

**UNIVERSIDADE FEDERAL DE SÃO CARLOS - UFSCar
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA - CCET
DEPARTAMENTO DE ENGENHARIA MECÂNICA - DEMec**

MURILO AUGUSTO MATTIOLI

**COLETA E ANÁLISE DE DADOS PROVENIENTES DE
ACELERÔMETROS DE *SMARTPHONE* DURANTE O
TRAJETO DE UM VEÍCULO VISANDO DETECÇÃO DE
DESCONTINUIDADES EM VIAS URBANAS**



São Carlos - SP
2025

MURILO AUGUSTO MATTIOLI

**COLETA E ANÁLISE DE DADOS PROVENIENTES DE
ACELERÔMETROS DE *SMARTPHONE* DURANTE O
TRAJETO DE UM VEÍCULO VISANDO DETECÇÃO DE
DESCONTINUIDADES EM VIAS URBANAS**

Trabalho de conclusão de curso
apresentado ao curso de graduação em
Engenharia Mecânica da Universidade
Federal de São Carlos, para obtenção do
título de bacharel em Engenharia
Mecânica.

Orientador: Prof. Dr. Sidney Bruce Shiki

São Carlos - SP

2025



FUNDAÇÃO UNIVERSIDADE FEDERAL DE SÃO CARLOS

COORDENAÇÃO DO CURSO DE ENGENHARIA MECÂNICA - CCEMec/CCET

Rod. Washington Luís km 235 - SP-310, s/n - Bairro Monjolinho, São Carlos/SP, CEP 13565-905

Telefone: (16) 33519703 - <http://www.ufscar.br>

DP-TCC-FA nº 31/2025/CCEMec/CCET

Graduação: Defesa Pública de Trabalho de Conclusão de Curso

Folha Aprovação (GDP-TCC-FA)

FOLHA DE APROVAÇÃO

MURILO AUGUSTO MATTIOLI

COLETA E ANÁLISE DE DADOS PROVENIENTES DE ACELERÔMETROS DE SMARTPHONE DURANTE O TRAJETO DE UM VEÍCULO VISANDO DETECÇÃO DE DESCONTINUIDADES EM VIAS URBANAS

Trabalho de Conclusão de Curso

Universidade Federal de São Carlos – Campus São Carlos

São Carlos, 25 de julho de 2025

ASSINATURAS E CIÊNCIAS

Cargo/Função	Nome Completo
Orientador	Sidney Bruce Shiki
Membro da Banca 1	Alexandre Tácito Malavolta
Membro da Banca 2	Benício Nacif Ávila



Documento assinado eletronicamente por **Sidney Bruce Shiki, Docente**, em 25/07/2025, às 17:15, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Alexandre Tácito Malavolta, Docente**, em 25/07/2025, às 17:15, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufscar.br/autenticacao>, informando o código verificador **1926602** e o código CRC **8B41B30D**.

Referência: Caso responda a este documento, indicar expressamente o Processo nº 23112.023425/2025-91

SEI nº 1926602

Modelo de Documento: Grad: Defesa TCC: Folha Aprovação, versão de 02/Agosto/2019



Documento assinado digitalmente

BENICIO NACIF AVILA

Data: 25/07/2025 17:33:59-0300

Verifique em <https://validar.iti.gov.br>

Dedico este trabalho aos meus pais e irmãos que me deram suporte em todos os momentos desta jornada.

Agradecimentos

Agradeço, primeiramente à minha mãe, Silvana, meu pai, Maurício e aos meus irmãos, Micheli e Matheus, por todo amor, carinho e sacrifício, apoio constante e por sempre acreditarem em mim, mesmo nos momentos de maior dificuldade.

Aos meus professores que fizeram parte da minha formação, contribuindo com conhecimento e inspiração ao longo desta jornada.

Em especial, agradeço ao professor Dr. Sidney Bruce Shiki, meu orientador, por toda a atenção, paciência e pelas oportunidades oferecidas para a elaboração deste trabalho. Também deixo meus agradecimentos especiais aos professores Dr. Armando Ítalo Sette Antonialli e Dr. Luis Antonio Oliveira Araujo, que foram fundamentais na reta final do curso, oferecendo suporte e incentivo nos momentos mais desafiadores.

Aos colegas de curso que compartilharam comigo conhecimentos, comemorações e frustrações, nos fortalecendo conforme as etapas de dificuldades eram superadas.

