Ferroviário a Alta Velocidade." Faculdade de Engenharia da Universidade do Porto. Tese de Mestrado, 1995.
- Caliński, T., and J. Harabasz. "A Dendrite Method for Cluster Analysis." *Communications in Statistics* 3, no. 1 (1974/01/01 1974): 1-27.
- Chang, Chongyi, Yuanwu Cai, Bo Chen, Qiuzhe Li, and Pengfei Lin. "Experimental Study of the Wheel/Rail Impact Caused by Wheel Flat within 400 km/H Using Full-Scale Roller Rig." *Railway Sciences* 1, no. 1 (2022): 76-89.
- Chellaswamy, C., M. Krishnasamy, L. Balaji, A. Dhanalakshmi, and R. Ramesh. "Optimized Railway Track Health Monitoring System Based on Dynamic Differential Evolution Algorithm." *Measurement* 152 (2020/02/01/ 2020): 107332.
- Cury, Alexandre, Diogo Ribeiro, Filippo Ubertini, and Michael Todd. *Structural Health Monitoring Based on Data Science Techniques | Structural Integrity Series | Volume 21*. 2021. doi:10.1007/978-3-030-81716-9.
- EN 13674-1:2002 - "Track – Rail - Part 1: Vignole railway rails 46 kg/m and above"; European Committee for Standardization (CEN), Brussels, 2002.

## REFERÊNCIAS

- EN 13848-2:2006 – “Railway applications - Track - Track geometry quality - Part 2: Measuring systems - Track recording vehicles”; European Committee for Standardization (CEN), Brussels.
- 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.
- Figueiredo, Eloi, and Adam Santos. "Machine Learning Algorithms for Damage Detection." 1-39, 2018.
- Gonçalves, Vítor, Araliya Mosleh, Cecília Vale, and Pedro A. Montenegro. "Wheel out-of-Roundness Detection Using an Envelope Spectrum Analysis." *Sensors* 23, no. 4 (2023). doi:10.3390/s23042138.
- Guedes, António Miguel Carvalho. "Deteção E Identificação De Dano Em Rodas De Veículos Ferroviários Baseada Na Resposta Dinâmica Induzida Pelo Veículo Na Via." Instituto Superior de Engenharia do Porto. Tese de Mestrado, 2022.
- Guedes, António, Ruben Silva, Diogo Ribeiro, Cecília Vale, Araliya Mosleh, Pedro Montenegro, and Andreia Meixedo. "Detection of Wheel Polygonization Based on Wayside Monitoring and Artificial Intelligence." *Sensors* 23, no. 4 (2023): 2188.
- Haykin, Simon. *Neural Networks: A Comprehensive Foundation*. Prentice Hall PTR, 1998.
- Hu, Haize, Jianxun Liu, Xiangping Zhang, and Mengge Fang. "An Effective and Adaptable K-Means Algorithm for Big Data Cluster Analysis." *Pattern Recognition* 139 (2023/07/01/ 2023): 109404.
- Jiang, Yanran, Bernard Chen, and Cameron Thompson. "A Comparison Study of Ride Comfort Indices between Sperling’s Method and En 12299." *International Journal of Rail Transportation* 7 (05/12 2019): 1-18.
- Johansson, Anders, and Jens C. O. Nielsen. "Rail Corrugation Growth—Influence of Powered Wheelsets with Wheel Tread Irregularities." *Wear* 262, no. 11 (2007/05/10/ 2007): 1296-307.
- Lee, Hyunseong, Hyung Jin Lim, Travis Skinner, Aditi Chattopadhyay, and Asha Hall. "Automated Fatigue Damage Detection and Classification Technique for Composite Structures Using Lamb Waves and Deep Autoencoder." *Mechanical Systems and Signal Processing* 163 (2022/01/15/ 2022): 108148.
- Lenssen, Lars, and Erich Schubert. "Medoid Silhouette Clustering with Automatic Cluster Number Selection." *Information Systems* 120 (2024/02/01/ 2023): 102290.
- Li, Lechen, Marcello Morgantini, and Raimondo Betti. "Structural Damage Assessment through a New Generalized Autoencoder with Features in the Quefreny Domain." *Mechanical Systems and Signal Processing* 184 (2023/02/01/ 2023): 109713.
- Liu, Xiaoyuan, and Wanming Zhai. "Analysis of Vertical Dynamic Wheel/Rail Interaction Caused by Polygonal Wheels on High-Speed Trains." *Wear* 314, no. 1 (2014/06/15/ 2014): 282-90.
- Lourenço, Afonso, Carolina Ferraz, Diogo Ribeiro, Araliya Mosleh, Pedro Montenegro, Cecília Vale, Andreia Meixedo, and Goreti Marreiros. "Adaptive Time Series Representation for out-of-Round Railway Wheels Fault Diagnosis in Wayside Monitoring." *Engineering Failure Analysis* 152 (2023/10/01/ 2023): 107433.
- MATLAB®. Natick, M., USA: Release R2018a, The MathWorks Inc. 2018: Natick, Massachusetts: The MathWorks Inc.
- Meixedo, Andreia Gomes. "Damage Identification in Railway Bridges Based on Train Induced Dynamic Responses." Faculdade de Engenharia da Universidade do Porto. Tese de Doutoramento, 2021.
- Meixedo, Andreia, Diogo Ribeiro, João Santos, Rui Calçada, and Michael Todd. "Real-Time Unsupervised Detection of Early Damage in Railway Bridges Using Traffic-Induced Responses." 117-42, 2021a.

