



ISEL
INSTITUTO SUPERIOR DE
ENGENHARIA DE LISBOA



Caracterização de vibrações em ambiente ferroviário

DIOGO MIGUEL NUNES DE MELO

(Licenciado em Engenharia Eletrónica e Telecomunicações e de Computadores)

Trabalho de Projeto para obtenção do grau de Mestre em Engenharia de Eletrónica e Telecomunicações, no Perfil de Eletrónica

Orientadores:

Doutor João Casaleiro
Doutor Carlos Mendes

Júri:

Presidente: Doutor Rui Duarte

Vogais:

Doutor João Casaleiro
Doutor Paulo Marques

Novembro de 2024

Caracterização de vibrações em ambiente ferroviário

DIOGO MIGUEL NUNES DE MELO

(Licenciado em Engenharia Eletrónica e Telecomunicações e de Computadores)

Trabalho de Projeto para obtenção do grau de Mestre em Engenharia de Eletrónica e Telecomunicações, no Perfil de Eletrónica

Orientadores:

Doutor João Casaleiro, ISEL - IPL

Doutor Carlos Mendes, ISEL - IPL

Júri:

Presidente: Doutor Rui Duarte, ISEL - IPL

Vogais:

Doutor João Casaleiro, ISEL - IPL

Doutor Paulo Marques, ISEL - IPL

Novembro de 2024

Agradecimentos

Em primeiro lugar quero expressar a minha profunda gratidão aos meus dois orientadores, o Prof. Carlos Mendes e o Prof. João Casaleiro, pelo apoio crucial à realização deste projeto, quer pelas discussões sobre o projeto, quer pela sua paciência e otimismo.

Gostaria também de agradecer ao ISEL e ao projeto Ferrovia 4.0 pelos recursos que permitiram realizar o trabalho desenvolvido nesta tese.

Por fim quero agradecer à minha família e amigos por seu incentivo, apoio, paciência e compreensão ao longo do período de trabalho neste projeto.

Resumo

As quedas de pedras em linhas férreas são, além de um potencial causador de acidentes, um problema para a manutenção da infraestrutura por parte do operador Infraestruturas de Portugal. No Relatório Anual de Segurança Ferroviária [1] são recomendadas medidas de mitigação de risco como *"(...)nomeadamente através da realização de empreitadas de contenção de taludes e do recurso aos sistemas de deteção de queda de blocos(...)"*.

Neste trabalho, são extraídas características dos sinais de vibração em ambiente ferroviário, que são, em seguida, submetidas a classificação automática, com o objetivo de distinguir entre diferentes tipos de eventos, incluindo a queda de pedras.

Com recurso a dados reais, obtidos em ambiente ferroviário, foi possível definir vários conjunto de características que, aliados a diferentes algoritmos de classificação, permitem uma precisão superior a 75%, o que aliado a pós-processamento permite a deteção de 100% dos eventos testados.

Palavras-chave: Vibrações em ferrovia, Acelerómetros de baixo custo, Deteção, Classificação

Abstract

Rockfalls on railway tracks are not only a potential cause of accidents but also a maintenance challenge for the infrastructure operator, Infraestruturas de Portugal. In the Annual Railway Safety Report [1], risk mitigation measures are recommended, such as *"(...) specifically through the execution of slope stabilization works and the use of rockfall detection systems (...)"*.

In this work, features are extracted from vibration signals in a railway environment, which are then subjected to automatic classification with the goal of distinguishing between different types of events, including rockfalls.

Using real data obtained in a railway environment, it was possible to define several sets of features that, combined with different classification algorithms, enable an accuracy above 75%, which, along with post-processing, allows for 100% detection of the tested events.

Keywords: Railway vibrations, Low-cost accelerometers, Detection, Classification

Índice

1	INTRODUÇÃO	1
1.1	Motivação e contexto	1
1.1.1	Prevenção de acidentes por derrocadas em ambiente ferroviário	1
1.1.2	Solução proposta	2
1.1.3	Talude	4
1.1.4	Deslizamento de terra	4
1.2	Estado da Arte	6
1.2.1	Introdução	6
1.2.2	Casos de estudo	7
1.3	Objetivos	10
1.4	Organização da tese	10
2	PLATAFORMA DE AQUISIÇÃO DE DADOS	13
2.1	Introdução	13
2.2	Arquitetura	14
2.3	Descrição de blocos	15
2.3.1	Microcontroladores	15
2.3.2	Acelerómetro	17
2.4	Funcionamento do sensor	18
2.4.1	Deteção de vibração em taludes	18
2.4.2	Recolha e transmissão de dados em bruto	18
2.5	Medição com o sensor	19
2.6	Medição de sinais em campo	20
2.6.1	Passagem de material circulante e queda de pedras em via-férrea	20
2.6.2	Ruído ambiente	21

3	EXTRAÇÃO DE CARACTERÍSTICAS	23
3.1	Introdução	23
3.2	Janelamento	24
3.3	Características no domínio do tempo	26
3.3.1	Valor eficaz da potência do sinal	26
3.3.2	Valor médio da potência do sinal	28
3.3.3	Valor de pico da potência do sinal	28
3.3.4	Taxa de cruzamento de zeros da amplitude do sinal	29
3.3.5	Desvio-padrão da amplitude do sinal	29
3.4	Características no domínio da frequência	30
3.4.1	Comboio	30
3.4.2	Pedras	30
3.4.3	Ruído	32
4	CLASSIFICADORES	37
4.1	Introdução	37
4.2	Conjuntos de treino	38
4.2.1	Classe <i>Ruído</i>	39
4.2.2	Classe <i>Comboio</i>	39
4.2.3	Classe <i>Pedra</i>	40
4.3	Pré-processamento de dados	41
4.3.1	Normalização	41
4.4	Classificadores	42
4.4.1	k-vizinhos mais próximos	42
4.4.2	Centroide mais próximo	43
4.5	Pós-processamento de resultados e classificação final do evento	44
4.5.1	Regiões de decisão	45
4.6	Métricas para classificadores binários e multiclasse	47
4.6.1	Matriz de Confusão	47
4.6.2	Exatidão	47
4.6.3	Precisão	48

4.6.4	Sensibilidade	48
4.6.5	Métrica F1	48
5	RESULTADOS	49
5.1	Introdução	49
5.2	Ensaio com classificadores	50
5.2.1	K-vizinhos mais próximos	50
5.2.2	Centroide mais próximo	50
5.2.3	Resultados	51
5.2.4	Conclusões	52
5.3	Pós-processamento	52
6	CONCLUSÕES E TRABALHO FUTURO	55
6.1	Introdução	55
6.2	Conclusões	55
6.3	Trabalho futuro	56
6.3.1	Introdução	56
6.3.2	Sinais de vibração e classes	56
6.3.3	Características dos sinais e classificadores	57

Lista de Figuras

1.1	Propagação de vibrações geradas pela passagem de um comboio.	2
1.2	Exemplos de taludes presentes em linhas férreas portuguesas: talude rochoso (a) e talude em betão (b).	4
2.1	Protótipo final (a) e diagrama geral do sensor (b).	14
2.2	Arquitetura do sensor.	15
2.3	Diagrama de blocos do microcontrolador ESP32.	15
2.4	Diagrama de blocos funcional do microcontrolador ARM STM32.	16
2.5	Diagrama de blocos funcional do acelerómetro ADXL355.	17
2.6	Referencial dos eixos de aceleração do sensor.	19
2.7	Talude (a) onde foi instalado o sensor (b) nos ensaios no Apeadeiro de Chelas.	20
2.8	Sinais de passagem de comboios <i>comboio1</i> e <i>comboio2</i> (a e b), adquiridos com f_s de 4000Hz.	21
2.9	Resposta do domínio do tempo dos sinais de queda de pedras <i>pedra1</i> e <i>pedra2</i> (a e b), adquiridos com f_s de 4000Hz.	21
2.10	Resposta do domínio do tempo de sinais de queda de pedras <i>pedra3</i> e <i>pedra4</i> , adquiridos com f_s de 4000Hz (a e b).	22
2.11	Resposta do domínio do tempo de um sinal de ruído na ausência de eventos ferroviários, adquirido com f_s de 4000Hz.	22
3.1	Taxonomia dos eventos de vibração em ambiente ferroviário estudados.	23
3.2	Exemplo de janelamento de um sinal de vibração gerado pela passagem de um comboio, com recurso a uma janela de <i>Hann</i>	26

3.3	Sinal de vibração <i>comboio1</i> e as suas características no domínio do tempo como <i>Potência Média</i> , <i>Potência RMS</i> e <i>Pico de Potência</i> (a) e (c) e <i>Desvio-Padrão</i> e <i>Taxa de Cruzamento de Zeros</i> (b) e (d) para uma janela de 1024 (a) e (b) e 64 (c) e (d) amostras.	27
3.4	Sinal de vibração <i>pedra3</i> e as suas características no domínio do tempo como <i>Potência Média</i> , <i>Potência RMS</i> e <i>Pico de Potência</i> para uma janela de 64 amostras.	28
3.5	Resposta do domínio da frequência dos sinais de passagem de comboios <i>comboio1</i> e <i>comboio2</i> , adquiridos com f_s de 4000Hz (a e c) e respectivos espectrogramas a 128 e 256 amostras (b e d).	31
3.6	Resposta do domínio da frequência de sinais de queda de pedras <i>pedra1</i> e <i>pedra2</i> , adquiridos com f_s de 4000Hz (a e c) e respectivos espectrogramas a 128 e 256 amostras (b e d).	33
3.7	Resposta do domínio da frequência de sinais de queda de pedras <i>pedra1</i> e <i>pedra2</i> , adquiridos com f_s de 4000Hz (a e b) e respectivos espectrogramas a 128 e 256 amostras (c e d).	34
3.8	Resposta do domínio da frequência (a) e espectrograma (b) de um sinal de ruído na ausência de eventos ferroviários, adquirido com f_s de 4000Hz.	35
3.9	Sobreposição dos espectros de sinais de vibração gerados pela passagem de comboios e pedras.	35
4.1	Diagrama de blocos do sistema de aquisição e classificação de eventos.	38
4.2	Conjunto de treino da classe <i>Ruído</i>	39
4.3	Conjunto de treino da classe <i>Comboio</i>	40
4.4	Conjunto de treino da classe <i>Pedra</i>	40
4.5	Exemplo da distribuição de um histograma de duas características antes e depois a normalização. Note-se a diferença de escala do eixo x no gráfico à esquerda e a sua coincidência à direita.	41
4.6	Dois características do conjunto de treino antes (a) e depois (b) de normalização.	41

4.7	Exemplo do algoritmo k-NN, onde o losango é um ponto de classe desconhecido, a ser classificado entre as três classes existentes, triângulos, círculos e quadrados. Dentro de cada símbolo está a distância euclidiana do losango a cada ponto das classes.	43
4.8	Exemplo do algoritmo centroide mais próximo, baseado nos pontos da figura 4.7. As figuras geométricas transparentes representam o centroide de cada classe.	44
4.9	Esquema de pós-processamento do sinal de vibração: cada janela é classificada e os resultados dessas classificações são agrupados. . . .	45
4.10	Regiões de decisão dos classificadores k-NN com $k = 5$ (a, d), $k = 11$ (b, e) e $k = 17$ (c, f) e Centroide mais próximo (g, i) definidas pelo seu conjunto de treino. O valor da janela é de 64 amostras (a, b, c, g, h, i). A vermelho está o sinal de teste <i>comboio1</i>	46
5.1	Exemplos do resultado da classificação com o classificador k-NN do sinal <i>pedra1</i> (a) e do sinal <i>comboio1</i> (b).	52

Lista de Tabelas

1.1	Comparação entre tipos de deslizamento de terras.	5
1.2	Comparação entre técnicas de monitorização de taludes.	7
3.1	Variação qualitativa das características do domínio do tempo para as classes estudadas.	24
3.2	Fontes de vibração geradas pela passagem de material circulante. . .	32
4.1	Matriz de confusão.	48
5.1	Número de janelas classificadas para o sinal <i>comboio1</i> e <i>pedra1</i> , com $k = 11$ e janela de 256 amostras e $k = 3$ e janela de 64 amostras, respetivamente. Os parâmetros classificados são <i>rms</i> e <i>std</i>	53

Lista de Acrónimos e Siglas

DAS Distributed Acoustic Sensing.

FIFO First In First Out.

FPU Floating Point Unit.

GNSS Global Navigation Satellite System.

GPS Global Positioning System.

InSAR Interferometric synthetic-aperture radar.

IoT Internet of Things.

IP Infraestruturas de Portugal.

ISEL Instituto Superior de Engenharia de Lisboa.

k-NN k-Nearest Neighbors.

LiDAR Light Detection and Ranging.

LiFePO₄ Lithium iron phosphate.

LoRa Long Range Wide Area.

LoRaWAN Long Range Wide Area Network.

MEMS Micro Electro-Mechanical Systems.

RGB Red Green Blue.

RMS Root Mean Square.

ROI Region of Interest.

RTC Real Time Clock.

SMOTE Synthetic Minority Oversampling Technique.

SPI Serial Peripheral Interface.

STFT Short-time Fourier Transform.

ZCR Zero Crossing Rate.

1

INTRODUÇÃO

1.1 Motivação e contexto

1.1.1 Prevenção de acidentes por derrocadas em ambiente ferroviário

As derrocadas em linhas férreas são, além de um potencial causador de acidentes, um problema de manutenção por parte do operador da infraestrutura. A sua imprevisibilidade é causadora de interrupções na circulação das linhas, bem como nos ciclos de manutenção das mesmas.

No Relatório Anual de Segurança Ferroviária de 2020 [1], compilado pelo operador Infraestruturas de Portugal, verifica-se que a colisão com obstáculos presentes na via-férrea é uma das principais causas de acidentes significativos na ferrovia, sendo impactantes ao nível da exploração ferroviária. Nesse relatório são também recomendadas medidas de mitigação de risco como "*(...)nomeadamente através da realização de empreitadas de contenção de taludes e do recurso aos sistemas de deteção de queda de blocos(...)*". A imprevisibilidade destes eventos e a impossibilidade de uma monitorização *in loco* permanente através de pessoal especializado tornam necessário adicionar algum grau de autonomia à monitorização de taludes. Um aspeto a considerar ao estudar este tipo de sistemas de monitorização é a variedade de características dos taludes, quer a nível físico (composição material, localização, inclinação ou acesso) quer a nível de infraestruturas de energia e comunicação.




Figura 1.1: Propagação de vibrações geradas pela passagem de um comboio.

Conhecendo as origens e os tipos de vibrações presentes em ambiente ferroviário é possível dividi-los por conjuntos de eventos típicos do regular funcionamento de operações e em eventos que potencialmente coloquem em causa a segurança na linha férrea. As vibrações geradas por material circulante em ambiente ferroviário têm diversas origens [2, 3, 4] desde fatores ambientais específicos da área de implantação como a inclinação e o material dos taludes; proximidade a cursos de água, chuva, vento, proximidade de obras ou pedreiras ativas; fatores relacionados com a topologia da linha férrea como distância entre travessas, condição dos carris, características do material circulante como a distância entre eixos e bogies, imperfeições nos rodados; a velocidade de deslocamento do comboio. Estas vibrações são transmitidas até às imediações da via-férrea, propagando-se até ao talude e estruturas próximas, como exemplifica a figura 1.1 [2].

1.1.2 Solução proposta

Esta tese propõe o estudo de algoritmos de classificação para deteção de deslizamento e queda de pedras em taludes ferroviários, com o objetivo de poderem ser aplicados em futuros sistemas de monitorização de taludes em tempo-real.