A todos vocês, meu muito obrigado.

Resumo

O transporte é fundamental para o funcionamento da sociedade, seja para o deslocamento individual e coletivo pelas vias urbanas ou para o fluxo de mercadorias que alimentam indústria e comércio de diversos tipos. A qualidade das vias de circulação interfere, por exemplo, na conservação dos veículos, no fluxo de tráfego e na experiência do condutor ao transitar. O monitoramento do estado de conservação das vias se torna uma ferramenta útil para a manutenção destas. Visando contribuir com a manutenção das vias abertas à circulação, o presente trabalho propõe o uso de acelerômetros de *smartphones* para detectar anomalias presentes no pavimento. Para isso, uma coleta de dados foi realizada em trechos definidos em vias locais na cidade de Monte Alto – SP. Com base nesses dados, análises foram realizadas com o intuito de identificar irregularidades. O objetivo do presente trabalho foi detectar e classificar discontinuidades presentes em pavimentos urbanos – como lombadas, faixas elevadas, tachões e buracos – a partir do desenvolvimento de classificadores utilizando métricas no domínio do tempo. O método de aquisição de dados e a abordagem matemática utilizada no projeto se mostraram promissoras no sentido de possibilitar a identificação de obstáculos presentes no pavimento, apresentando resultados com F1-score de até 98,7% na detecção de buracos.

Palavras-chave: Detecção de Irregularidades, Vibrações Mecânicas, Classificadores, Dispositivos Móveis.

Abstract

Transportation plays a crucial role in the functioning of society, both for individual and collective mobility in urban areas and for the flow of goods that sustain various industrial and commercial sectors. The quality of roadways directly affects vehicle preservation, traffic flow, and driver experience. In this context, monitoring pavement conditions becomes a valuable tool for road maintenance. This study proposes the use of smartphone accelerometers to detect pavement anomalies as a means to support the upkeep of road infrastructure. Data collection was conducted on selected road segments in the city of Monte Alto – SP, and subsequent analyses were carried out to identify surface irregularities. The objective was to detect and classify discontinuities present in urban pavement – such as speed bumps, raised crosswalks, road studs, and potholes – through the development of classifiers using time-domain metrics. The data acquisition process and the mathematical methodology employed proved effective, yielding promising results with an F1-score of up to 98.7% in pothole detection.

Keywords: Road Anomaly Detection, Mechanical Vibrations, Classifiers, Mobile Devices.

Lista de Figuras

Figura 1 – Parâmetros calibrados para o experimento de Manzi (2019)	4
Figura 2 – Métricas Z-THRESH, Z-DIFF, STDEV(Z) e G-ZERO	6
Figura 3 – Modelo de quarto de carro	11
Figura 4 – Modelo de meio carro	12
Figura 5 – Resposta à entrada tipo buraco	13
Figura 6 – Representação dos componentes de um acelerômetro MEMS	15
Figura 7 – Orientação dos eixos de um <i>smartphone</i>	16
Figura 8 – Efeito da filtragem em frequência – passa-baixa	17
Figura 9 – Localização do percurso trafegado	21
Figura 10 – Eventos presentes no percurso trafegado	21
Figura 11 – Buracos selecionados para o trabalho e suas localizações	23
Figura 12 – Fixação do <i>smartphone</i>	25
Figura 13 – Capturas de tela do <i>Phyphox</i>	25
Figura 14 – Gráfico da aceleração no eixo z da volta 20 da Toro	28
Figura 15 – Gráfico da aceleração no eixo z da sequência 4 do buraco 3 do Onix	28
Figura 16 – Gráfico da aceleração no eixo z da lombada 1 à velocidade de entrada de 15 km/h na volta 14 do Onix – 125 Hz	29
Figura 17 – Início e fim de um evento calculado via MATLAB comparando os níveis RMS	31
Figura 18 – Indicação das métricas utilizadas	32
Figura 19 – Circuito que contém faixas elevadas, lombadas e tachões	34
Figura 20 – Sequência de extração de dados para um buraco	35
Figura 21 – Semelhanças e diferenças entre curvas	36
Figura 22 – Comparação entre gráficos originais e filtrados	38
Figura 23 – Distribuição do nível RMS em função da velocidade para buracos	40
Figura 24 – Dispersão espalhada: vale global de tachões e inclinação de buracos	42
Figura 25 – Comparação entre as métricas antes e após a normalização	43
Figura A.1 – Gráficos da aceleração em z dos obstáculos percorridos	52
Figura A.2 – Distribuição do nível RMS em função da velocidade para buracos	55
Figura A.3 – Distribuição do nível RMS em função da velocidade para faixas	56