- . "Structural Health Monitoring Strategy for Damage Detection in Railway Bridges Using Traffic Induced Dynamic Responses." 389-408, 2022a.
- Meixedo, Andreia, João Santos, Diogo Ribeiro, Rui Calçada, and Michael Todd. "Damage Detection in Railway Bridges Using Traffic-Induced Dynamic Responses." *Engineering Structures* 238 (2021/07/01/ 2021b): 112189.
- Meixedo, Andreia, João Santos, Diogo Ribeiro, Rui Calçada, and Michael D. Todd. "Online Unsupervised Detection of Structural Changes Using Train-Induced Dynamic Responses." *Mechanical Systems and Signal Processing* 165 (2022/02/15/ 2022b): 108268.
- Meng, Q., D. Catchpoole, D. Skillicom, and P. J. Kennedy. "Relational Autoencoder for Feature Extraction." Paper presented at the 2017 International Joint Conference on Neural Networks (IJCNN), 14-19 May 2017 2017.
- Mohammadi, Mohammadreza, Araliya Mosleh, Cecilia Vale, Diogo Ribeiro, Pedro Montenegro, and Andreia Meixedo. "An Unsupervised Learning Approach for Wayside Train Wheel Flat Detection." *Sensors* 23, no. 4 (2023): 1910.
- Montenegro, P. A., S. G. M. Neves, R. Calçada, M. Tanabe, and M. Sogabe. "Wheel-Rail Contact Formulation for Analyzing the Lateral Train-Structure Dynamic Interaction." *Computers & Structures* 152 (2015/05/01/ 2015): 200-14.
- Montenegro, Pedro Aires, Rui Calçada, Nelson Vila Pouca, and M. Tanabe. "Running Safety Assessment of Trains Moving over Bridges Subjected to Moderate Earthquakes." *Earthquake Engineering & Structural Dynamics* 45 (03/01 2016): n/a-n/a.
- Montenegro, Pedro Aires, Raphael Heleno, Hermes Carvalho, Rui Calçada, and C. Baker. "A Comparative Study on the Running Safety of Trains Subjected to Crosswinds Simulated with Different Wind Models." *Journal of Wind Engineering and Industrial Aerodynamics* 207 (10/08 2020): 104398.
- Mosleh, Araliya, Pedro Alves Costa, and Rui Calçada. "A New Strategy to Estimate Static Loads for the Dynamic Weighing in Motion of Railway Vehicles." *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit* 234, no. 2 (2020): 183-200.
- Mosleh, Araliya, Andreia Meixedo, Diogo Ribeiro, Pedro Montenegro, and Rui Calçada. "Automatic Clustering-Based Approach for Train Wheels Condition Monitoring." *International Journal of Rail Transportation* (2022a): 1-26.
- . "Early Wheel Flat Detection: An Automatic Data-Driven Wavelet-Based Approach for Railways." *Vehicle System Dynamics* 61, no. 6 (2023/06/03 2023): 1644-73.
- Mosleh, Araliya, Pedro Aires Montenegro, Pedro Alves Costa, and Rui Calçada. "10 - Approaches for Weigh-in-Motion and Wheel Defect Detection of Railway Vehicles." In *Rail Infrastructure Resilience*, edited by Rui Calçada and Sakdirat Kaewunruen, 183-207: Woodhead Publishing, 2022b.
- . "Railway Vehicle Wheel Flat Detection with Multiple Records Using Spectral Kurtosis Analysis." *Applied Sciences* 11, no. 9 (2021b): 4002.
- Mosleh, Araliya, Pedro Montenegro, Pedro Alves Costa, and Rui Calçada. "An Approach for Wheel Flat Detection of Railway Train Wheels Using Envelope Spectrum Analysis." *Structure and Infrastructure Engineering* 17, no. 12 (2021/12/02 2021a): 1710-29.
- Mu, Jian, Jing Zeng, Caihong Huang, Yi Sun, and Hutang Sang. "Experimental and Numerical Investigation into Development Mechanism of Wheel Polygonalization." *Engineering Failure Analysis* 136 (2022/06/01/ 2022): 106152.
- Neto, José, Pedro Aires Montenegro, Cecília Vale, and Rui Calçada. "Evaluation of the Train Running Safety under Crosswinds - a Numerical Study on the Influence of the Wind Speed and Orientation