Os algoritmos de classificação são alimentados com características (*features*) extraídas de sinais de vibração. A aquisição de dados para estudo, bem como a implantação futura desse sistema, realiza-se através de um senso. Este foi escolhido por permitir cobrir a área de um talude ou estrutura a monitorizar. As suas principais características são:

- Sensor de baixo custo e baixo consumo
- Autónoma do ponto de vista energético, utilizando um sistema de colheita de energia
- Baixa manutenção, sendo desenhado para uma implantação em terreno com grande inclinação e de difícil acesso
- Robustez e longo alcance na transmissão de dados, minimizando a dependência

de infraestrutura local complexa como 5G ou WiFi

- Opção de pré-processamento local de dados, permitindo processar quantidades significativas de dados

Pretende-se que o classificador escolhido consiga distinguir diferentes tipo de eventos, nomeadamente:

- Vibrações geradas por deslizamento de terras e queda de pedras
- Vibrações geradas pela passagem de material circulante, composto por comboios de passageiros, comboios de carga e veículos de manutenção ferroviária

Os critérios para escolha para o classificador são:

- Um valor de Precisão que garanta uma deteção unívoca de um determinado tipo de evento ferroviário
- Um valor de Sensibilidade que garanta a máxima redução possível de falsos negativos no caso de queda de pedras, devido às consequências materiais e pessoais da não deteção destes eventos

O estudo de vibrações em ambiente ferroviário debruça-se frequentemente na relação entre carril e rodados [5], normalmente associado ao estudo do desgaste da infraestrutura. Nesta tese ir-se-á estudar a possibilidade de aplicar algumas dessas técnicas à deteção de eventos [6].

Considerando que os sinais gerados por vibração em ambiente ferroviário e os sinais de áudio, partilham características no que diz respeito à sua variação no domínio do tempo e espectro de frequência, consideram-se técnicas aplicadas na análise de sinais de áudio [7].

As propostas de classificador foram testadas num computador e com sinais previamente obtidos, mas tendo em conta o objetivo futuro de implantação num sensor com alimentação autónoma, neste caso numa plataforma de aquisição de dados, composta por um microcontrolador para processamento de dados e um acelerómetro de três eixos, entre outros periféricos.

Futuramente pretende-se que o sensor possa ser instalado num talude e transmitir dados de vibração até um servidor central, reportando eventos ferroviários. Esta arquitetura, baseada em um ou vários sensores autónomos já foi considerada em outros projetos de monitorização de deslizamento de terras [8].

Este estudo pretende ser aplicável a outros ambientes onde a deteção de queda de pedras em tempo-real seja um fator crítico para garantir a segurança de pessoas e bens como, por exemplo, a rodovia e construções em planos inclinados.

1.1.3 Talude

Um talude é um plano de terreno inclinado em rampa, que limita um maciço de terra, rocha ou de ambos, com função principal de garantir a estabilidade do terreno. Um talude artificial é obtido por meio de terraplanagem ou de escavação e um talude natural surge por processos naturais de formação do solo. Na figura 1.2 mostram-se dois tipos de taludes comuns na ferrovia em Portugal.



Figura 1.2: Exemplos de taludes presentes em linhas férreas portuguesas: talude rochoso (a) e talude em betão (b).

1.1.4 Deslizamento de terra

Um deslizamento de terra [9] refere-se ao movimento descendente e lateral de materiais de encosta sob a influência da gravidade, podendo ocorrer de forma generalizada em encostas naturais, construídas ou escavadas. Os deslizamentos de terra podem ocorrer em encostas à beira da instabilidade e podem ser desencadeados por processos naturais como chuvas, derretimento de neve, erosão por correntes, atividades vulcânicas ou sísmicas; perturbações humanas como agricultura, construção, mineração ou de pedreiras, cortes ou variação nos níveis de reservatórios; qualquer combinação desses fatores.

Os deslizamentos de terra podem ser iniciados tanto por eventos de chuvas intensas e de curta duração, de horas a dias, quanto por precipitação prolongada, de semanas a meses. Os eventos mais rápidos desencadeiam deslizamentos de superfície, enquanto os mais longos estão geralmente associados a movimentos de encostas mais profundos e extensos, na ordem de 5 a 20 m de profundidade, e com um maior risco de geração de danos.

Uma das classificações mais amplamente utilizadas baseia-se no tipo de movimento, como queda e deslizamento e no tipo de material envolvido, como rocha, detritos e solo, é mostrada na tabela 1.1

Tabela 1.1: Comparação entre tipos de deslizamento de terras.

Descrição	Velocidade	Consequência
Extremamente rápido	5 m/s	<ul style="list-style-type: none"> • Grande catástrofe • Edifícios destruídos • Grande número de fatalidades
Muito rápido	3 m/min	<ul style="list-style-type: none"> • Algumas fatalidades devido a pouca possibilidade de fuga
Rápido	1,8m/h	<ul style="list-style-type: none"> • Evacuação possível • Destruição de algumas construções
Moderado	13 m/mês	<ul style="list-style-type: none"> • Algumas estruturas temporárias podem resistir, mas por pouco tempo
Lento	1,6m/ano	<ul style="list-style-type: none"> • Reparações estruturais podem ser realizadas durante o deslocamento • Estruturas temporárias podem ser mantidas com reparações frequentes, desde que o ritmo de deslizamento não se altere
Muito lento	16mm/ano	<ul style="list-style-type: none"> • Algumas estruturas permanentes não serão afetadas
Extremamente lento	> 16mm/ano	<ul style="list-style-type: none"> • Só detetável com equipamento especial • Podem ser realizadas novas construções, desde que sejam tomadas medidas preventivas

1.2 Estado da Arte

1.2.1 Introdução

Na bibliografia existem algumas técnicas para detecção de deslizamentos de terras e derrocadas em ferrovia. Por exemplo, sistemas baseados em tecnologias óticas, radar e de fibra ótica para a detecção de objetos na ferrovia como o LiDAR[10], InSAR [11] e DAS [12]. Estes sistemas, embora já utilizados noutros contextos com sucesso, sofrem de algumas limitações quando aplicados à ferrovia:

- Tecnologia ótica depende das condições climáticas e de iluminação para garantir detecções adequadas [10, 13]
- Radar tem baixa granularidade e alta complexidade para aplicações de tempo-real [11]
- Fibra ótica tem a sua eficácia condicionada por baixo isolamento em relação às interferências exteriores [12]

A pesquisa realizada apresenta algumas das atuais técnicas para monitorização de taludes e detecção de objetos na via-férrea baseadas em tecnologias como sensores de inclinação e vibração, LiDAR, satélite e InSAR:

- Monitorização local

Inclinação Sensores de inclinação instalados ao longo da ferrovia podem detetar alterações bruscas ou fora da norma no ângulo de inclinação do terreno adjacente. Estas alterações podem ser sintomáticas de um futuro deslizamento de terras [14].

Vibração Sensores de vibração podem ser usados para monitorizar vibrações incomuns ou movimentos ao longo da ferrovia. Variações bruscas ou fora da norma nos valores médios de vibração podem ajudar a identificar áreas suscetíveis a deslizamentos de terra [15].

LiDAR Sistemas LiDAR são eficazes na detecção de mudanças na topografia, superfície do solo e também na presença de objetos de grandes dimensões na via-férrea. O LiDAR pode ser usado para criar modelos de elevação de alta resolução que permitem identificar deformações ou movimentos no terreno que podem indicar a ocorrência de deslizamentos de terras, mas são dependentes das condições climáticas e exigem uma elevada componente de processamento computacional.[10]

- Monitorização remota

Monitorização Geodésica Este método envolve a medição precisa de pontos de referência ao longo da ferrovia usando equipamentos geodésicos,

como estações totais, recetores GNSS e inclinómetros [14]. Neste método são consideradas mudanças na posição ou inclinação desses pontos de referência.

Monitorização por inSAR Imagens de radar por satélite são usados para monitorizar mudanças na topografia e no uso da terra ao redor da ferrovia.[11, 16]

A aplicabilidade destas técnicas relativamente ao tema desta tese é discutida na tabela 1.2.

Tabela 1.2: Comparação entre técnicas de monitorização de taludes.

Técnica	Vantagem	Desvantagem
Inclinação	<ul style="list-style-type: none"> • Baixa quantidade de informação transmitida • Detecção preventiva 	<ul style="list-style-type: none"> • Cobertura localizada • Necessita de leituras a médio/longo prazo
Vibração	<ul style="list-style-type: none"> • Caracterização através do domínio do tempo e da frequência 	<ul style="list-style-type: none"> • Significativa quantidade de dados para processar
LiDAR	<ul style="list-style-type: none"> • Quantificação do volume de queda de pedras • Alcance em grandes distâncias 	<ul style="list-style-type: none"> • Complexidade de processamento • Dependente de condições climáticas
Monitorização Geodésica	<ul style="list-style-type: none"> • Análise georreferenciada • Detecção de vários tipos de deslizamento de terras 	<ul style="list-style-type: none"> • Complexidade de processamento de rede de sensores • Cobertura limitada
Monitorização remota por satélite ou radar	<ul style="list-style-type: none"> • Cobertura alargada 	<ul style="list-style-type: none"> • Complexidade de processamento pode não permitir deteção em tempo-real • Custo elevado

1.2.2 Casos de estudo

Foram analisados artigos que abordam a monitorização e prevenção de deslizamento de terras e também segurança em ferrovias. Desse conjunto selecionaram-se três para uma análise crítica, discutindo as diferenças entre essas técnicas e as adotadas nesta tese.

Monitoring and early warning method for a rockfall along railways based on vibration signal

O artigo [17] aborda os riscos das quedas de rochas em ferrovias em regiões montanhosas da China, estudando a vibração gerada pela queda de rochas numa rede de proteção sensorizada e na própria ferrovia. Para evitar falsos positivos, tornou-se necessário distinguir três tipos de eventos: rochas que caem na rede, rochas que passam a rede e caem na ferrovia e o material circulante na ferrovia.

Foram medidas as vibrações geradas pela passagem de material circulante através da colocação de sensores na via-férrea e verificou-se a existência uma distribuição de energia equivalente em todo o espectro de frequência analisado, equivalente a um sinal de ruído branco. No domínio do tempo o sinal evolui de forma crescente, sendo o pico registado aquando da passagem de um eixo pela zona do sensor, decrescendo a partir daí. A presença de rochas foi detetada, mesmo que com menor intensidade, a 20 m do ponto de queda.

Esta pesquisa mostrou que o pico das vibrações geradas pela queda de rochas na rede se situa entre as frequências entre 10 Hz a 20 Hz e que o tamanho das rochas está relacionado com a frequência, amplitude e duração do sinal, embora a análise realizada seja qualitativa e não estabeleça nenhuma relação linear entre o tamanho das rochas e estes parâmetros. No caso da queda de rochas em ferrovia, o pico de vibrações encontra-se entre os 250 Hz a 300 Hz. No domínio do tempo os sinais são de curta duração, na ordem das unidades de segundo.

Conclusões

A conjugação de ambas as técnicas, sensores na rede de proteção e via-férrea, permite a deteção de queda de pedras embora exista a possibilidade da rede de proteção se romper, tornando o sistema menos eficaz no domínio da prevenção, no caso de quedas com maior intensidade energética. A conjugação de sensores na rede e na via-férrea permite apenas detetar situações em que a queda se manifesta diretamente na rede ou na via-férrea, excluindo qualquer outro cenário. O artigo não traça conclusões sobre deslocamentos lentos, vibrações com origem externa à ferrovia ou geradas pela passagem de material circulante.

Distributed acoustic monitoring to secure transport infrastructure against natural hazards - requirements and new developments

O artigo [18] discute a aplicabilidade do sistema DAS para a deteção de obstáculos na via-férrea. O estudo realizado propõe avaliar se é possível detetar obstáculos na via-férrea, através do uso de fibra ótica instalada ao longo do trajeto.

O DAS é um sistema baseado em fibra ótica para deteção de vibrações ou pressão mecânica ao longo de uma fibra ótica, transformando-a numa rede de sensores distribuídos, tendo como princípio de funcionamento a dispersão de Rayleigh no interior da fibra. Esta tecnologia é aplicada em monitorização de vibração em diversas áreas, nomeadamente infraestruturas como oleodutos e ferrovias.

O DAS é composto por três elementos: um laser, um detetor ótico, que compõem um interrogador ótico e uma fibra ótica. O laser envia um pulso de luz com um comprimento de onda conhecido, que atravessa a fibra ótica em toda a sua extensão. Devido a imperfeições na sua estrutura, alguma da luz é refletida na direção oposta

e incide sobre o detetor ótico. Este fenómeno, designado por dispersão de Rayleigh, permite calcular a localização do evento e a sua intensidade ao medir o sinal recebido no detetor ótico no domínio do tempo. Uma fibra ótica instalada numa conduta paralela à linha férrea é sensível a vibrações acústicas, gerando esforço mecânico sobre a fibra, o que modifica a fase e amplitude da luz retrodifundida devido à variação do índice de refração da fibra na zona afetada. O sistema DAS pode ser utilizado em fibras óticas comerciais por distâncias na ordem das dezenas de 50 km, existindo já estudos para a sua extensão por mais de 100 km. Através do DAS, a fibra ótica torna-se numa rede de sensores de vibração distribuídos com uma granularidade na ordem dos metros.

Foram distinguidas três classes de evento:

- Queda de materiais com energia inferior a 1,5 kJ
- Queda de materiais com energia superior a 1,5 kJ
- Passagem de material circulante

O primeiro tipo de evento necessitava de validação manual por um operador, devido à existência de falsos positivos; o segundo tipo de evento foi detetado automaticamente, sem intervenção humana; o terceiro tipo de evento foi corretamente detetado durante a passagem de material circulante em operação normal, mas no caso da realização de operações de manutenção (com paragens e arranques na via-férrea) a identificação não foi possível.

Conclusões

As experiências realizadas mostraram que foi possível detetar a passagem de material circulante, bem como a queda de material com energia superior a 1,5 kJ, como queda de pedras ou queda de árvores. No entanto, devido à alta sensibilidade do sistema por fatores como acoplamento acústico da fibra ótica a estruturas circundantes, eventos climáticos, operação de máquinas ou obras na proximidade, foram gerados cerca de cinco falsos alarmes por dia, na versão de melhor desempenho do sistema. O DAS em ambiente ferroviário poderá ser um sistema viável no futuro se a sua aplicação for melhorada em dois aspetos: os classificadores de deteção e a minimização de interferências externas.

Research on Obstacle Detection Method of Urban Rail Transit Based on Multisensor Technology

No artigo [19] é descrita uma solução híbrida para a deteção de objetos na via-férrea em tempo-real, baseada em visão por computador e LiDAR, num sistema acoplado na frente do comboio. A combinação destas técnicas permite, através do processamento das imagens de vídeo, definir a região de interesse, Region of

Interest (ROI), na linha férrea e com o LiDAR, verificar a existência de objetos dentro dessa ROI, medindo a distância entre o comboio e um potencial obstáculo. Esta conjugação de tecnologias, não sendo uma solução inovadora [20] permite que o foco seja na deteção de objetos na linha, necessitando de definir classes de eventos relativos à presença de objetos na linha férrea e não de classes relativas à passagem de material circulante, por exemplo.

Conclusões

Mesmo considerando ultrapassadas as questões particulares de deteção da ROI referente à linha férrea e a influência das condições climatéricas no desempenho da câmara RGB e do LiDAR, o estudo realizado neste artigo mostra apenas a deteção de pessoas na linha férrea, e não obstáculos como pedras ou árvores, por exemplo. O facto da efetividade do sistema depender da utilização de um comboio para monitoramento da zona afetada faz com que exista sempre o risco de acidente por falha da deteção do objeto e não permite nenhuma ação preventiva por parte do gestor da infraestrutura.

1.3 Objetivos

O estudo desenvolvido permitirá a definição de algoritmos de classificação para a monitorização e deteção de derrocadas e deslizamentos de terra em taludes. Para tal, o sistema deverá classificar corretamente o que são eventos comuns, como a passagem de material circulante, como um comboio de carga ou de passageiros, e o que são eventos de interesse, como um deslizamento rápido de terras ou queda de blocos.