elevadas

Figura A.4 – Distribuição do nível RMS em função da velocidade para lombadas 57

Figura A.5 – Distribuição do nível RMS em função da velocidade para tachões 58

Figura A.6 – Distribuição do pico global em função da velocidade para buracos 59

Figura A.7 – Distribuição do pico global em função da velocidade para faixas 61

elevadas

Figura A.8 – Distribuição do pico global em função da velocidade para lombadas 62

Figura A.9 – Distribuição do pico global em função da velocidade para tachões 63

Figura A.10 – Distribuição do vale global em função da velocidade para buracos 64

Figura A.11 – Distribuição do vale global em função da velocidade para faixas 65

elevadas

Figura A.12 – Distribuição do vale global em função da velocidade para lombadas 66

Figura A.13 – Distribuição do vale global em função da velocidade para tachões 68

Figura A.14 – Distribuição da inclinação em função da velocidade para buracos 69

Figura A.15 – Distribuição da inclinação em função da velocidade para faixas 70

elevadas

Figura A.16 – Distribuição da inclinação em função da velocidade para lombadas 71

Figura A.17 – Distribuição da inclinação em função da velocidade para tachões 72

Lista de Tabelas

Tabela 1 - Classificação do estado geral por região da federação segundo ano de 2022	1
Tabela 2 – Lista de veículos utilizados no trabalho	20
Tabela 3 – Quantidade de dados coletados Onix	26
Tabela 4 – Quantidade de dados coletados Toro	27
Tabela 5 – Total de dados coletados	27
Tabela 6 – Fator de ampliação do RMS para detectar o início do evento	30
Tabela 7 – Matriz de confusão para classificador multiclasse	33
Tabela 8 – Limiões estatísticos dos <i>Boxplots</i> - método <i>IQR</i>	44
Tabela 9 – Matriz de confusão do classificador desenvolvido com a distância euclidiana mínima com relação às médias das métricas	45
Tabela 10 – Matriz de confusão do classificador desenvolvido com a distância euclidiana mínima com relação às medianas das métricas	45

Lista de Siglas

B1	Buraco 1
B2	Buraco 2
B3	Buraco 3
CNT	Confederação Nacional do Transporte
CTB	Código de Trânsito Brasileiro
DNIT	Departamento Nacional de Infraestrutura de Transportes
FE1	Faixa Elevada 1
FE2	Faixa Elevada 2
FN	Falso Negativo
FP	Falso Positivo
GPS	Global Positioning System
IRI	International Roughness Index
IQR	Interquartile Range (Intervalo Interquartil)
L1	Lombada 1
L2	Lombada 2
L3	Lombada 3
MDC	Mínima Distância do Centróide
MEMS	Micro-Electro-Mechanical Systems
RMS	Root Mean Square (Valor eficaz)
SIG	Sistemas de Informações Geográficas
T1	Tachão 1
T2	Tachão 2
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

Lista de Símbolos

M	Massa do veículo
J	Momento de inércia do veículo
K_1	Rigidez da mola da roda dianteira
K_2	Rigidez da mola da roda traseira
B_1	Fator de amortecimento da roda dianteira
B_2	Fator de amortecimento da roda traseira
m_1	Massa da roda dianteira
m_2	Massa da roda traseira
K_{p1}	Rigidez do pneu dianteiro
K_{p2}	Rigidez do pneu traseiro
d_h	Distância horizontal entre o CG e o ponto do acelerômetro
d_v	Distância vertical entre o CG e o ponto do acelerômetro
k	Coefficiente elástico
γ	Coefficiente de amortecimento

Sumário

1. Introdução	1
1.1. Contextualização	1
1.2. Objetivos	3
2. Revisão bibliográfica	4
3. Fundamentação teórica	10
3.1. Condições das vias abertas à circulação no Brasil.....	10
3.2. Veículos como um sistema massa-mola-amortecedor	11
3.3. Vibrações mecânicas.....	13
3.4. Acelerômetros e <i>smartphones</i>	15
3.5. Filtragem de sinais	16
3.6. Classificador multiclasse baseado na mínima distância ao centróide (MDC)..	18
3.7. Métricas para avaliação de classificadores	18
4. Metodologia.....	20
4.1. Aquisição de dados	20
4.2. Gerenciamento dos dados	27
4.3. Definição de início e fim do evento	29
4.4. Métricas.....	31
4.5. Classificadores multiclasse	32
4.6. Avaliação dos classificadores	33
5. Resultados e discussão.....	34
5.1. Análise dos sinais.....	34
5.2. Filtragem do sinal	37