## REFERÊNCIAS

- Considering the Normative Chinese Hat Model." *International Journal of Rail Transportation* 9 (06/28 2020): 1-28.
- NG, Andrew. "Cs294a Lecture Notes - Sparse Autoencoder." In [https://web.stanford.edu/class/cs294a/sparseAutoencoder\\_2011new.pdf](https://web.stanford.edu/class/cs294a/sparseAutoencoder_2011new.pdf), 2011.
- Nielsen, Jens, and A. Johansson. "Out-of-Round Railway Wheels-a Literature Survey." *Proceedings of The Institution of Mechanical Engineers Part F-journal of Rail and Rapid Transit - PROC INST MECH ENG F-J RAIL R* 214 (03/01 2000): 79-91.
- Olshausen, Bruno A., and David J. Field. "Sparse Coding with an Overcomplete Basis Set: A Strategy Employed by V1?". *Vision Research* 37, no. 23 (1997/12/01/ 1997): 3311-25.
- Peng, Bo. "Mechanisms of Railway Wheel Polygonization." University of Huddersfield. Doctoral thesis, 2020.
- Pimentel, Ricardo, Diogo Ribeiro, Luís Matos, Araliya Mosleh, and Rui Calçada. "Bridge Weigh-in-Motion System for the Identification of Train Loads Using Fiber-Optic Technology." *Structures* 30 (2021/04/01/ 2021): 1056-70.
- Pintão, Bruno, Araliya Mosleh, Cecilia Vale, Pedro Montenegro, and Pedro Costa. "Development and Validation of a Weigh-in-Motion Methodology for Railway Tracks." *Sensors* 22, no. 5 (2022): 1976.
- Prawin, J., and G. S. Vijaya Bhaskara. "Outlier Analysis Combined with Gaussian Mixture Model for Structural Damage Detection." *Materials Today: Proceedings* (2023/04/01/ 2023).
- Quaresma, Carolina. "Porto-Lisboa De Comboio Em 1h15 Após 2030. Conheça a Nova Linha De Alta Velocidade. ." *TSF- Rádio Notícias*. URL: <https://www.tsf.pt/portugal/economia/governo-apresenta-tracado-e-desenvolvimento-da-linha-ferroviaria-de-alta-velocidade-15204469.html> (2022).
- "Railway-Technology.Com. (Acedido Em Outubro De 2023). Url: Railway-Technology.Com."
- "Railway Technology (Acedido Em Setembro De 2023). ." <https://www.railway-technology.com/>.
- Ribeiro, Diogo Rodrigo. "Efeitos Dinâmicos Induzidos Por Tráfego Em Pontes Ferroviárias: Modelação Numérica, Calibração E Validação Experimental." Faculdade de Engenharia da Universidade do Porto. Tese de Doutoramento, 2012.
- Rytter, A. . "Vibrational Based Inspection of Civil Engineering Structures. Aalborg: Dept. Of Building Technology and Structural Engineering, Aalborg University.", 1993.
- Saraiva, Sérgio. "Deep Learning Passo a Passo." *Programar. Revista Portuguesa de Programação*, 2018.
- Saramago, Gabriel Araújo. "Caracterização Dos Efeitos Dinâmicos Induzidos Por Tráfego Ferroviário Na Ponte Cascalheira: Modelação Numérica, Calibração E Validação Experimental." Instituto Superior de Engenharia do Porto. Tese de Mestrado, 2020.
- Sarwar, Muhammad Zohaib, and Daniel Cantero. "Deep Autoencoder Architecture for Bridge Damage Assessment Using Responses from Several Vehicles." *Engineering Structures* 246 (2021/11/01/ 2021): 113064.
- Silva, Nelso. "Galeira De Fotos - Cp 4008." In <https://www.flickr.com/people/nelsosilva/>, 2018.
- Silva, R., A. Guedes, D. Ribeiro, C. Vale, A. Meixedo, A. Mosleh, and P. Montenegro. "Early Identification of Unbalanced Freight Traffic Loads Based on Wayside Monitoring and Artificial Intelligence." *Sensors* 23, no. 3 (2023): 1544.
- Staśkiewicz, Tomasz, and Bartosz Firlik. "Out-of-Round Tram Wheels – Current State and Measurements." *Archives of Transport* 45 (03/30 2018): 83-93.