Os objetivos desta tese são:

1. Estudar os diferentes tipos de sinais presentes em ambiente ferroviário do ponto de vista das suas características no tempo e frequência
2. Definir quais as características no domínio do tempo e na frequência que permitem caracterizar os eventos propostos em 2
3. Definir classificadores para deteção automática dos eventos definidos em 2, para dados recolhidos previamente e em tempo real

1.4 Organização da tese

Neste capítulo é realizada uma descrição da motivação e contexto que conduziram à escolha do tema deste trabalho, bem como uma descrição dos seus objetivos. São descritos os principais desafios para os gestores de infraestruturas e operadores

ferroviários causados pela queda de pedras e deslocamentos de terras na ferrovia e possíveis estratégias para a mitigação dos efeitos desses eventos. É também descrito o atual estado da arte de sistemas para medição de vibrações em ambiente ferroviário, discutindo-se as vantagens e desvantagens das abordagens referidas.

No Capítulo 2, é apresentada uma análise ao sensor utilizado para a recolha de dados de vibração, bem como aos sinais adquiridos. São discutidos aspetos como o tipo específico de acelerómetro escolhido e a arquitetura escolhida de processadores, comunicação sem fios e periféricos auxiliares do sensor. É também descrito o contexto de desenvolvimento do sensor, com detalhe para o trabalho realizado no *firmware* do dispositivo para recolha, processamento e envio de dados de vibração.

No Capítulo 3 são descritos os tipos de sinais presentes em ambiente ferroviário, tendo por base referencias mencionadas no Capítulo 1 e recolhas de campo realizadas com o sensor descrito no Capítulo 2. São descritas também técnicas de processamento de sinal que permitem extrair características (*features*). São estas características os dados a classificar para deteção de eventos.

No Capítulo 4 são discutidos diferentes tipos de classificadores aplicados à deteção de eventos. São realizados ensaios com sinais de teste para avaliar a Precisão e a Sensibilidade dos classificadores, considerando características extraídas pela análise nos domínios do tempo e da frequência do sinal.

No Capítulo 5 são realizados ensaios aos classificadores estudados no Capítulo 4 com sinais de vibração adquiridos em campo. Os classificadores são testados para diferentes parâmetros de entrada com o objetivo de maximizar a deteção correta de eventos e a minimização de falsos negativos.

Por fim, no Capítulo 6, são discutidas as conclusões, bem como ideias a desenvolver como trabalho futuro.

2

PLATAFORMA DE AQUISIÇÃO DE DADOS

2.1 Introdução

O sensor utilizado nesta tese para a recolha de dados de vibração foi inicialmente concebido no ISEL como parte integrante do projeto Ferrovia 4.0. A figura 2.1 mostra o sensor, cujo desenvolvimento teve como meta principal a criação de uma plataforma versátil para a deteção e processamento de sinais de vibrações em múltiplos ambientes.

A escolha deste sensor tomou em conta a sua implantação em ambientes adversos, a sua autonomia energética, variedade de opções de acesso a infraestruturas de rede sem fios e a escalabilidade, possibilitando o seu funcionamento em rede. A escalabilidade é um desafio relevante, pois o sensor, ao garantir apenas a cobertura na deteção de vibração num raio de apenas alguns metros, necessita de estar integrado numa rede composta por múltiplos sensores para cobrir uma área abrangente. Outro fator relevante foi o seu acelerómetro de três eixos [21], de baixo nível de ruído e alta sensibilidade.




Figura 2.1: Protótipo final (a) e diagrama geral do sensor (b).

2.2 Arquitetura

O sensor [22], com a suas funcionalidades descritas na figura 2.1 e a sua arquitetura descrita na figura 2.2, é composto por:

- Microcontrolador ARM, para aquisição e armazenamento de dados dos acelerômetros
- Microcontrolador ESP32, para comunicações WiFi e processamento de sinal
- Acelerômetro Analog Devices ADXL355
- Módulo LoRaWAN para comunicações LoRa
- Sistema de colheita de energia integrado baseado no gestor de energia ADP5090, em conjunto com um painel solar e baterias LiFePO4
- Interface para cartão de armazenamento microSD
- Módulo de localização GPS
- Interface RS-485, para uso de acelerômetros externos

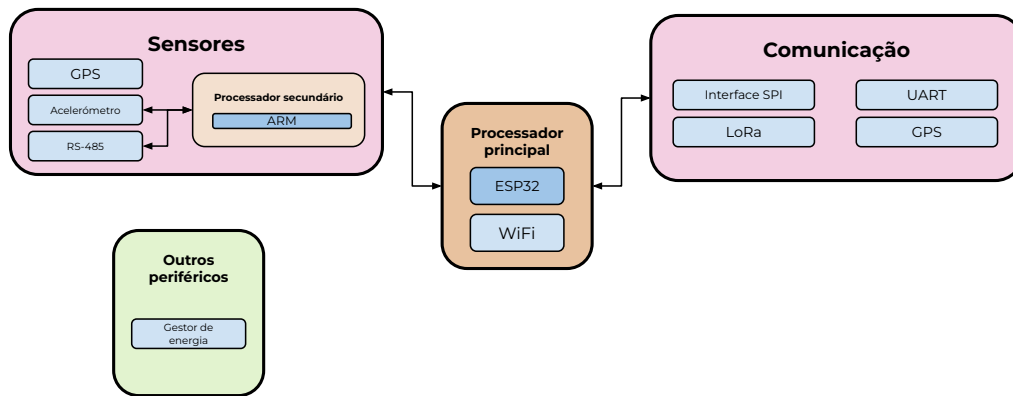


Figura 2.2: Arquitetura do sensor.

2.3 Descrição de blocos

2.3.1 Microcontroladores

ESP32

O ESP32[23] é um microcontrolador de baixo custo e baixo consumo de energia, do fabricante Espressif, de uso comum no desenvolvimento de projetos IoT. Possui um processador interno *dual-core* a 32 bits, suportando um relógio entre 80 MHz a 240 MHz, memória *flash* até 11 MB, com periféricos como WiFi, Bluetooth, relógio de tempo-real interno (RTC) e interfaces de comunicação como SPI, I₂C e cartão SD. A figura 2.3 mostra todos os periféricos disponíveis.

Este processador permite correr a implementação da linguagem Python para microcontroladores, o MicroPython, tomando partido de parte significativa das bibliotecas Python para manipulação e processamento de dados e da implantação de *stacks* de comunicação como WiFi e LoRa.

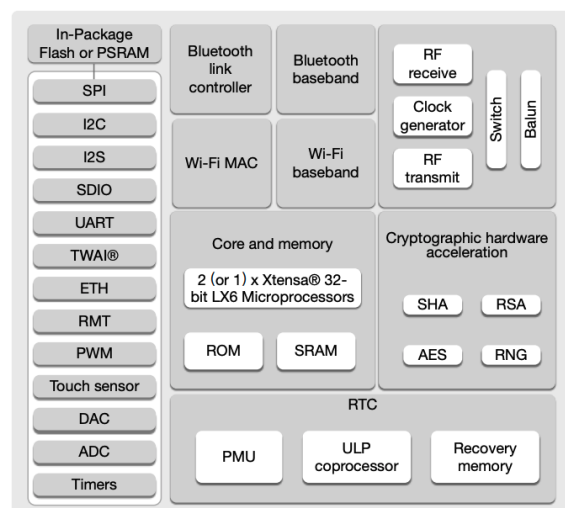


Figura 2.3: Diagrama de blocos do microcontrolador ESP32.

Para a recolha de dados desenvolveu-se *firmware* especializado em MicroPython que implantasse as seguintes funcionalidades:

- Configurar o acelerómetro, através do microcontrolador ARM
- Aguardar atividade detetada pelo acelerómetro
- Recolher dados, através do microcontrolador ARM
- Enviar dados por WiFi

ARM

O microcontrolador ARM de muito baixo consumo escolhido é o STM32L451, do fabricante STMicroelectronics, baseado na arquitetura RISC Cortex-M4 a 32-bit de *core* único, com relógio até 80 MHz, memória *flash* de 256 kB e periféricos como RTC. A arquitectura do microcontrolador é descrita na figura 2.4. O seu papel no sensor é estabelecer um interface de comunicação e armazenamento de amostras recolhidas por um ou mais acelerómetros e, por sua vez, através do protocolo SPI enviar para o microcontrolador ESP32, funcionalidade esta já implementada pelo fabricante.

Este microcontrolador foi escolhido devido à sua FPU, possibilitando numa iteração futura do projeto o rápido processamento de amostras com bibliotecas baseadas na linguagem C/C++.

O consumo deste processador quando em funcionamento foi medido e situa-se na ordem dos 5mA quando o sensor em modo de repouso, sendo o processador responsável por despertar o sensor quando é detetada atividade de vibração.

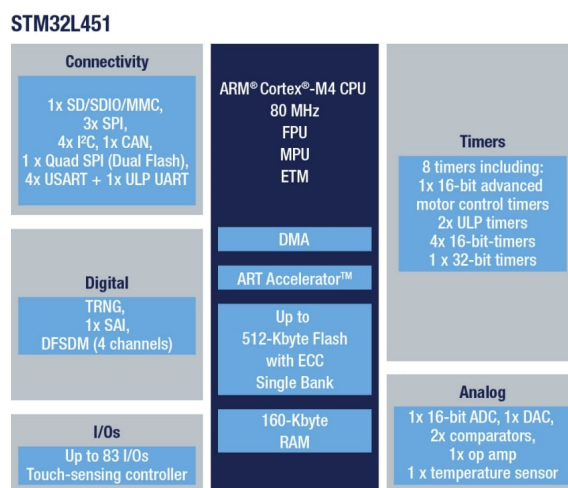


Figura 2.4: Diagrama de blocos funcional do microcontrolador ARM STM32.

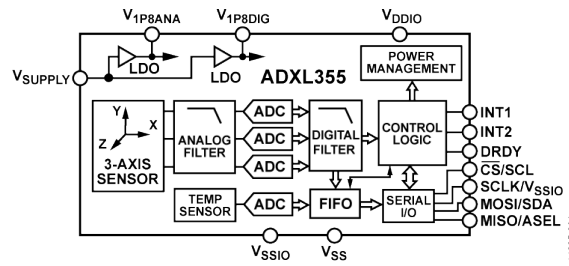


Figura 2.5: Diagrama de blocos funcionais do acelerômetro ADXL355.

2.3.2 Acelerômetro

A escolha do acelerômetro MEMS ADXL355 [21], do fabricante Analog Devices, levou em conta as características de consumo, custo, nível de ruído, sensibilidade, geração de eventos através da definição de um limiar de aceleração e da existência de uma memória *buffer* do tipo FIFO para evitar a perda de amostras. Este dispositivo foi utilizado também em outros projetos ligados à medição de vibrações em ambiente ferroviário [6, 24]. Na figura 2.5 está presente o seu diagrama de blocos funcionais.

O ADXL355 permite configurar o valor máximo de aceleração detetável nos eixos x , y e z de $\pm 2g$ a $\pm 8g$, com uma resolução de 20 *bits* por cada eixo. Cada amostra pode ser armazenada na memória FIFO, de até 32 amostras de vibração, posteriormente transferidas por SPI para a memória *flash* microcontrolador ARM.

O débito de amostragem é também variável, entre 4Hz a 4000Hz, com um filtro passa-baixo de frequência de corte quatro vezes inferior à frequência de amostragem, variando entre 1Hz a 1000Hz. A frequência máxima que o acelerômetro consegue recolher é limitada por um filtro analógico de *anti-aliasing*, com f_c de 1500Hz.

O sensor estará a maior parte do seu tempo a aguardar a ocorrência de um evento, portanto estará em modo *deep sleep*, consumindo o mínimo possível de energia. Este acelerômetro possui a capacidade de gerar interrupções quando a aceleração a que é submetido ultrapassada um determinado limiar. Estas interrupções são utilizadas para despertar o microcontrolador ESP32, responsável pelo processamento e envio de dados, algo necessário no contexto de um sensor autónomo a nível energético.

O ADXL355 possui uma densidade espectral de ruído na ordem de $25 \mu g \sqrt{Hz}$, o que a uma frequência de amostragem de 1000Hz se traduz em 0,7 mg [25]. Outra das suas características é a baixa dependência da aceleração relativamente à temperatura, na ordem dos 0,15 mg/°C dentro da gama de temperatura entre $-40^\circ C$ e os $+125^\circ C$, desta forma mostrando que é indicado para uso em ambientes exteriores sujeitos a uma significativa variação de temperatura ao longo do ano.

2.4 Funcionamento do sensor

2.4.1 Detecção de vibração em taludes

Pretendeu-se que o modo de funcionamento do sensor maximizasse a sua autonomia energética, garantindo que o sensor apenas iria despertar quando fosse detetada vibração ou quando realizasse alguma atividade temporizada e que no restante período permanecesse adormecido, em modo *deep sleep*. No modo *deep sleep* o microcontrolador principal ESP32 desliga todos os seus periféricos, garantindo um consumo mínimo de energia, mantendo apenas ativo o RTC e a sua memória RAM de 8kB, bem como o modo de despertar por interrupção externa.

O sensor é despertado por três razões possíveis:

- *Power on wake-up*: no caso da bateria estar anteriormente desligada ou sem carga. O sensor perde a informação relativa ao RTC e tenta sincronizar, se possível.
- *Activity wake-up*: o acelerómetro deteta vibração acima de um liminar, gera uma interrupção, despertando o sensor. Dependendo do modo de funcionamento implantado, pode enviar os dados em bruto por WiFi ou realizar um processamento local, enviado características do sinal por LoRa
- *RTC wake-up*: periodicamente o sensor desperta para realizar uma atividade pré-definida.

Para este estudo apenas é relevante o modo *Activity wake-up*.

Activity wake-up

O acelerómetro gera uma interrupção que desperta o sensor e o coloca em funcionamento. Os dados gerados são recolhidos e armazenados pelo microcontrolador ARM, executando continuamente uma rotina de leitura de novos dados do acelerómetro, sendo de seguida enviados por SPI para o microcontrolador ESP32. Dependendo do modo de funcionamento implantado, o sensor pode enviar os dados em bruto por WiFi ou realizar um processamento local, enviado características do sinal por LoRa. Relativamente a outro tipo de atividades relacionadas com a operação do sensor em si, este é dotado de um RTC, sincronizado via WiFi, com a possibilidade de vir a ser sincronizado por LoRa.

2.4.2 Recolha e transmissão de dados em bruto

No âmbito desta tese a recolha de dados foi feita sem processamento e com a transmissão de dados realizada através de WiFi para que o processamento seja feito posteriormente. Estes dados brutos de vibração recolhidos pelo sensor foram utilizados

pelo sistema de classificação implantado neste trabalho.

Envio de dados em tempo real por WiFi

Este modo de utilização permitiu recolher sinais para posterior análise *offline*, tendo sido desenvolvido *firmware* que implementa as seguintes funcionalidades:

- Configuração de parâmetros do acelerómetro
- Leitura de dados em bloco do acelerómetro em tempo-real
- Envio de dados recolhidos via WiFi para armazenamento num servidor local, por ligação UTP

2.5 Medição com o sensor

O sinal medido pelo sensor dá origem a um vetor tridimensional de aceleração, com os eixos X, Y e Z correspondentes ao referencial da figura 2.6, onde os eixos X e Y estão no mesmo plano da figura e Z é o eixo que sai da figura. Quando colocado numa superfície paralela ao nível do chão, o valor dos eixos X e Y é 0 *g* e o do eixo Z igual a 1 *g*.

Neste estudo, e seguindo o trabalho de outros autores [17], iremos considerar o módulo deste sinal, calculando através da equação 2.1.

$$\text{modulo}[n] = \sqrt{x[n]^2 + y[n]^2 + z[n]^2}, \quad (2.1)$$




Figura 2.6: Referencial dos eixos de aceleração do sensor.

2.6 Medição de sinais em campo

2.6.1 Passagem de material circulante e queda de pedras em via-férrea

A recolha de dados em via-férrea com o sensor foi conduzida em ambiente real com fácil acesso aos taludes, especificamente num local da Linha de Cintura de Lisboa próximo do ISEL, o apeadeiro de Chelas, na figura 2.7.