5.3. Aplicação das métricas aos dados do estudo	40
5.4. Indicadores de desempenho dos classificadores	44
6. Considerações finais	47
Referências.....	49
Apêndice A – Gráficos complementares à análise e discussão dos resultados.....	52

1. Introdução

1.1. Contextualização

No Brasil, o deslocamento da população e o transporte de cargas ocorrem, principalmente, nas vias abertas à circulação e seu estado de conservação afeta diretamente a rotina dos brasileiros. Vias bem conservadas implicam maior segurança e conforto, aumento da vida dos componentes mecânicos do veículo, melhor experiência para o condutor e passageiros e melhora no fluxo do trânsito. Para garantir boas condições de tráfego é preciso detectar e intervir em irregularidades na malha viária.

O Código de Trânsito Brasileiro (CTB), em seu artigo 60, classifica as vias abertas à circulação em vias urbanas e vias rurais. As vias urbanas são classificadas como via de trânsito rápido, via arterial, via coletora e via local, enquanto as vias rurais são classificadas como estrada e rodovia.

Segundo a Confederação Nacional do Transporte (CNT), em seu anuário do transporte de 2022, a extensão total da malha rodoviária brasileira era de 1.720.909 km em 2021, sendo dessa malha apenas 12,4% pavimentadas. Outro dado da pesquisa indica que 66% das rodovias avaliadas, em 2022, apresentam algum tipo de problema no estado geral. A CNT classificou o estado geral das rodovias por região para o ano de 2022 em ótimo, bom, regular, ruim e péssimo. Os dados obtidos são apresentados na Tabela 1.

Tabela 1 - Classificação do estado geral por região da federação segundo ano de 2022

Região da Federação	Extensão Total (%)					Total
	2022					
	Ótimo	Bom	Regular	Ruim	Péssimo	
Brasil	8,5	25,5	40,7	18,8	6,5	100,0
Norte	2,4	18,4	37,0	27,1	15,1	100,0
Nordeste	3,3	25,4	41,7	20,0	9,5	100,0
Sudeste	17,5	26,8	33,9	17,5	4,4	100,0
Sul	9,0	25,7	46,5	16,1	2,6	100,0
Centro-Oeste	6,2	28,8	47,3	15,2	2,5	100,0

Fonte: Adaptado de Anuário CNT do Transporte 2022

Manzi (2019), em seu estudo de detecção de irregularidades em vias urbanas a partir de dados de um único eixo de um acelerômetro de *smartphone*, compara a importância da

infraestrutura viária para a sociedade com a importância dos vasos sanguíneos para os seres humanos. Segundo Valletta (2023), o monitoramento ativo das condições de pavimentação em todas as localidades da malha viária brasileira é inviável dada a extensão da malha rodoviária e somente as vias de maior tráfego e maior urbanização recebem a devida atenção e manutenção. Nesse contexto, o presente trabalho dá continuidade às abordagens propostas por Manzi (2019) e Valetta (2023), ao propor um modelo de detecção de irregularidades no pavimento a partir de captação de sinais de vibração mecânica experimentada pelos veículos.

Para Almeida (2018), que em seu trabalho desenvolveu um aplicativo para *smartphone* utilizado para estimar o Índice Internacional de Irregularidades (IRI) para avaliar as condições dos pavimentos de acordo com a irregularidade longitudinal de pavimentos flexíveis, o desenvolvimento socioeconômico de um país está fortemente relacionado com as condições das infraestruturas de transportes e a carência de manutenção adequada, assim como a recuperação parcial do pavimento, são fatores que afetam a segurança e o conforto dos usuários, também comprometendo a vida útil do pavimento.