- Talaei, Saeid, Xinqun Zhu, Jianchun Li, Yang Yu, and Tommy H. T. Chan. "Transfer Learning Based Bridge Damage Detection: Leveraging Time-Frequency Features." *Structures* 57 (2023/11/01/ 2023): 105052.
- Tao, Gongquan, Chenxi Xie, Hengyu Wang, Xiaoxuan Yang, Changquan Ding, and Zefeng Wen. "An Investigation into the Mechanism of High-Order Polygonal Wear of Metro Train Wheels and Its Mitigation Measures." *Vehicle System Dynamics* 59, no. 10 (2021/10/03 2021): 1557-72.
- Teixeira, António Jorge Silvestre e Paulo Ivo Cortez. *Mecânica-Uma Introdução*. 2019.
- Vale, Cecilia. "Wheel Flats in the Dynamic Behavior of Ballasted and Slab Railway Tracks." *Applied Sciences* 11, no. 15 (2021): 7127.
- Vale, Cecília, and Rui Calçada. *Dynamic Response of a Coupled Vehicle-Track System to Real Longitudinal Rail Profiles*. 2010. doi:10.4203/ccp.93.11.
- Vale, Cecília Maria Nogueira Alvarenga Santos do. "Influência Da Qualidade Dos Sistemas Ferroviários No Comportamento Dinâmico E No Planeamento Da Manutenção Preventiva De Vias De Alta Velocidade." Faculdade de Engenharia da Universidade do Porto. Tese de Doutoramento 2010.
- Wang, Jie, Wei Zhou, Xia-ying Ren, Ming-ming Su, and Jia Liu. "A Waveform-Based Clustering and Machine Learning Method for Damage Mode Identification in Cfrp Laminates." *Composite Structures* 312 (2023/05/15/ 2023a): 116875.
- Wang, Peng, Congwei Li, Ruobing Liang, Sungmin Yoon, Song Mu, and Yuchuan Liu. "Fault Detection and Calibration for Building Energy System Using Bayesian Inference and Sparse Autoencoder: A Case Study in Photovoltaic Thermal Heat Pump System." *Energy and Buildings* 290 (04/01 2023b): 113051.
- Wang, Zilong, and Young-Jin Cha. "Unsupervised Deep Learning Approach Using a Deep Auto-Encoder with a One-Class Support Vector Machine to Detect Damage." *Structural Health Monitoring* 20, no. 1 (2021/01/01 2020): 406-25.
- Wu, Yue, Xing Du, He-ji Zhang, Ze-feng Wen, and Xue-song Jin. "Experimental Analysis of the Mechanism of High-Order Polygonal Wear of Wheels of a High-Speed Train." *Journal of Zhejiang University-SCIENCE A* 18, no. 8 (2017/08/01 2017): 579-92.
- Wu, Yue, Jianuo Wang, Moukai Liu, Xuesong Jin, Xiaoyi Hu, Xinbiao Xiao, and Zefeng Wen. "Polygonal Wear Mechanism of High-Speed Wheels Based on Full-Size Wheel-Rail Roller Test Rig." *Wear* 494-495 (2022/04/15/ 2022): 204234.
- Ye, Yunguang, Caihong Huang, Jing Zeng, Yichang Zhou, and Fansong Li. "Shock Detection of Rotating Machinery Based on Activated Time-Domain Images and Deep Learning: An Application to Railway Wheel Flat Detection." *Mechanical Systems and Signal Processing* 186 (2023/03/01/ 2023): 109856.
- Ye, Yunguang, Lai Wei, Fansong Li, Jing Zeng, and Markus Hecht. "Multislice Time-Frequency Image Entropy as a Feature for Railway Wheel Fault Diagnosis." *Measurement* 216 (2023/07/01/ 2023): 112862.
- Ye, Yunguang, Bin Zhu, Ping Huang, and Bo Peng. "Oornet: A Deep Learning Model for on-Board Condition Monitoring and Fault Diagnosis of out-of-Round Wheels of High-Speed Trains." *Measurement* 199 (2022/08/01/ 2022): 111268.
- Yessoufou, Fadel, and Jinsong Zhu. "Deep Autoencoder Model for Direct Monitoring of Bridges Subjected to a Moving Vehicle Load under Varying Temperature Conditions." *Structures* 52 (2023/06/01/ 2023): 752-67.
- Zhang, Jie, Guang-xu Han, Xinbiao Xiao, Wang Ruiqian, Yue Zhao, and Xuesong Jin. "Influence of Wheel Polygonal Wear on Interior Noise of High-Speed Trains." 373-401, 2018.

## REFERÊNCIAS