Em ambos os casos os dados foram recolhidos em tempo real pelo sensor e enviados para um servidor local através de uma rede WiFi *ad-hoc*.

Apeadeiro de Chelas

Com o sensor instalado num talude, presente na figura 2.7, foi possível recolher sinais de vibração, amostrados a uma frequência de 4000 Hz, como os presentes na figura 2.8. Foram também adquiridos sinais de queda de pedras simulada, arremessando para o talude pedras com peso inferior a 100 g.




Figura 2.7: Talude (a) onde foi instalado o sensor (b) nos ensaios no Apeadeiro de Chelas.

Caracterização do sinal no domínio do tempo


Passagem de material circulante

O sinal de vibração medido tem a forma de um fuso no domínio do tempo [17], espelhando o efeito de aproximação e afastamento do comboio face à localização do

sensor. Nas observações realizadas, verificou-se uma duração do evento entre os 10 s a 30 s.



(a)




(b)


Figura 2.8: Sinais de passagem de comboios *comboio1* e *comboio2* (a e b), adquiridos com f_s de 4000Hz.

Queda de pedras

A vibração gerada por queda de pedras origina um sinal impulsivo, de curta duração e de decaimento rápido, geralmente com duração inferior a 100 ms, visível nas figuras 2.9 e 2.10.



(a)




(b)


Figura 2.9: Resposta do domínio do tempo dos sinais de queda de pedras *pedra1* e *pedra2* (a e b), adquiridos com f_s de 4000Hz.

2.6.2 Ruído ambiente

O ruído ambiente do sensor é composto pelas contribuições do nível de ruído do acelerómetro, cuja amplitude e distribuição espectral é conhecida [21], mas também



(a)




(b)

Figura 2.10: Resposta do domínio do tempo de sinais de queda de pedras *pedra3* e *pedra4*, adquiridos com f_s de 4000Hz (a e b).

pelo ruído ambiental presente no meio em que o sensor é instalado. Estas podem ter diversas origens, tais como as condições climáticas da região (incidência direta de vento no sensor ou chuva), proximidade de cursos de água, trânsito rodoviário e ferroviário, indústrias e construção, entre outros.

Caracterização do sinal no domínio do tempo



(a)

Figura 2.11: Resposta do domínio do tempo de um sinal de ruído na ausência de eventos ferroviários, adquirido com f_s de 4000Hz.

Este sinal foi captado pelo sensor quando instalado no talude do Apeadeiro de Chelas durante períodos sem atividade, permitindo a determinação do nível de aceleração médio em repouso.

O valor de pico do ruído do sensor situa-se nos 2 mg, sendo a variação no tempo da amplitude de carácter aleatório e sem características impulsivas. Uma destas medições do ruído está presente na figura 2.11.

3

EXTRAÇÃO DE CARACTERÍSTICAS DE SINAIS DE VIBRAÇÃO

3.1 Introdução

Neste capítulo foi realizado um estudo a partir destes sinais para a escolha de características que permitam distinguir entre diferentes classes. A taxonomia destas classes está descrita na figura 3.1.

A extração de características dos sinais permite reduzir a quantidade de dados a transmitir e processar. O sinal é analisado em blocos designados por *janelas*, onde é assumido que as características que o definem se mantêm relativamente constantes. Neste estudo definiu-se um conjunto de características de interesse baseadas, por




Figura 3.1: Taxonomia dos eventos de vibração em ambiente ferroviário estudados.

exemplo, na variação da potência do sinal [26, 27], sendo extraídas características no domínio do tempo e da frequência.

No domínio do tempo consideraram-se as seguintes características:

- Valor eficaz da potência
- Valor médio da potência
- Valor de pico da potência
- Taxa de cruzamento de zeros da amplitude
- Desvio-padrão da amplitude

Na tabela 3.1 temos a variação qualitativa de cada característica face ao tipo de evento ocorrido, representando uma tendência geral de cada uma.

Tabela 3.1: Variação qualitativa das características do domínio do tempo para as classes estudadas.

Características	Variação		
	Pedras	Comboio	Ruído
Valor eficaz da potência	Média	Media	Baixa
Valor médio da potência	Média	Media	Baixa
Valor de pico da potência	Alta	Média	Baixa
Taxa de cruzamento de zeros da amplitude	Alta	Média	Alta
Desvio-padrão da amplitude	Alta	Alta	Baixa

No domínio da frequência consideraram-se as seguintes características:

- Magnitude da frequência do espectro

Sobre a análise do espectro pretende-se estudar se certas bandas de frequência permitem discriminar os eventos.

3.2 Janelamento

O janelamento (*windowing*) consiste na divisão de um sinal em segmentos temporais chamados janelas de amostras, onde as suas características permanecem praticamente constantes. Esta técnica pode ser aplicada em tempo-real, em cenários aonde vão sendo conhecidas porções do sinal e não a sua totalidade.

A duração da janela de amostras pode ter em conta a natureza de eventos a analisar. Num cenário onde a totalidade do evento seja analisada como um bloco único, como uma queda de pedras que gera picos de amplitude, o cálculo do valor médio ou máximo do sinal tenderia a se aproximar do valor médio geral, mascarando a real intensidade do evento ferroviário. No entanto, se o sinal for analisado em blocos

menores, a influência de cada impulso é considerada dentro de um intervalo de tempo mais curto, destacando-se relativamente ao valor médio de amplitude dessa janela. Esta análise permite também considerar que uma sequência longa de dados, isto é, com alguns segundos de duração, pode conter diferentes tipos de eventos: inicialmente pode conter uma queda de pedras, seguida pela ausência de eventos onde só é detetado ruído e por fim a passagem de material circulante. Este tipo de sinal não será objeto de estudo nesta tese.

A dimensão ótima da janela deverá ser selecionada em função de duas condicionantes:

- Minimização do número de cálculos a realizar
- Detecção de eventos de natureza impulsiva, isto é, eventos com elevada potência de pico, mas cuja duração é muito curta, na escala dos milissegundos

Aplicação

A técnica de janelamento consiste na multiplicação de uma função de janela $w[n]$ com uma secção do sinal $x[n]$ a analisar, ambos de dimensão N_{frame} , a começar num índice $n = k$. O resultante é uma porção do sinal original apenas entre as amostras k e $k + N_{frame}$. Dependendo do formato da janela, o conteúdo espectral do novo sinal resultante pode sofrer alterações devido a fenómenos de vazamento espectral (*spectral leakage*) gerando lóbulos laterais no espectro ou *aliasing*, bem como alterações na amplitude do espectro. Nos testes realizados considerou-se a função de janelamento de Hann e a abordagem *Overlap-Add*, que será descrita mais à frente.

A janela de Hann permite uma relação equilibrada entre a supressão dos lóbulos laterais e a manutenção da amplitude do lóbulo central, mantendo uma melhor resolução de frequência que a janela de Hamming, por exemplo. Na figura 3.2 está representada a partição de um sinal de vibração em janelas de amostras e com a aplicação de uma janela de *Hann*.

A abordagem *Overlap-add* pode ser aplicada a sinais adquiridos previamente ou em tempo-real, para análise, processamento e reconstrução de um sinal no domínio do tempo. A partição do sinal é realizada com janelas simétricas de N_{frame} amostras e espaçadas entre si $\frac{N_{frame}}{2}$. Seguindo esta partição, e observando a figura 3.2, é possível verificar que, quando somadas as regiões particionadas do sinal após aplicação de uma janela, o sinal original pode ser reconstruído sem alterações no domínio do tempo e minimizando o vazamento espectral no domínio da frequência.




Figura 3.2: Exemplo de janelamento de um sinal de vibração gerado pela passagem de um comboio, com recurso a uma janela de *Hann*.

Uma janela $x_i[n]$ extraída de um sinal $x[n]$, onde i é o índice da janela, é dada por:

$$x_i[n] = \sum_{n=1}^{N_{signal}} x[n] * w[n - N_{frame}], \quad (3.1)$$

onde N_{frame} é a dimensão da janela em amostras e $w[n]$ é uma função de janelamento de dimensão igual a N_{frame} .

3.3 Características no domínio do tempo

Inicialmente realizou-se um estudo de propriedades do sinal relativas à potência do sinal, bem como propriedades estatísticas como desvio padrão e taxa de cruzamento de zeros. O objetivo foi relacionar a variação destas propriedades ao longo do tempo com sinais gerados por diferentes tipos de eventos. A potência do sinal foi estudada através da potência média, potência RMS e valor de pico.

Nas figuras 3.3 e 3.4 são apresentadas essas seis características aplicadas a sinais de vibração gerados por comboios e por pedras, respectivamente.

3.3.1 Valor eficaz da potência do sinal

O valor eficaz da potência do sinal é dado por:

$$RMS[i] = \sqrt{\frac{1}{N_{frame}} \sum_{n=1}^{N_{frame}} |x_i[n]|^2}, \quad (3.2)$$

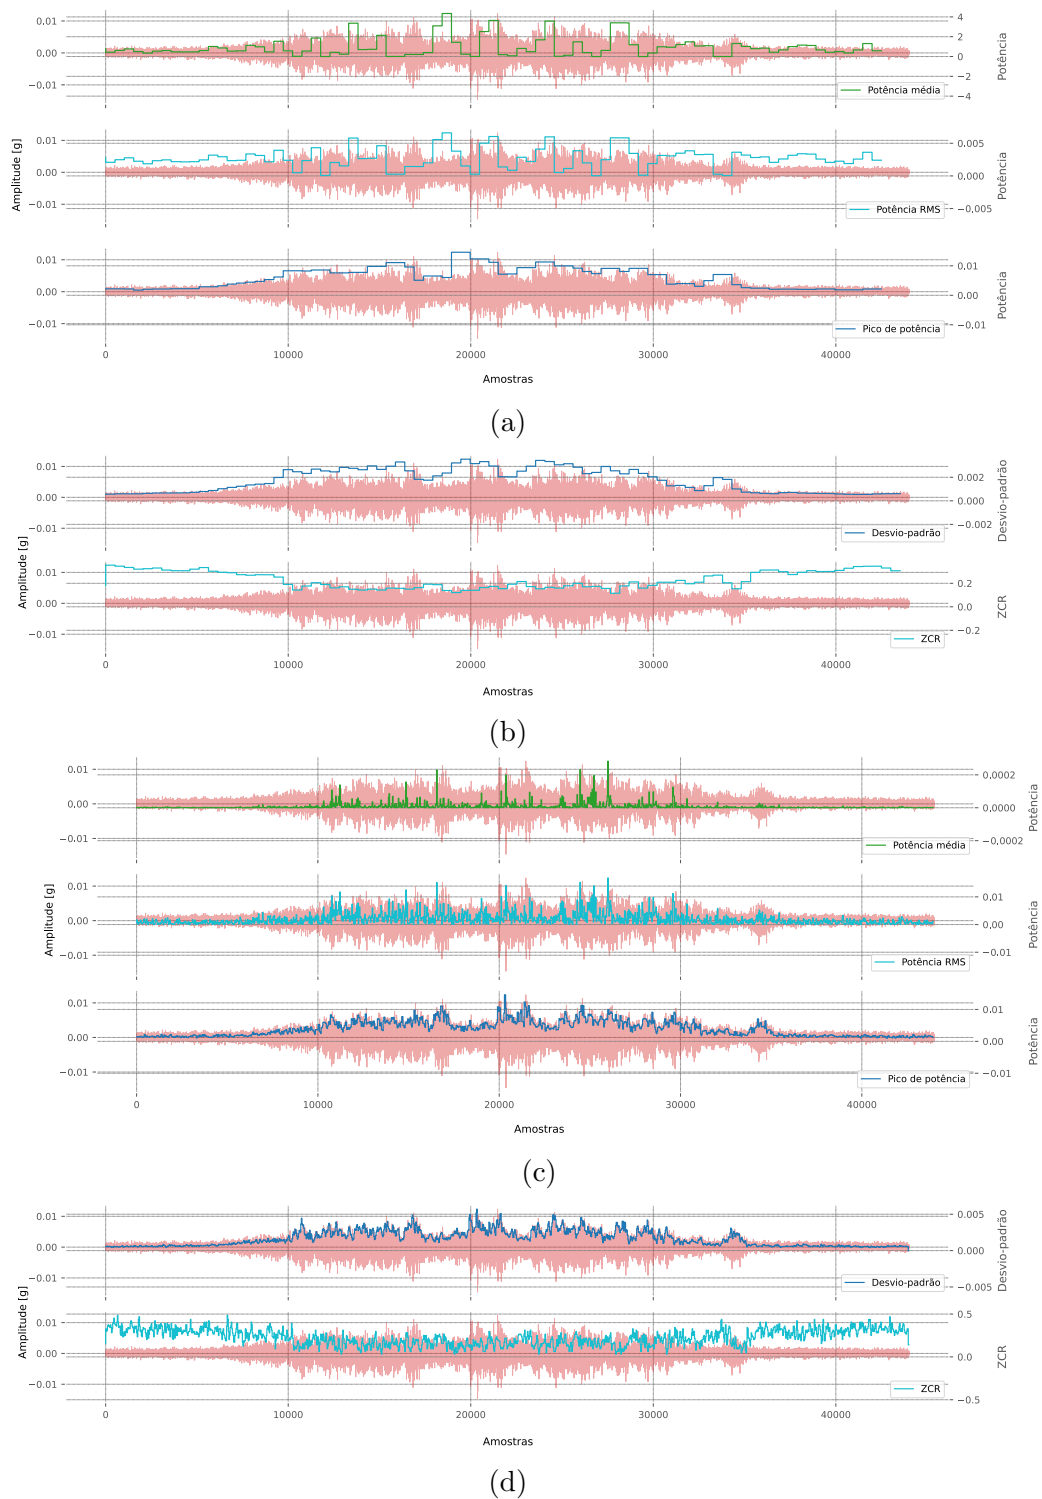


Figura 3.3: Sinal de vibração *comboio1* e as suas características no domínio do tempo como *Potência Média*, *Potência RMS* e *Pico de Potência* (a) e (c) e *Desvio-Padrão* e *Taxa de Cruzamento de Zeros* (b) e (d) para uma janela de 1024 (a) e (b) e 64 (c) e (d) amostras.

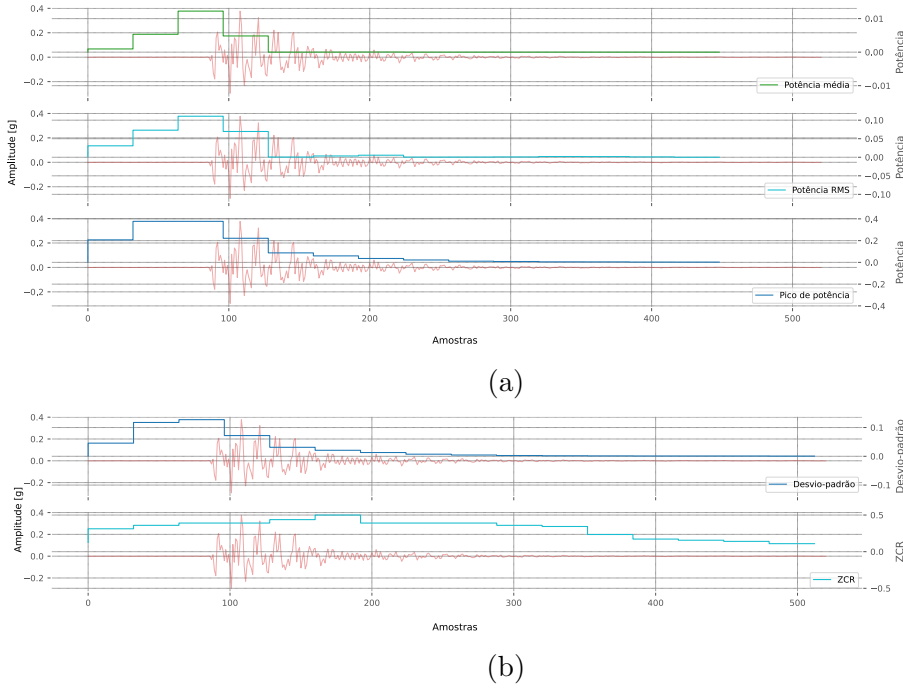


Figura 3.4: Sinal de vibração *pedra3* e as suas características no domínio do tempo como *Potência Média*, *Potência RMS* e *Pico de Potência* para uma janela de 64 amostras.

onde $RMS[i]$ representa a potência eficaz de uma janela de índice i do sinal $x[n]$. O valor $x_i[n]$ representa a amostra n do conjunto de amostras da janela de índice i e de dimensão N_{frame} .