Conhecendo a importância e as dificuldades do monitoramento das condições das vias abertas à circulação, uma solução é o uso de *smartphones* para captação de dados a partir de vibrações e posicionamento por meio de acelerômetros e GPS integrados à maioria destes dispositivos. Para Mednis et al. (2011) a utilização de *smartphones* para captação de dados do estado das vias é muito atraente em termos de usabilidade e prática devido à popularidade destes dispositivos. Seu trabalho consiste em um sistema de detecção de buracos de diferentes tamanhos nas vias utilizando *smartphones* equipados com sistema operacional Android.

Luz (2019), em seu estudo comparativo de desempenho entre os aplicativos *Roadoid*, *Roadlab* e *SmartIRI* aplicados em vias na cidade de Fortaleza – CE, destaca que o meio acadêmico deve contribuir para a melhoria da infraestrutura de transportes por meio de desenvolvimento de pesquisas a médio e longo prazo, tendo como aliado o intenso avanço tecnológico da última década, que deve ser incorporado pela infraestrutura de transportes para avaliar as condições dos pavimentos urbanos.

A detecção de irregularidades usando acelerômetros de *smartphones* é feita por meio da análise das vibrações experimentadas pelos veículos no trânsito. Diferentes superfícies das vias, como paralelepípedos, chão batido e pavimento geram vibrações diferentes ao trafegar. Em estradas asfaltadas, a detecção das anomalias no pavimento através das vibrações

captadas é facilitada em comparação aos demais terrenos. Sendo assim, segundo Rodrigues (2019), que em seu trabalho utiliza uma abordagem automatizada baseada na transformada wavelet de Haar sem usar calibração manual para detectar buracos em estradas, na detecção baseada em sensores a maior dificuldade é determinar se as variações nos dados obtidos são causadas por buracos ou por outras anomalias existentes no terreno, o que pode causar um aumento no número de falsos positivos.

Visando contribuir neste segmento de estudo, neste trabalho está sendo proposta a captação de dados através de acelerômetros de um *smartphone* durante o trajeto de um veículo em vias urbanas com irregularidades conhecidas com finalidade de classificar padrões das curvas obtidas e associá-las com os eventos reais experimentados ao trafegar.

1.2. Objetivos

O objetivo geral deste trabalho é detectar e classificar discontinuidades presentes em pavimentos urbanos – como lombadas, faixas elevadas, tachões e buracos – a partir da análise de sinais de vibração, gerados durante a passagem de veículos por esses obstáculos, captados por acelerômetros presentes em *smartphones*, de modo a possibilitar a análise e a associação de comportamentos e padrões das curvas adquiridas com eventos experimentados. Também se destacam como objetivos específicos do estudo os itens a seguir:

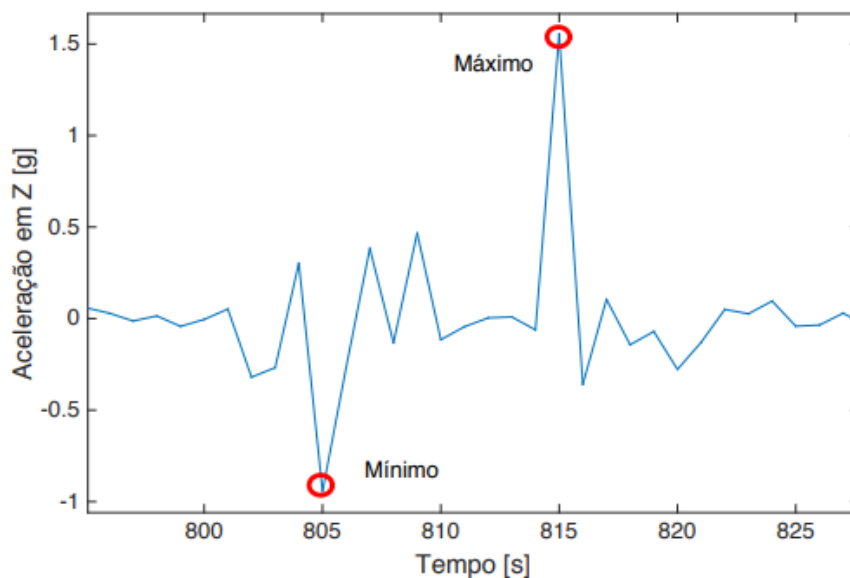
- Elaborar uma revisão bibliográfica acerca de técnicas de detecção de irregularidades nas estradas;
- Estabelecer um ou mais trajetos com discontinuidades conhecidas, para uma ou mais velocidades, de forma que seja possível levantar um conjunto de dados capaz de identificar os eventos;
- Coletar amostras de sinais de vibração para mais de um veículo em todos os obstáculos definidos;
- Tratar os dados obtidos utilizando técnicas matemáticas, aplicando métodos de processamento e organização;
- Identificar métricas aplicáveis ao estudo e desenvolver classificadores, realizando sua avaliação por meio de indicadores de desempenho;
- Identificar os eventos reais com base no conjunto de dados obtidos na fase de coleta de dados;
- Discutir as contribuições e limitações encontradas neste trabalho.