Este parâmetro será designado como *rms*.

3.3.2 Valor médio da potência do sinal

O valor médio da potência do sinal é dado por:

$$Mean[i] = \frac{1}{N_{frame}} \sum_{n=1}^{N_{frame}} |x_i[n]|^2, \quad (3.3)$$

onde $Mean[i]$ representa a potência média de uma janela de índice i do sinal $x[n]$. O valor $x[n]$ representa a amostra n do conjunto de amostras da janela de índice i e de dimensão N_{frame} .

Este parâmetro será designado como *mean*.

3.3.3 Valor de pico da potência do sinal

O valor de pico de um sinal permite conhecer o maior valor de amplitude ou potência do sinal numa dada janela temporal. Quando relacionado com o valor médio ou RMS da potência, permite detetar a existência de valores atípicos ou fora da norma, possíveis indicadores de eventos de carácter impulsivo, por exemplo. No caso de um

sinal com baixa variação de amplitude o seu valor médio e de pico serão aproximados, enquanto num sinal impulsivo o valor máximo e médio serão diferentes.

O valor de pico da potência de um sinal é dado por:

$$Peak[i] = \max_{1 \leq n \leq N_{frame}} Power_i[n], \quad (3.4)$$

onde $Peak[i]$ representa o valor de máximo da potência $Power[n]$, compreendido entre a amostra $n = 1$ a $n = N_{frame}$ de um sinal $x_i[n]$.

Este parâmetro será designado como **peak**.

3.3.4 Taxa de cruzamento de zeros da amplitude do sinal

A taxa de cruzamento de zeros, *Zero Crossing Rate* (ZCR), indica quantas vezes um sinal atravessa o valor zero de amplitude, o que é um indicador da periodicidade do sinal, no caso de variação baixa de ZCR, ou da sua aleatoriedade, no caso de variação alta de ZCR. Este parâmetro tem a vantagem de ser computacionalmente pouco complexo.

O valor de ZCR é dado por:

$$ZCR[i] = \frac{1}{2} \sum_{n=1}^{N_{frame}} |sgn(x_i[n]) - sgn(x_i[n-1])|, \quad (3.5)$$

onde $ZCR(i)$ representa a variação de ZCR de uma janela de índice i . O valor $x_i(n)$ representa a amostra n do conjunto de amostras da janela de índice i e de dimensão N_{frame} . A função sgn retorna 1 se a amostra $x_i[n]$ for igual ou maior do que zero e -1 se for menor que zero.

Este parâmetro será designado por **zcr**.

3.3.5 Desvio-padrão da amplitude do sinal

O desvio-padrão indica quanto um sinal varia em torno da sua média. Um sinal de queda de pedras, por exemplo, terá um desvio padrão superior ao sinal de passagem de comboio, porque neste a amplitude tem uma variação inferior ao longo do tempo. O desvio-padrão é dado nas unidades de cada característica, o que facilita a sua interpretação. O valor do desvio-padrão é dado por:

$$SD[i] = \sqrt{\frac{\sum_{n=1}^{N_{frame}} |x_i[n] - \bar{x}_i|^2}{N_{frame}}}, \quad (3.6)$$

onde $SD[i]$ representa o desvio-padrão uma janela de índice i de dimensão N_{frame} . O valor \bar{x}_i representa a média da mesma.

Este parâmetro será designado por *std*.

3.4 Características no domínio da frequência

Foram analisados os espectros dos sinais, bem como os espectrogramas de forma a compreender a evolução das componentes de frequência do sinal ao longo do tempo e a possível proeminência de umas sobre outras.

Os espectros dos dois tipos de sinais indicam que, embora ambos coincidam na maioria da ocupação do espectro, a passagem de material circulante gera componentes de frequência únicas acima de 1000 Hz. Este fator pode ser essencial para distinguir entre os dois tipos de eventos, por exemplo. Propõe-se então que a potência das componentes de alta frequência seja uma característica a considerar para classificação de eventos. As figuras 3.5, 3.6, 3.7 e 3.8 mostram os espectros dos sinais estudados neste trabalho, estando as suas componentes de frequência dentro dos valores presentes na tabela 3.2.

Nesta tabela [2] verifica-se que as componentes de frequência dos sinais gerados por material circulante se podem dividir em três grupos:

- Baixa frequência - inferior a 15 Hz
- Média frequência - entre a 15 Hz a 500 Hz
- Alta frequência - de 500 Hz até 2000 Hz


Conclui-se que a f_s do acelerómetro do sensor deverá ser pelo menos 4000 Hz de forma a amostrar a totalidade deste tipo de sinais. No entanto, de modo a diminuir a quantidade de informação a adquirir, admite-se que as vibrações de frequências características mais baixas possam ser suficientes para caracterizar o sinal.

3.4.1 Comboio


Assume-se que um pico de amplitude no espectro é relevante se for pelo menos uma ordem de grandeza acima do nível de ruído. Embora em ambas exista uma componente de amplitude considerável até aos 100 Hz e entre 200 Hz a 500 Hz, numa das medições existem componentes centradas em frequências superiores como 1000 Hz.

3.4.2 Pedras


Em linha com resultados encontrados em outros estudos [17] os sinais no domínio da frequência provenientes de quedas de pedras apresentam uma magnitude significativa na faixa de 20 a 80 Hz. São visíveis dois picos comuns a todas as medições: a partir




(a)



(b)



(c)



(d)

Figura 3.5: Resposta do domínio da frequência dos sinais de passagem de comboios *comboio1* e *comboio2*, adquiridos com f_s de 4000Hz (a e c) e respectivos espectrogramas a 128 e 256 amostras (b e d).

Tabela 3.2: Fontes de vibração geradas pela passagem de material circulante.

Velocidade do comboio (km/h)	40	80	160
Deslocamento da massa do comboio (Hz)	3	5	11
Desalinhamento dos carris (Hz)	>1 a >100	>2 a >200	>4 a >400
Desgaste dos carris (Hz)	500	1000	2000
Desalinhamento de rodados (Hz)	>4	>8	>15
Poligonização de rodados (Hz)	100	200	400
Espaçamento entre bogies (Hz)	1	3	5
Espaçamento entre travessas (Hz)	múltiplos de 16	múltiplos de 32	múltiplos de 64

de unidades de Hz até valores inferiores a 100 Hz e também entre os 250 Hz e os 350 Hz.

3.4.3 Ruído


Na sua distribuição espectral o ruído é praticamente uniforme em todo o espectro, como se verifica na figura 3.8. Isto indica que, para as medições realizadas, não existem componentes de frequência que se destacam em termos de amplitude face ao restante do espectro.

Na passagem de material circulante existem casos em que frequências acima de 750 Hz exibem uma amplitude na mesma ordem de grandeza das frequências mais comuns entre queda de pedras.



Este comportamento nos dois tipos de evento a classificar mostra que as características extraídas no domínio da frequência podem não permitir a distinção entre os dois tipos de eventos porque existem componentes comuns a ambos os eventos, como mostra a figura 3.9.

Uma possível explicação para este fenómeno pode passar pela ressonância da caixa ou da estrutura à qual o sensor está acoplado. Não existe um estudo por parte do fabricante do sensor que permita validar esta hipótese e o estudo do sensor está fora do âmbito desta tese.


Independentemente do peso destas duas possíveis causas, esta realidade mostra que uma análise qualitativa às componentes de frequência do sinal não permite distinguir entre diferentes tipo de evento. Analisando a evolução da amplitude das frequências ao longo do tempo através do espectrograma das figuras 3.5, 3.6 e 3.7 verifica-se que





(a)



(b)




(c)





(d)


Figura 3.6: Resposta do domínio da frequência de sinais de queda de pedras *pedra1* e *pedra2*, adquiridos com f_s de 4000Hz (a e c) e respectivos espectrogramas a 128 e 256 amostras (b e d).





(a)



(b)




(c)




(d)

Figura 3.7: Resposta do domínio da frequência de sinais de queda de pedras *pedra1* e *pedra2*, adquiridos com f_s de 4000Hz (a e b) e respectivos espectrogramas a 128 e 256 amostras (c e d).



(a)



(b)

Figura 3.8: Resposta do domínio da frequência (a) e espectrograma (b) de um sinal de ruído na ausência de eventos ferroviários, adquirido com f_s de 4000Hz.




Figura 3.9: Sobreposição dos espectros de sinais de vibração gerados pela passagem de comboios e pedras.

as componentes de maior frequência dos sinais decaem mais rapidamente do que as de baixa frequência, sugerindo que a sua presença no espectro possa ser menos relevante para a caracterização do evento, mas tal só se poderá comprovar através de diferentes técnicas de análise espectral [7].

4

CLASSIFICADORES

4.1 Introdução

Neste capítulo é discutido o desenho de um sistema de classificação automático em tempo-real alimentado por um conjunto de características distintivas de eventos ferroviários. Para escolha do classificador o critério adotado foi a maximização da Precisão (maximização de classificações corretas) e Sensibilidade (minimização de falsos negativos). Um falso negativo num sistema de monitorização de linhas férreas pode omitir um evento de deslizamento de pedras, o que pode originar um acidente que, para além de atrasos na exploração e danos materiais, pode gerar perdas humanas.

Foram estudadas diferentes abordagens para a escolha de um classificador [28], tendo-se iniciado o estudo da classificação com recurso a duas características no domínio do tempo dos sinais estudados.

Foram considerados dois algoritmos de classificação:

- k-vizinhos mais próximos (k-NN)
- Centroide mais próximo

Para ambos os classificadores o seu princípio de funcionamento baseia-se no cálculo de distâncias entre pontos e pretende-se que, para ambos, se realize a optimização dos seus hiperparâmetros. Esta optimização permite maximizar o número de deteções

válidas e minimizar os falsos positivos e negativos. Para o caso em estudo esta assume duas formas: o ajuste de hiperparâmetros do classificador, por exemplo, no caso do k-NN encontrar o número de k ótimo para a detecção das várias classes e também a escolha da dimensão da janela de amostras a considerar para cada classificação.

O sistema de classificação proposto na figura 4.1 consiste em seis blocos que serão descritos neste capítulo:

- Aquisição de dados
- Conjunto de treino
- Pré-processamento de dados
- Classificador
- Pós-processamento de resultados
- Classificador de eventos

Os sinais recolhidos foram divididos em dois grupos: um conjunto de treino e um conjunto de teste. O conjunto de treino proposto é composto por sinais adquiridos em ambiente real, previamente validados como pertencentes a uma determinada classe. Na pesquisa para este trabalho não foram encontrados conjuntos de treino padrão para validação de classificadores de sinais de vibração em ambiente ferroviário ou rodoviário, ao contrário de outras áreas de estudo como eventos sísmicos onde a validação recorrendo a bases de dados padrão é comum.

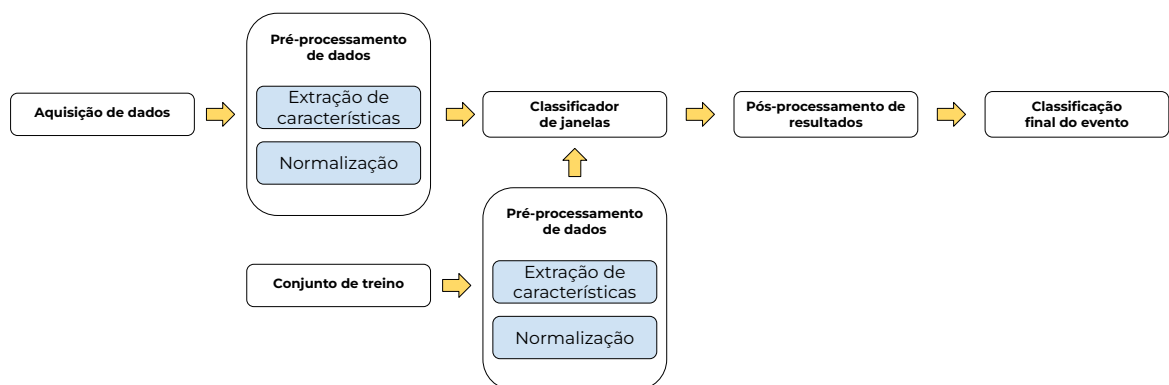


Figura 4.1: Diagrama de blocos do sistema de aquisição e classificação de eventos.

4.2 Conjuntos de treino

Para a formação dos conjuntos de treino foram consideradas três classes de eventos: *Ruído*, *Comboio* e *Pedras*, onde a variável medida é a aceleração, em unidades de gravidade g .

4.2.1 Classe *Ruído*

A classe *Ruído* é composta por sinais de vibração ambiental numa determinada linha ferroviária, resultante das contribuições de vários elementos da sua envolvente como vento, tráfego rodoviário, ruído do acelerómetro, entre outros na ausência de qualquer tipo de atividade numa linha férrea. Conhecer o comportamento do ruído permite estabelecer um critério para deteção de eventos em que qualquer variação de aceleração acima do nível médio do ruído poderá ser indicador de um evento.

O conjunto de treino em uso é composto por três sinais correspondentes ao nível médio de ruído medido na via-férrea na ausência de qualquer interferência externa, presente na figura 4.2. Devido à natureza constante do sinal *Ruído*, considerou-se que uma aquisição de duração igual ou inferior a 1 s por sinal seria suficiente para caracterizar esta classe.




Figura 4.2: Conjunto de treino da classe *Ruído*.

4.2.2 Classe *Comboio*

A classe *Comboio* considera eventos de passagem de material circulante como comboios de passageiros, de carga e veículos de manutenção da via-férrea de qualquer comprimento e dentro dos limites de velocidade de operação para a via em questão.

A figura 4.3 mostra o conjunto de treino em uso, composto por três sinais correspondentes à passagem de material circulante, obtidos durante a passagem de comboios de passageiros num apeadeiro desativado em Lisboa, onde o sensor foi montado num talude.

O sinal da classe *Comboio* possui uma característica crescente de amplitude da aceleração, resultante da posição relativa do material circulante ao sensor, tendo se considerado que uma aquisição com duração igual ou superior a 2 s seria suficiente para caracterizar esta classe. No caso em estudo, o conjunto de treino é composto

por vários segmentos de uma passagem de material circulante que caracterizam as etapas de aproximação, coincidência e afastamento.




Figura 4.3: Conjunto de treino da classe *Comboio*.

4.2.3 Classe *Pedra*

A classe *Pedra* inclui os tipos de queda de pedras possíveis de obter dadas as condicionantes na aquisição deste tipo de sinais. É composta por sinais de carácter impulsivo ou continuado e qualquer ocorrência que coloque em causa a segurança da via-férrea e a passagem de material circulante.

O conjunto de treino em uso é composto por três sinais de vibração correspondentes a queda de pedras num talude. Estes sinais, presentes na figura 4.4 foram obtidos simulando uma queda de pedras, projetando pedras de peso inferior a 100 g em direção ao talude onde o sensor se encontrava. Os sinais da classe *Pedra* é de muito curta duração, tendo se considerado que uma aquisição com duração igual ou inferior a 100 ms seria suficiente para caracterizar os sinais desta classe. A sua amplitude é de ordem de grandeza cerca de cem vezes superior à classe *Ruído*.




Figura 4.4: Conjunto de treino da classe *Pedra*.

4.3 Pré-processamento de dados

4.3.1 Normalização

As gamas de valores das características estudadas podem variar entre si em várias ordens de grandeza, o que pode fazer com que classificadores baseados em distância não tenham o comportamento desejado. Estes classificadores serão mais sensíveis às características com valores absolutos maiores, fazendo com que a sua variação tenha maior influência no resultado final do que as restantes.




Figura 4.5: Exemplo da distribuição de um histograma de duas características antes e depois a normalização. Note-se a diferença de escala do eixo x no gráfico à esquerda e a sua coincidência à direita.

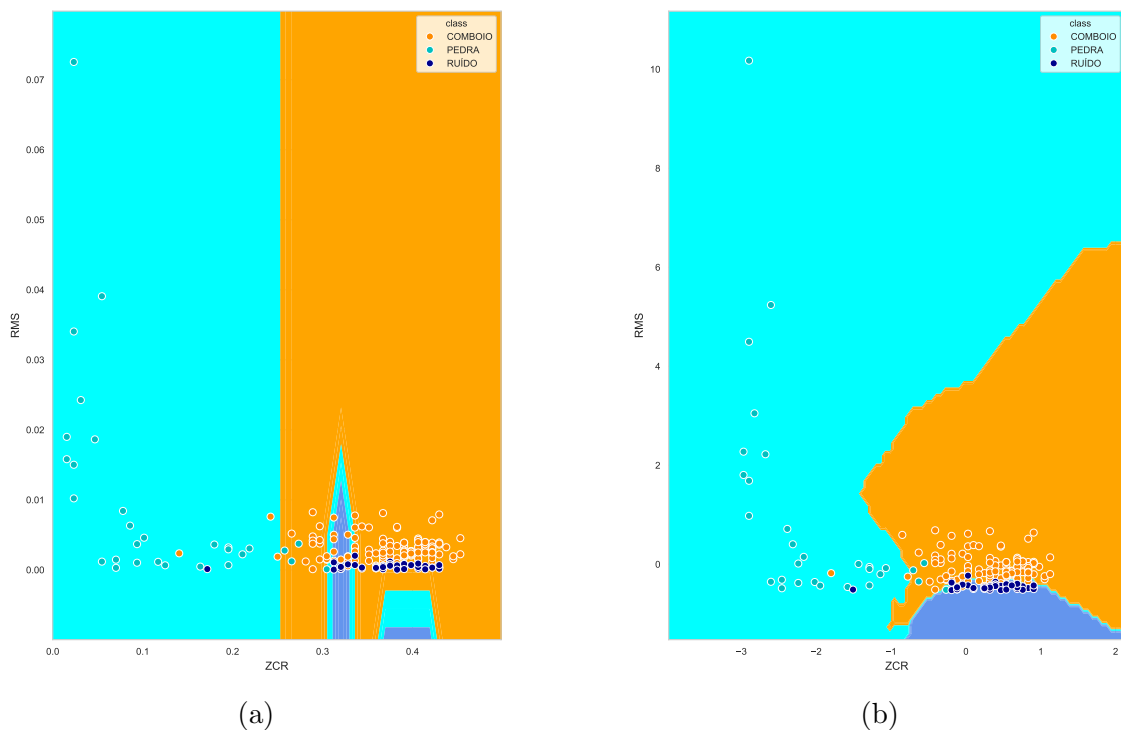


Figura 4.6: Duas características do conjunto de treino antes (a) e depois (b) de normalização.

A normalização de características utilizando a pontuação padrão, z -score ou *Standard Score*, permite comparar grandezas com diferentes unidades, centrando os dados

em torno de média igual a 0 e desvio-padrão igual a 1 e expressando a sua distribuição através da distância ao centro em unidades de desvio-padrão. Um exemplo do efeito da normalização de dados está presente nas figuras 4.5 e 4.6. Na equação 4.1, z representa o valor normalizado de uma variável X , após subtrair a média μ e dividir pelo desvio-padrão σ :

$$z = \frac{X - \mu}{\sigma} \quad (4.1)$$

Esta técnica tem limitações visto que a normalização de dados baseada no valor médio e desvio-padrão pode ser influenciada negativamente por valores extremos, *outliers*, que não retratam a normal variação dos dados, por exemplo, aumentando artificialmente o valor da média. Para o estudo realizado a influência destes valores é considerada desprezável.

4.4 Classificadores

4.4.1 k-vizinhos mais próximos

O algoritmo k-vizinhos mais próximos, *k-Nearest Neighbors (k-NN)*, é um método de aprendizagem automática não supervisionada [29] que determina a classe de um ponto, inicialmente desconhecida, com base na distância aos k pontos mais próximos entre as classes conhecidas, dada pela equação 4.2:

$$d_{(P,\omega)} = \sqrt{\sum_{i=1}^n (\omega_i - P)^2}, \quad (4.2)$$

onde as classes ω_i correspondem ao conjunto de pontos que definem cada uma das i classes conhecidas e P é o ponto a classificar. Ao obter os k pontos com a menor distância d , isto é, a sua vizinhança mais próxima, verifica-se qual a classe ω_i com maior ocorrência nesses k pontos, sendo o ponto P classificado como pertencendo a essa classe. A figura 4.7 mostra uma representação da aplicação do algoritmo.

Alguns fatores importantes a considerar no uso do classificador k-NN: quanto maior o número de pontos em cada classe, ω_i e quanto maior o número de características de cada classe, maior a complexidade computacional da classificação, o que o tornará dispendioso em termos de tempo e recursos computacionais.

O número de elementos de cada classe deverá ser o mais próximo possível entre si para evitar enviesamentos por votação de maioria, isto é, uma classe ser votada de forma favorável simplesmente porque existem mais pontos dessa classe. Uma possível solução, para além de aumentar o número de pontos é a criação de pontos sintéticos nas classes minoritárias, através de técnicas como Synthetic Minority




Figura 4.7: Exemplo do algoritmo k-NN, onde o losango é um ponto de classe desconhecido, a ser classificado entre as três classes existentes, triângulos, círculos e quadrados. Dentro de cada símbolo está a distância euclidiana do losango a cada ponto das classes.

Oversampling Technique (SMOTE).

A escolha do valor de k excessivamente grande pode tornar a classificação em tempo-real demorada ou até inviável; um valor de k pequeno pode tornar a classificação instável, tornando-a sensível ao ruído presente nos dados, fazendo com que a classificação fique oscilante se próximo de uma fronteira de decisão. Note-se que o *ruído* aqui descrito diz respeito a flutuações nos valores dos dados provenientes de diversas origens, desde erros de medição ou valores extremos (*outliers*) e não ao *ruído* medido na via-férrea, descrito no capítulo 2.

Outro fator importante é a dimensionalidade a considerar por classificação, isto é, quando parâmetros estão a ser considerados em cálculo de distância, sendo que o conceito de distância poder até deixar de ter significado quantitativo. Um número grande de dimensões torna os dados demasiado dispersos, prejudicando a classificação [30].

Existem também variantes deste algoritmo [31] que permitem atribuir pesos mais significativos a vizinhos mais próximos, minimizando a influência de valores extremos. Esta abordagem não será considerada para este estudo.

4.4.2 Centroide mais próximo

Este algoritmo [32, 33] partilha a mesma mecânica do k-NN, com a diferença que os dados correspondentes a cada sinal do conjunto de treino das classes são o centroide de cada *cluster*. O centroide, ou centro de massa, de cada classe é calculado através da média das características dos sinais do conjunto de treino correspondentes à classe ω_i . A classificação de um ponto P é realizada calculado a distância a n centroides, onde n é o número de sinais do conjunto de treino de todas as classes. A figura 4.8

mostra uma representação da aplicação do algoritmo.

Este algoritmo tem vantagens sobre o k-NN como a diminuição do número de cálculos a realizar por cada ponto analisado, mais independência sobre o número de amostras do conjunto de treino e uma reduzida sensibilidade do classificador a pontos isolados.

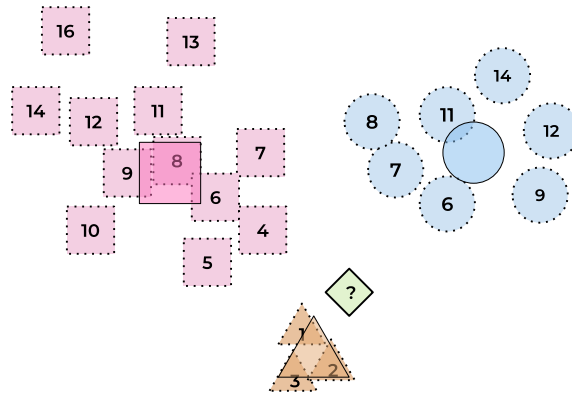


Figura 4.8: Exemplo do algoritmo centroide mais próximo, baseado nos pontos da figura 4.7. As figuras geométricas transparentes representam o centroide de cada classe.

4.5 Pós-processamento de resultados e classificação final do evento

A eficácia dos classificadores foi testada utilizando o conjunto de treino definido em 4.2 com o classificador a gerar uma classificação rígida, isto é, uma indicação direta do tipo de classe a que pertence. Esta classificação surge em oposição a um classificador suave, onde a sua saída seria a probabilidade de um conjunto de amostras do sinal pertencer às várias classes conhecidas.

Após a classificação individual dos conjuntos de amostras propõe-se agrupar os segmentos contíguos que sejam da mesma classe. Idealmente todos os segmentos de um sinal da classe *Comboio*, por exemplo, seriam classificados como pertencentes a essa classe, mas dependendo de fatores como dimensão da janela e o tipo de características consideradas, algumas janelas de amostras podem ser classificadas incorretamente.

Após a classificação de todos os segmentos é possível decidir qual será a classe provável do evento. Se se considerar apenas as classificações realizadas no intervalo de tempo em que foram detetadas vibrações acima do limiar do ruído, a classe do evento é a que tiver maior número de ocorrências dentro desse intervalo de tempo. O diagrama da figura 4.9 mostra o seu funcionamento.

As detecções feitas pelo classificador são discretas e independentes da ordem a que correspondem no sinal que lhes deu origem, isto é, uma classificação num momento não é afetada por classificações anteriores ou futuras, e não as afeta.

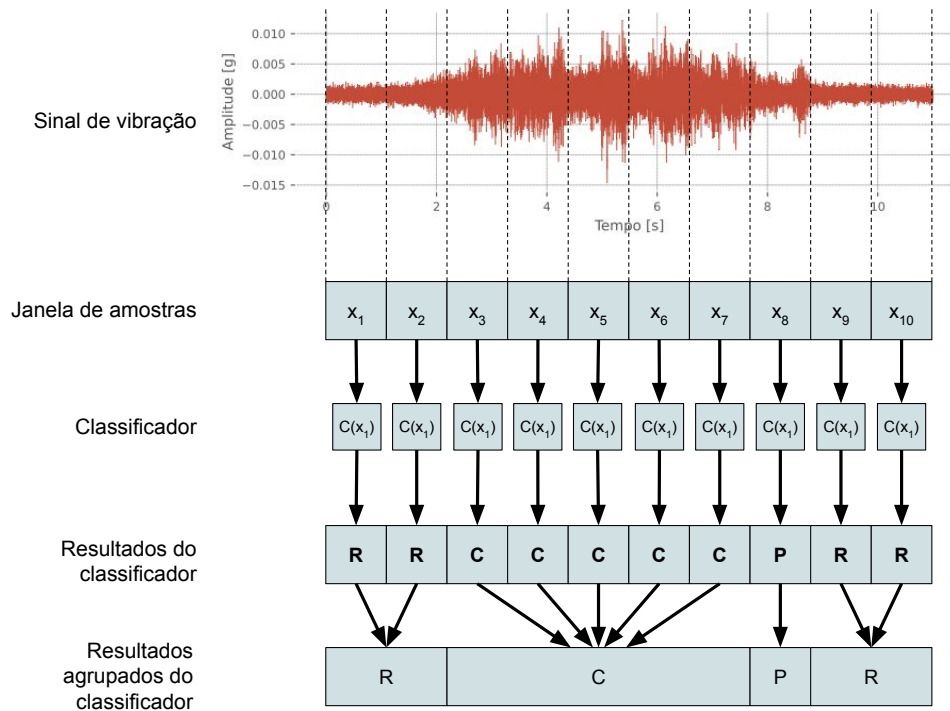


Figura 4.9: Esquema de pós-processamento do sinal de vibração: cada janela é classificada e os resultados dessas classificações são agrupados.

4.5.1 Regiões de decisão

Na figura 4.10 estão definidas as regiões de decisão para dois classificadores estudados. As regiões de decisão definem áreas nas quais todos os pontos contidos pertencem a uma determinada classe. No caso do classificador k-NN as regiões de decisão correspondentes às classes *Comboio* e *Ruído* aumentam em consonância com o aumento do valor de k e da dimensão da janela de amostras. Uma das causas deste aumento é o número de pontos de cada conjunto de treino ser diferente, sendo a classe *Comboio* com o maior número de pontos, sendo beneficiada quando o valor de k é aumentado.

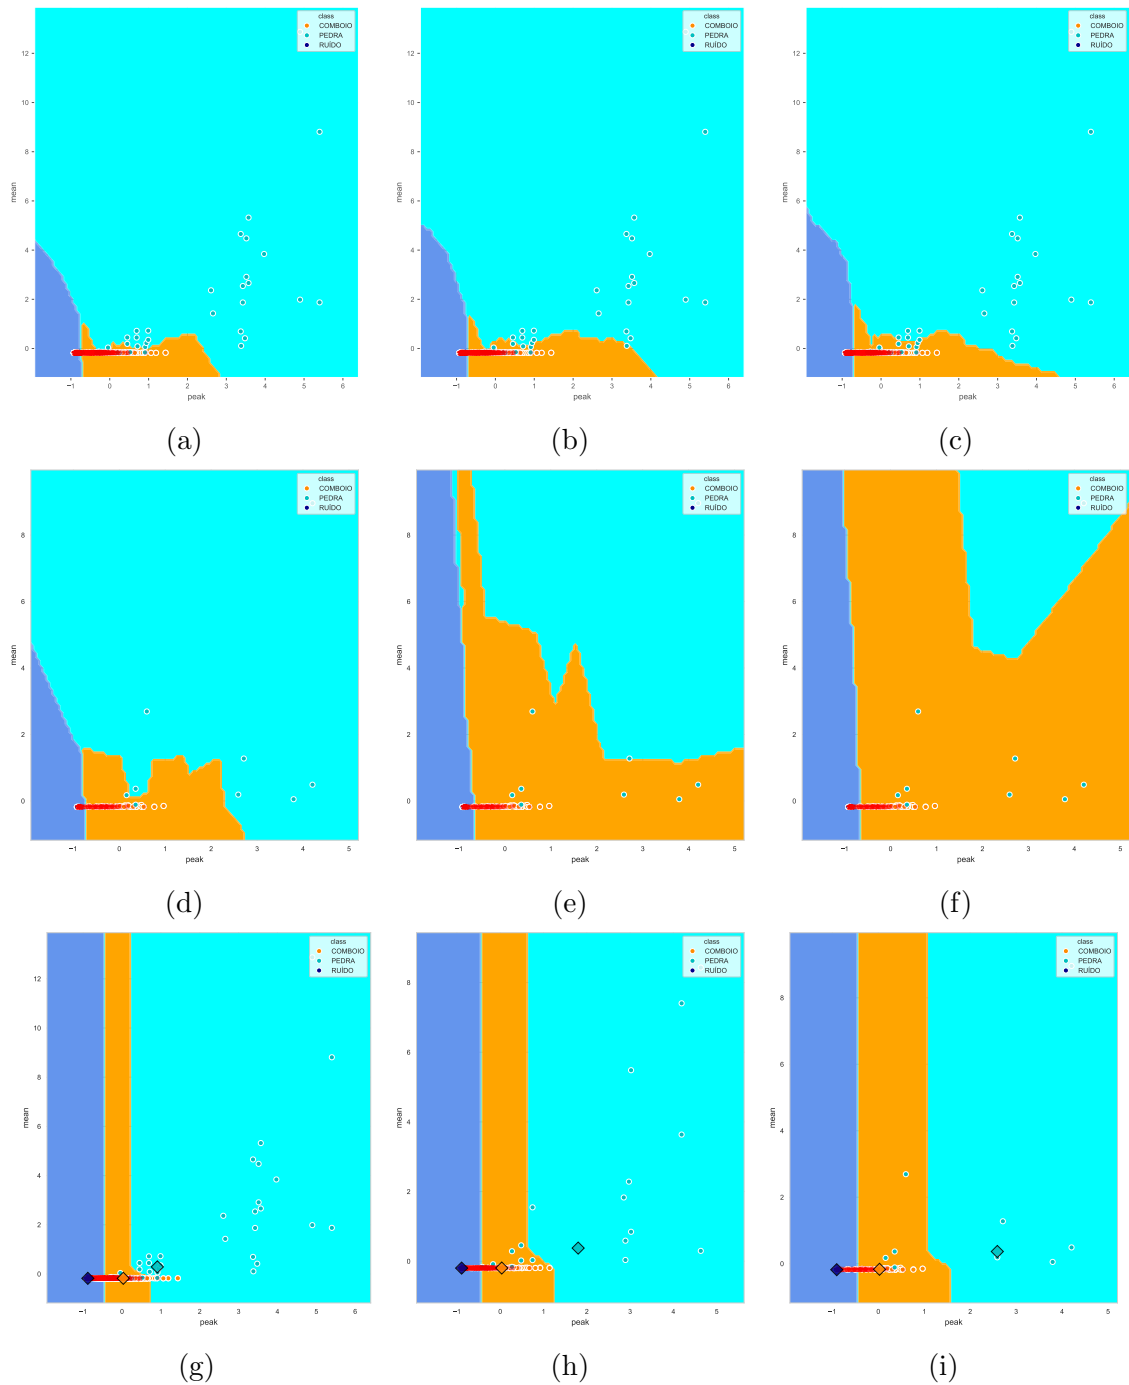


Figura 4.10: Regiões de decisão dos classificadores k -NN com $k = 5$ (a, d), $k = 11$ (b, e) e $k = 17$ (c, f) e Centroeide mais próximo (g, i) definidas pelo seu conjunto de treino. O valor da janela é de 64 amostras (a, b, c, g, h, i). A vermelho está o sinal de teste *comboio1*.