2. Revisão bibliográfica

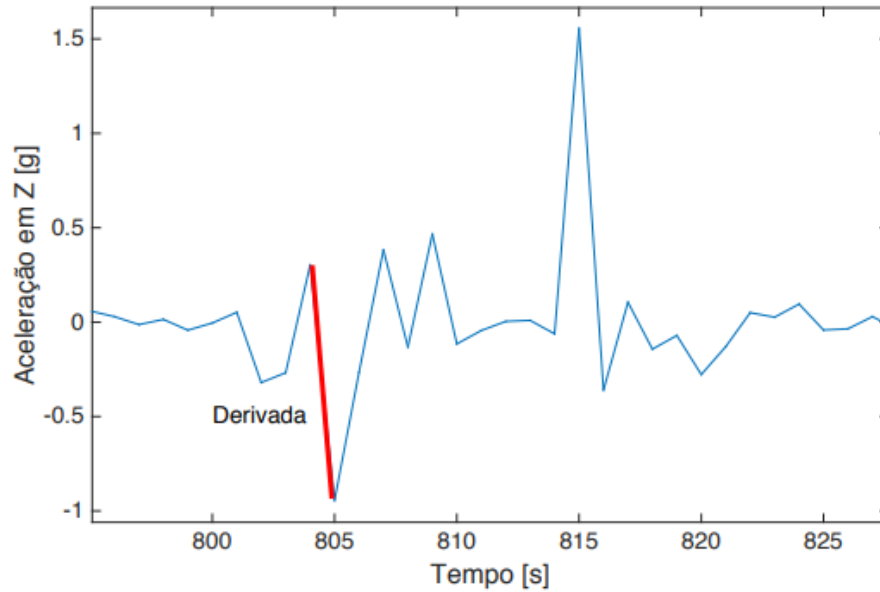
Este capítulo dedica-se ao estudo da literatura necessária para o desenvolvimento do presente trabalho, abordando a revisão de técnicas de aquisição de dados de vibrações provenientes de acelerômetros de *smartphones*, modelos matemáticos e uso de *softwares* para análise dos dados, conceito de classificadores de conjunto de dados em domínio do tempo e, por fim, análise da eficiência das classificações.

Manzi (2019) trabalhou com captação e tratamento de dados para detecção de irregularidades nas vias urbanas a partir de um único eixo de acelerômetro de um *smartphone* fixado ao painel de um carro de passeio. Foram utilizados métodos de classificação das curvas de aceleração no domínio do tempo. As métricas utilizadas em seu trabalho foram amplitudes máxima e mínima e a derivada referente ao início de cada evento, que representa mudanças bruscas na leitura do sensor. Tais parâmetros possibilitaram classificar os eventos em buracos, tachões e trechos sem irregularidades com avaliações de eficiência satisfatória. A Figura 1 representa as características observadas nos sinais obtidos pela autora para classificação dos eventos.

Figura 1 – Parâmetros calibrados para o experimento de Manzi (2019)