4.6 Métricas para classificadores binários e multiclasse

A avaliação do desempenho de um classificador realiza-se com métricas como a Exatidão, Precisão, Sensibilidade e a Métrica F1, o que permitirá escolher a configuração de parâmetros de um classificador que maximize a correta detecção de classes e que minimize os falsos negativos.

Estas métricas são calculadas com recurso aos valores de:

- Verdadeiros positivos
- Verdadeiros negativos
- Falsos positivos
- Falsos negativos

Um resultado é um **Verdadeiro Positivo**, VP , se um classificador atribui a classe A e o valor real é A . Por outro lado, um resultado é um **Verdadeiro Negativo**, VN , se um classificador atribui \bar{A} e o valor real é \bar{A} .

Um resultado é um **Falso Positivo**, FP , se um classificador atribui A e o valor real é \bar{A} . Por outro lado, um resultado é um **Falso Negativo**, FN , se um classificador atribui \bar{A} e o valor real é A .

Esta metodologia é aplicada a classificadores binários, isto é, classificadores com duas classes, mas podem também ser aplicadas a classificadores multiclasse, os utilizados neste estudo. Existem duas abordagens possíveis:

- *One vs One*, onde são agrupadas todas as combinações possíveis de duas classes, gerando $\frac{N(N-1)}{2}$ combinações para um total de N classes
- *One vs All*, onde as classes são divididas entre a classe A , pertencente ao conjunto de N classes e a classe \bar{A} , composta pelas $N - 1$ classes restantes.

4.6.1 Matriz de Confusão

A Matriz de Confusão expressa o número de ocorrências de cada classe do classificador, positivas e negativas, numa matriz quadrada com N igual ao número de classes, sendo este caso $N = 3$. Um exemplo de uma matriz de confusão está presente na tabela 4.1.

4.6.2 Exatidão

Exatidão é a taxa de classificações positivas e negativas corretas do classificador. Esta métrica indica uma tendência geral sobre o desempenho do classificador, sendo

Tabela 4.1: Matriz de confusão.

Real	Detetado		
	<i>Pedra</i>	<i>Comboio</i>	<i>Ruído</i>
<i>Pedra</i>	<i>Pedra quando Pedra</i>	<i>Pedra quando Comboio</i>	<i>Pedra quando Ruído</i>
<i>Comboio</i>	<i>Comboio quando Pedra</i>	<i>Comboio quando Comboio</i>	<i>Comboio quando Ruído</i>
<i>Ruído</i>	<i>Ruído quando Pedra</i>	<i>Ruído quando Comboio</i>	<i>Ruído quando Ruído</i>

que o seu valor ótimo é 1.

$$\text{Exactidão} = \frac{VP + VN}{VP + VN + FP + FN} \quad (4.3)$$

4.6.3 Precisão

Precisão é a taxa de classificações positivas corretas do classificador relativamente à existência de falsos positivos detetados pelo classificador, sendo que o seu valor ótimo é 1.

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (4.4)$$

4.6.4 Sensibilidade

A Sensibilidade é a taxa de classificações positivas corretas do classificado relativamente à existência de falsos negativos detetados pelo classificador, sendo que o seu valor ótimo é 1.

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (4.5)$$

4.6.5 Métrica F1

A Métrica F1 relaciona a Precisão e a Sensibilidade, permitindo avaliar em simultâneo o peso dos falsos positivos e falsos negativos, sendo que o seu valor ótimo é 1.

$$\text{Métrica F1} = 2 \times \frac{\text{Precisão} \times \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}} = \frac{2 \times VP}{2 \times VP + FP + FN} \quad (4.6)$$

5

RESULTADOS

5.1 Introdução

Neste capítulo são discutidos os ensaios do sistema de classificação automática com dados recolhidos em campo com o sensor. Pretende-se avaliar o desempenho do sistema de classificação estudado no capítulo 4 e assim validar a sua adequação ao objeto de estudo.

Comparando os algoritmos relativamente ao seu tempo de processamento o k-NN é o algoritmo com o maior tempo de cálculo, devido ao número de operações necessárias para realizar uma classificação, já que cada sinal do conjunto de treino gera um conjunto de pontos para cada classe entre as dezenas ou centenas, dependendo da dimensão da janela e da duração do sinal. Este fator não é considerado para a comparação entre classificadores realizada neste estudo.

Para a condução destes ensaios foi desenvolvida uma aplicação em Python, com recurso às bibliotecas de *Machine Learning* scikit-learn [34], tirando partido das suas implantações dos algoritmos de classificação k-NN e centroide mais próximo.

5.2 Ensaios com classificadores

5.2.1 K-vizinhos mais próximos

A aplicação do algoritmo k-NN ao caso de estudo desta tese considera que as três classes consideradas são separadas em regiões homogêneas, *clusters*, cujas coordenadas são dadas pelo valor normalizado de duas características de entre as cinco estudadas.

Escolheram-se para os testes valores de k de 3, 7 e 11 e valores de janela de 64, 128 e 256. Os parâmetros escolhidos são *peak*, *mean*, *zcr*, *rms* e *std* e serão consideradas combinações únicas de 2 a 2, totalizando 10 hipóteses diferentes de parâmetros. Cada conjunto de parâmetros é designado por *ponto*, visto ter apenas duas dimensões. A figura 4.10 do capítulo 4 mostra os *clusters* e correspondentes regiões de decisão. As tabelas seguintes contêm as matrizes de confusão correspondentes aos ensaios do classificador k-NN.

5.2.2 Centroide mais próximo

A aplicação do algoritmo centroide mais próximo é baseada nos mesmos *clusters* considerados para o algoritmo k-NN no entanto para cada um destes é calculado um centroide. A distância mais curta de cada conjunto de características a cada um destes centroides define a sua classificação dentro das três classes consideradas. As distâncias são medidas através de coordenadas que correspondem ao valor normalizado de duas características,

Escolheram-se para os testes valores de janela de 64, 128 e 256. Os parâmetros escolhidos são *peak*, *mean*, *zcr*, *rms* e *std* e serão consideradas combinações únicas de 2 a 2, totalizando 10 hipóteses diferentes de parâmetros. Cada conjunto de parâmetros é designado por *ponto* por ser um vetor de duas dimensões. A figura 4.10 do capítulo 4 mostra os *clusters* e correspondentes regiões de decisão.

5.2.3 Resultados

A análise aos resultados terá em conta o desempenho geral do classificador e a minimização de falsos negativos. Desta forma as métricas que serão consideradas mais relevantes são Precisão e Sensibilidade mais elevados.

k-Nearest Neighbors

O k-NN exibiu valores de acerto maiores para os testes realizados com as combinações de parâmetros:

- *peak* com *mean* ou com *std*
- *zcr* com *std*
- *rms* com *std*

Há uma tendência para um melhor desempenho com valores de janela e de k mais baixos. Isto poderá estar relacionado com a curta duração dos sinais da classe *Pedra* utilizados que deram origem a poucas janelas para classificação e também a uma pior discriminação aquando do uso de janelas superiores a 64 amostras. O classificador k-NN para valores de k maiores e com conjuntos de treino com dimensões disparens irá dar preferência na classificação dos sinais ao que apresentar um maior número de pontos.

Centroide mais próximo

O classificador por centroide mais próximo exibiu valores de acerto maiores para os testes realizados com as combinações de parâmetros:

- *peak* com *mean* ou com *std*
- *mean* com *std*
- *zcr* com *std*
- *rms* com *std*

Este classificador exibiu um desempenho semelhante ao k-NN, o que indica que em ambiente com capacidade computacional limitada, como o sensor utilizado na recolha de dados, este classificador pode ser suficiente.

Para todas as combinações de parâmetros o maior número de erros ocorre entre a classe *Ruído* e a classe *Comboio*. Não foi encontrada nenhuma combinação de características que permitisse diferenciar melhor estas duas classes.

5.2.4 Conclusões

Foram possíveis de obter, para ambos os classificadores em estudo, diferentes combinações possíveis para os parâmetros que maximizam o valor das métricas de interesse, Precisão e Sensibilidade, mostrando uma possibilidade de escolha de hiperparâmetros que minimize falsos positivos e negativos. O classificador k-NN mostrou um melhor desempenho face ao classificador centroide mais próximo, no entanto mesmo as configurações com piores prestações poderiam ser consideradas após pós-processamento.

Ao considerar o evento ferroviário a classificar apenas entre o segmento em que a amplitude média do sinal é maior do que o valor médio do ruído basta implantar um sistema de votação em que a classe com mais ocorrências será a classe do evento. Esta abordagem simplificada pode mascarar a existência de um evento da classe *Pedra* em simultâneo com um evento da classe *Comboio*.

5.3 Pós-processamento

Após os resultados da classificação das janelas é possível classificar o sinal contabilizando as ocorrências das três classes, sendo que a classe com maiores ocorrências será a que corresponde ao tipo de evento. A figura 5.1 é uma representação visual para melhor compreender o resultado da classificação das janelas de amostras. Mesmo com classificações da classe *Pedra* a meio do sinal da classe *Comboio* é possível concluir que se trata de um sinal dessa classe.

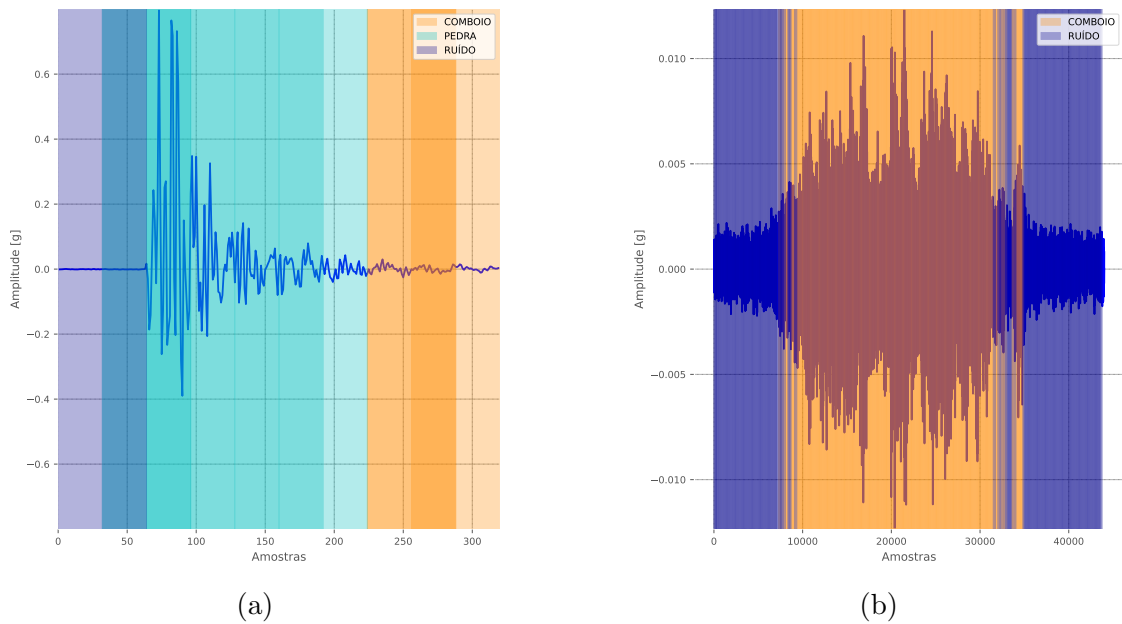


Figura 5.1: Exemplos do resultado da classificação com o classificador k-NN do sinal *pedra1* (a) e do sinal *comboio1* (b).

Para os exemplos considerados temos na tabela 5.1 dois sinais classificados de acordo

com a classe classificada em maior número. Quer o sinal *comboio1* quer o sinal *pedra1* são classificados correctamente, mesmo com uma escolha de características que poderá não ser a que permite obter melhores resultados de classificação. Um exemplo deste pós-processamento está presente na tabela 5.1.

Tabela 5.1: Número de janelas classificadas para o sinal *comboio1* e *pedra1*, com $k = 11$ e janela de 256 amostras e $k = 3$ e janela de 64 amostras, respetivamente. Os parâmetros classificados são *rms* e *std*.

Sinal	Detetado		
	<i>Comboio</i>	<i>Pedra</i>	<i>Ruído</i>
<i>comboio1</i>	199	0	143
<i>pedra1</i>	2	6	1

6

CONCLUSÕES E TRABALHO FUTURO

6.1 Introdução

Neste capítulo são introduzidas conclusões decorrentes do estudo realizado, bem como propostas para trabalho futuro.

6.2 Conclusões

As características dos sinais como a análise da potência do sinal considerando o valor médio, valor RMS, valor de pico, ZCR e desvio-padrão foram adequadas para a distinção de eventos no domínio do tempo.

A técnica escolhida para o estudo do sinal no domínio da frequência não se mostrou adequada para a distinção entre sinais. A análise dos espectros dos sinais realizou-se com o objetivo de detetar frequências ou bandas de frequência que permitissem a sua distinção entre classes, que não foi possível visto que a resposta em frequência dos sinais se sobrepunha em todo o espectro para diferentes tipos de eventos.

Os dois classificadores estudados no capítulo 4 mostraram ser escolhas adequadas para classificar os sinais em estudo. Foram realizadas simulações com sinais de teste para estudar o valor de hiperparâmetros e de dimensão da janela de análise que

maximizam a precisão do classificador. O classificador k-NN possui no geral um melhor desempenho com os diferentes tipos de sinais, desde que o valor de k seja igual ou inferior a 7 e para uma janela de 64 amostras.

Foi também demonstrado que é possível considerar classificadores com piores desempenhos considerando a etapa de pós-processamento.