(a) Valores de amplitude máxima e mínima em z

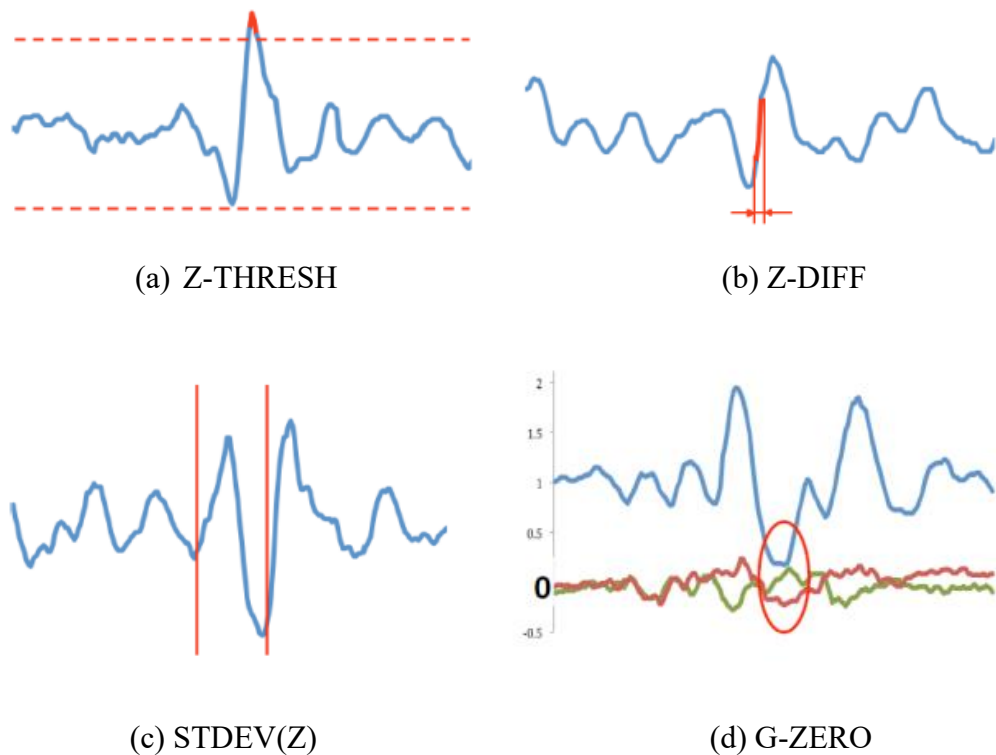


(b) Derivadas no início do evento

Fonte: Adaptado de Manzi (2019)

Outra abordagem de análise de vibrações no domínio do tempo visando estudar características que não exigissem técnicas avançadas de processamento de dados foi utilizada no trabalho de Mednis et al. (2011). Os dados foram adquiridos a partir de quatro *smartphones* em uma taxa de amostragem de 100 Hz com um único carro de passeio e estudados a partir das características Z-THRESH, Z-DIFF, STDEV(Z) e G-ZERO, que representam, respectivamente, o limite da aceleração no eixo z no qual um valor obtido acima deste é considerado buraco, a diferença entre duas medições de aceleração consecutivas, o desvio padrão para um determinado período do evento e instantes em que as acelerações dos três eixos tendem a zero. A Figura 2 ilustra as características estudadas pelos autores. Os testes de avaliação realizados para cada algoritmo utilizado e a análise de desempenho das diferentes classes de irregularidades apresentaram taxas de verdadeiros positivos de até 90%.

Figura 2 – Métricas Z-THRESH, Z-DIFF, STDEV(Z) e G-ZERO



Fonte: Adaptado de Mednis et al. (2011)

Em seu trabalho, Valetta (2023) apresentou um modelo dinâmico de meio carro e aplicou entradas que representam irregularidades em vias urbanas e rodovias com finalidade de estabelecer uma base para análise de sinais de acelerômetros como forma de detecção de irregularidades em vias. O autor desenvolveu uma modelagem matemática a partir de uma representação simplificada discreta de meio carro considerando 4 graus de liberdade. Aplicou ainda entradas do tipo lombada, buraco, tachões e faixa elevada por meio de simulação computacional observando e validando padrões que determinem o evento ocorrido dado o tipo de sinal obtido. O trabalho possibilita observar que o aumento da velocidade implica em aumento das amplitudes dos picos e vales, com exceção da entrada tipo buraco que apresenta maior pico em velocidade de 30km/h. Observou também que o aumento da velocidade do veículo reduz as distâncias entre picos e vales e o tempo total de acomodação do sistema.

No artigo de Harikrishnan (2017), é proposto um método para monitorar superfícies de estradas e detectar buracos e lombadas, além de prever sua severidade. O estudo utiliza acelerômetros de *smartphones* para coletar vibrações do veículo nos eixos x e z . O eixo x está alinhado com a direção lateral do veículo e sua utilização é justificada pelo fato de que, normalmente, apenas um lado do veículo sofre o impacto ao passar por um buraco,

implicando em vibrações no eixo x , diferente de quando o obstáculo é uma lombada, onde os dois lados do veículo realizam o mesmo movimento. Um algoritmo de filtragem de dados possibilita identificar eventos anormais, e a filtragem da razão $x-z$ classifica esses eventos como buracos ou lombadas. Adicionalmente, um algoritmo estima a severidade dos danos com base na relação entre aceleração vertical e deslocamento vertical do veículo. A fixação do *smartphone* foi testada em diferentes locais do veículo e a mais eficaz foi no centro do painel. O trabalho se mostrou satisfatório em classificar e estimar a gravidade dos eventos buracos e lombadas para velocidades entre 15 e 20 km/h.