Devido ao baixo número de sinais de queda de pedra adquiridos, as conclusões do capítulo 5 podem não ser aplicáveis a todo o tipo de sinais da classe *Pedra*. Ambos os classificadores testados permitiram classificações com precisão superior a 0,6, após o devido ajuste de k e do tamanho da janela, no entanto, o classificador k-NN mostrou uma maior precisão, com potencial contrapartida de um maior número de operações a realizar.

6.3 Trabalho futuro

6.3.1 Introdução

Como trabalho futuro propõe-se a realização de atividades que validem a solução encontrada para contextos mais alargados, quer através do alargamento dos conjuntos de treino das várias classes, quer pela pesquisa de outro tipo de classificadores com maior precisão e menor número de operações por classificação. Sugere-se também a aplicação da solução proposta em ambientes de natureza similar, onde a variável a ser estudada seja uma vibração ambiental gerada por diferentes agentes e medida no solo ou em estruturas rochosas. Dois exemplos seriam taludes rodoviários ou segurança de perímetros.

6.3.2 Sinais de vibração e classes

No que diz respeito aos sinais gerados por material circulante propõe-se uma recolha em diversos tipos de ambientes, incluindo taludes de diferentes materiais e a diferentes distâncias da via-férrea. O objetivo seria abranger material circulante variado, eventualmente abrindo espaço para uma maior segmentação da classe *Comboio* com espaço para diferentes subclasses de material circulante, por exemplo.

Para sinais gerados por queda de pedras a solução passaria por recolhas simuladas em encostas e taludes onde a recolha possa ser feita em segurança, sendo que idealmente as medições seriam realizadas em ferrovias em construção ou a sofrer obras de beneficiação. Seria de interesse alargar o âmbito do que seria detetado como uma queda de pedras, segmentando-o por dimensão dos blocos e distinguindo entre queda de pedras ou um aluimento de terras.

Por último, propõe-se o estudo do sinal no domínio do tempo através dos três eixos de aceleração medidos pelo acelerómetro. Este formato já é relevante para conhecer

o comportamento de deslocamentos de terra lentos, mas o seu uso para tempo-real ainda é desconhecido.

6.3.3 Características dos sinais e classificadores

O estudo de características no domínio da frequência poderá ser alargado, considerando técnicas espectrais como as descritas em [7, 27], envolvendo o centro de massa, pico de amplitude, espalhamento, entropia, entre outras. No domínio do tempo existem outras características que poderiam ser igualmente estudadas como a autocorrelação ou a entropia do sinal.

Na pesquisa para esta tese foram conhecidas outras aplicações para a extração de características, no entanto, considerou-se que o seu estudo estaria fora do âmbito deste projeto devido à sua complexidade. Como exemplos podem ser citadas as transformadas *wavelet* ou de Fourier de termo curto, STFT, que permitem analisar em simultâneo as suas características temporais e de frequência ou a transformada de Hilbert.

Uma das possíveis características do sinal a ser considerada seria a sua duração total, isto é, o período de tempo em que a amplitude da aceleração é superior ao o nível máximo de ruído. Tendo em conta que, por exemplo, a passagem de material circulante tem a duração de dezenas de segundos e que uma queda de pedras tem uma duração entre décimas de segundo e alguns segundos, esta característica pode oferecer uma visão global do tipo de evento em questão.

No que diz respeito a classificadores propõe-se um estudo mais alargado, com vista a minimizar o número de operações necessárias para uma classificação válida, sendo de interesse evitar os baseados em distância entre pontos. Este estudo pode incidir sobre classificadores do tipo árvore de decisão [35], cujo peso computacional relevante ocorre para cálculo da árvore de decisão durante o período de treino do algoritmo.

Por último, propõe-se o estudo de eventos ferroviários em simultâneo, isto é, considerando que uma queda de pedras pode ocorrer em simultâneo com a passagem de material circulante. Possíveis soluções seriam o estudo de sinais medidos ou sintéticos compostos por somas de ambas as classes de interesse e também o alargamento do estudo a novas categorias de parâmetros, nomeadamente através de técnicas espectrais.

Bibliografia

- [1] IMTT. *Relatório Anual de Segurança Ferroviária*. Rel. téc. Instituto da Mobilidade e dos Transportes, I.P, 2020. URL: <https://www.imt-ip.pt/sites/IMTT/Portugues/IMTT/relatoriosectoriais/Documents/RASF%202020%20v1.1%20Final.pdf>.
- [2] UIC. *RAILWAY INDUCED VIBRATION - State of the art report*. Rel. téc. International Union of Railways (UIC), 2017. URL: <https://uic.org/IMG/pdf/uic-railway-induced-vibration-report-2017.pdf>.
- [3] D.P. Connolly et al. “Benchmarking railway vibrations – Track, vehicle, ground and building effects”. Em: *Construction and Building Materials* 92 (2015). Railway Engineering-2013, pp. 64–81. ISSN: 0950-0618. DOI: <https://doi.org/10.1016/j.conbuildmat.2014.07.042>. URL: <https://www.sciencedirect.com/science/article/pii/S0950061814007661>.
- [4] Slimane Ouakka, Olivier Verlinden e Georges Kouroussis. “Railway ground vibration and mitigation measures: benchmarking of best practices”. Em: *Railway Engineering Science* 30.1 (mar. de 2022), pp. 1–22. ISSN: 2662-4753. DOI: [10.1007/s40534-021-00264-9](https://doi.org/10.1007/s40534-021-00264-9). URL: <https://doi.org/10.1007/s40534-021-00264-9>.
- [5] Jerzy Kisilowski e Rafał Kowalik. “Mechanical Wear Contact between the Wheel and Rail on a Turnout with Variable Stiffness”. Em: *Energies* 14.22 (2021). ISSN: 1996-1073. DOI: [10.3390/en14227520](https://doi.org/10.3390/en14227520). URL: <https://www.mdpi.com/1996-1073/14/22/7520>.
- [6] Jyoti Kumar Barman e Durlav Hazarika. “Condition Monitoring of NFR Trains With Measurements From a Single Wayside 3D Vibration Sensor”. Em: *IEEE Sensors Journal* 20.8 (2020), pp. 4096–4103. DOI: [10.1109/JSEN.2019.2961942](https://doi.org/10.1109/JSEN.2019.2961942).
- [7] Theodoros Giannakopoulos e Aggelos Pikrakis. “Chapter 4 - Audio Features”. Em: *Introduction to Audio Analysis*. Ed. por Theodoros Giannakopoulos e Aggelos Pikrakis. Oxford: Academic Press, 2014, pp. 59–103. ISBN: 978-0-08-099388-1. DOI: <https://doi.org/10.1016/B978-0-08-099388-1.00004-2>. URL: <https://www.sciencedirect.com/science/article/pii/B9780080993881000042>.

- [8] Ghee Leng Ooi et al. “Near real-time landslide monitoring with the smart soil particles”. Em: *Japanese Geotechnical Society Special Publication* 2.28 (2016), pp. 1031–1034. DOI: [10.3208/jgssp.HKG-05](https://doi.org/10.3208/jgssp.HKG-05).
- [9] Nicola Casagli et al. “Landslide detection, monitoring and prediction with remote-sensing techniques”. Em: 4 (jan. de 2023), pp. 51–64. DOI: [10.1038/s43017-022-00373-x](https://doi.org/10.1038/s43017-022-00373-x).
- [10] Ioannis Farmakis et al. “Rockfall detection using LiDAR and deep learning”. Em: *Engineering Geology* 309 (2022), p. 106836. ISSN: 0013-7952. DOI: <https://doi.org/10.1016/j.enggeo.2022.106836>. URL: <https://www.sciencedirect.com/science/article/pii/S0013795222003210>.
- [11] Jin Qian et al. “Improving Railway Alignment Selection in Mountainous Areas with Complex Vegetation: A Multisource Data Landslide Identification Approach for Assisted Decision-Making Research”. Em: *Sustainability* 15.14 (2023). ISSN: 2071-1050. DOI: [10.3390/su151411388](https://doi.org/10.3390/su151411388). URL: <https://www.mdpi.com/2071-1050/15/14/11388>.
- [12] Hong-Hu Zhu et al. “Distributed Acoustic Sensing for Monitoring Linear Infrastructures: Current Status and Trends”. Em: *Sensors* 22.19 (2022). ISSN: 1424-8220. DOI: [10.3390/s22197550](https://doi.org/10.3390/s22197550). URL: <https://www.mdpi.com/1424-8220/22/19/7550>.
- [13] Michel Jaboyedoff et al. “Use of LIDAR in landslide investigations: a review”. Em: *Natural Hazards* 61.1 (mar. de 2012), pp. 5–28. ISSN: 1573-0840. DOI: [10.1007/s11069-010-9634-2](https://doi.org/10.1007/s11069-010-9634-2). URL: <https://doi.org/10.1007/s11069-010-9634-2>.
- [14] Gang Qiao et al. “Landslide Investigation with Remote Sensing and Sensor Network: From Susceptibility Mapping and Scaled-down Simulation towards in situ Sensor Network Design”. Em: *Remote Sensing* 5.9 (2013), pp. 4319–4346. ISSN: 2072-4292. DOI: [10.3390/rs5094319](https://doi.org/10.3390/rs5094319). URL: <https://www.mdpi.com/2072-4292/5/9/4319>.
- [15] Jan Burjánek et al. “Ambient vibration characterization and monitoring of a rock slope close to collapse”. Em: *Geophysical Journal International* 212.1 (out. de 2017), pp. 297–310. ISSN: 0956-540X. DOI: [10.1093/gji/ggx424](https://doi.org/10.1093/gji/ggx424). eprint: <https://academic.oup.com/gji/article-pdf/212/1/297/21887583/ggx424.pdf>. URL: <https://doi.org/10.1093/gji/ggx424>.
- [16] Jinmin Zhang et al. “Landslide Detection in the Linzhi–Ya’an Section along the Sichuan–Tibet Railway Based on InSAR and Hot Spot Analysis Methods”. Em: *Remote Sensing* 13.18 (2021). ISSN: 2072-4292. DOI: [10.3390/rs13183566](https://doi.org/10.3390/rs13183566). URL: <https://www.mdpi.com/2072-4292/13/18/3566>.
- [17] Yan Yan et al. “Monitoring and early warning method for a rockfall along railways based on vibration signal characteristics”. Em: *Scientific Reports* 9.1

- (abr. de 2019), p. 6606. ISSN: 2045-2322. DOI: [10.1038/s41598-019-43146-1](https://doi.org/10.1038/s41598-019-43146-1). URL: <https://doi.org/10.1038/s41598-019-43146-1>.
- [18] Michael Brauner et al. “Distributed acoustic monitoring to secure transport infrastructure against natural hazards - requirements and new developments”. Em: *13th Congress INTERPRAEVENT 2016 - Conference Proceedings*. INTERPRAEVENT. 2016, pp. 231, 238. URL: <https://interprevent2016.ch/>.
- [19] Tianwen Xiao, Yongneng Xu e Huimin Yu. “Research on Obstacle Detection Method of Urban Rail Transit Based on Multisensor Technology”. Em: *Journal of Artificial Intelligence and Technology* 1 (jan. de 2021). DOI: [10.37965/jait.2020.0027](https://doi.org/10.37965/jait.2020.0027).
- [20] *SMART2 Advanced integrated obstacle and track intrusion detection system for smart automation of rail transport*. <https://smart2rail-project.net/>. Acedido a 2023-10-17.
- [21] *Low Noise, Low Drift, Low Power, 3-Axis MEMS Accelerometers*. ADXL355. Rev. A. Analog Devices. 2018. URL: https://www.analog.com/media/en/technical-documentation/data-sheets/adxl354_adxl355.pdf.
- [22] ET Concept. *Vibration Sensor - Developer's Guide*. Version 1. 2023.
- [23] *ESP32 Series Datasheet*. ESP32. Version 4.4. Espressif Systems. 2023. URL: https://www.espressif.com/sites/default/files/documentation/esp32_datasheet_en.pdf.
- [24] Ireneusz Celiński et al. “Research on the Applicability of Vibration Signals for Real-Time Train and Track Condition Monitoring”. Em: *Sensors* 22.6 (2022). ISSN: 1424-8220. DOI: [10.3390/s22062368](https://doi.org/10.3390/s22062368). URL: <https://www.mdpi.com/1424-8220/22/6/2368>.
- [25] *Accelerometer Specifications - Quick Definitions*. <https://www.analog.com/en/products/landing-pages/001/accelerometer-specifications-definitions.html>. Acedido a 2023-11-03.
- [26] Romain Serizel et al. “Acoustic Features for Environmental Sound Analysis”. Em: *Computational Analysis of Sound Scenes and Events*. Ed. por Tuomas Virtanen, Mark D. Plumbley e Dan Ellis. Springer International Publishing AG, 2017, pp. 71–101. DOI: [10.1007/978-3-319-63450-0_4](https://doi.org/10.1007/978-3-319-63450-0_4). URL: <https://hal.science/hal-01575619>.
- [27] Eleni Tsalera, Andreas Papadakis e Maria Samarakou. “Monitoring, profiling and classification of urban environmental noise using sound characteristics and the KNN algorithm”. Em: *Energy Reports* 6 (nov. de 2020), pp. 223–230. DOI: [10.1016/j.egy.2020.08.045](https://doi.org/10.1016/j.egy.2020.08.045).
- [28] Julien Lepine e Vincent Rouillard. “Evaluation of Shock Detection Algorithm for Road Vehicle Vibration Analysis”. Em: *Vibration* 1.2 (2018), pp. 220–238.

- ISSN: 2571-631X. DOI: [10.3390/vibration1020016](https://doi.org/10.3390/vibration1020016). URL: <https://www.mdpi.com/2571-631X/1/2/16>.
- [29] T. Cover e P. Hart. “Nearest neighbor pattern classification”. Em: *IEEE Transactions on Information Theory* 13.1 (1967), pp. 21–27. DOI: [10.1109/TIT.1967.1053964](https://doi.org/10.1109/TIT.1967.1053964).
- [30] Charu C. Aggarwal, Alexander Hinneburg e Daniel A. Keim. “On the Surprising Behavior of Distance Metrics in High Dimensional Space”. Em: *Database Theory — ICDT 2001*. Ed. por Jan Van den Bussche e Victor Vianu. Berlin, Heidelberg: Springer Berlin Heidelberg, 2001, pp. 420–434. ISBN: 978-3-540-44503-6.
- [31] Sahibsingh A. Dudani. “The Distance-Weighted k-Nearest-Neighbor Rule”. Em: *IEEE Transactions on Systems, Man, and Cybernetics* SMC-6.4 (1976), pp. 325–327. DOI: [10.1109/TSMC.1976.5408784](https://doi.org/10.1109/TSMC.1976.5408784).
- [32] Manoj Thulasidas. “Nearest Centroid: A Bridge between Statistics and Machine Learning”. Em: *2020 IEEE International Conference on Teaching, Assessment, and Learning for Engineering (TALE)*. 2020, pp. 9–16. DOI: [10.1109/TALE48869.2020.9368396](https://doi.org/10.1109/TALE48869.2020.9368396).
- [33] B.B. Chaudhuri. “A new definition of neighborhood of a point in multi-dimensional space”. Em: *Pattern Recognition Letters* 17.1 (1996), pp. 11–17. ISSN: 0167-8655. DOI: [https://doi.org/10.1016/0167-8655\(95\)00093-3](https://doi.org/10.1016/0167-8655(95)00093-3). URL: <https://www.sciencedirect.com/science/article/pii/0167865595000933>.
- [34] F. Pedregosa et al. “Scikit-learn: Machine Learning in Python”. Em: *Journal of Machine Learning Research* 12 (2011), pp. 2825–2830.
- [35] Martin Krzywinski e Naomi Altman. “Classification and regression trees”. Em: *Nature Methods* 14.8 (ago. de 2017), pp. 757–758. ISSN: 1548-7105. DOI: [10.1038/nmeth.4370](https://doi.org/10.1038/nmeth.4370). URL: <https://doi.org/10.1038/nmeth.4370>.