Os estudos sobre o uso de *smartphones* para monitoramento das condições das vias de circulação não se limitam em identificar apenas buracos. Medição de irregularidades longitudinais também são alvo da facilidade e popularidade destes aparelhos. Irregularidades longitudinais são variações na superfície das estradas como ondulações, rugosidades e buracos. Segundo Almeida (2018, apud DNIT, 2006) “o conceito de Irregularidade Longitudinal de um pavimento é o conjunto dos desvios da superfície do pavimento em relação a um plano de referência”. Em seu trabalho, Almeida (2018) desenvolveu um aplicativo de *smartphone* para monitorar as irregularidades longitudinais das estradas através do IRI estimado pela leitura do eixo y do *smartphone* fixado a um suporte no carro. O autor conclui positivamente para o uso de dispositivos móveis para auxiliar no monitoramento das estradas no que diz respeito ao levantamento do IRI, mas discute limitações como a taxa de aquisição de dados em 100 Hz e a necessidade de calibração do sistema uma vez que os resultados obtidos variam em função do veículo utilizado, modelo de *smartphone* e velocidade.

De acordo com Rodrigues (2019), a maioria dos trabalhos realizados com finalidade de detecção de anomalias nas vias abertas à circulação utilizando sensores de *smartphones* estuda uma forma de classificar os eventos utilizando um *threshold* fixo, o que limita o modelo uma vez que existem diferenças dos sinais produzidos devido aos diferentes modelos de *smartphones*, acelerômetros e veículos, onde suas dimensões, suspensão e posicionamento do sensor são impactantes. Seu trabalho considera um valor de *threshold* calculado considerando todas as diferenças e limitações apontadas utilizando a transformada wavelet de Haar. O *threshold* adaptativo utilizado pelo autor se mostrou promissor na análise de sinais de acelerômetros no domínio do tempo onde, para detecção de buracos, obteve eficácia de

aproximadamente 96% e taxa de especificidade de 100%, indicando que o algoritmo não classificou nenhum falso positivo.

Passos et al. (2021) propuseram uma abordagem alternativa à detecção de buracos em pavimentos utilizando técnicas de processamento digital de imagens. O estudo baseou-se na análise de imagens da superfície das vias, classificadas por um modelo de *deep learning* treinado para identificar padrões associados a falhas no pavimento, como buracos e trincas. As imagens disponibilizadas pelo Departamento Nacional de Infraestrutura de Transportes (DNIT) foram analisadas em ambiente computacional, com foco na eficiência do reconhecimento dos eventos, alcançando resultados expressivos em precisão e acurácia. A metodologia apresentada, embora não dependa de sensores de *smartphones*, se mostra interessante no sentido de ampliar o escopo de monitoramento urbano automatizado.

Santhier e Luvizão (2022) realizaram um estudo de caso na rodovia SC-355 com o objetivo de comparar métodos distintos de análise da irregularidade longitudinal do pavimento. Os autores adquiriram os dados utilizaram o aplicativo *SmartIRI* instalado no *smartphone* fixado a um veículo e compararam seus resultados com os valores obtidos por meio de um perfilômetro a laser coletados em 2017. A comparação entre os métodos demonstrou boa correlação, validando a viabilidade do uso de *smartphones* para este tipo de levantamento. Os autores também discutem limitações, como a influência do tipo de veículo, faixa de velocidade recomendada entre 60 e 80 km/h e a necessidade de calibração prévia para resultados mais precisos.

No trabalho de Farias et al. (2023), foi investigado o uso *smartphones* como ferramenta para avaliação da irregularidade longitudinal de pavimentos, com integração dos dados coletados a Sistemas de Informações Geográficas (SIG). A aquisição de dados foi realizada a partir de um veículo contendo um perfilômetro inercial a laser para realizar o levantamento de IRI do pavimento e um *smartphone* fixado por meio de um suporte parabrisas, com aquisição dos sinais de aceleração no eixo vertical durante o percurso, associando os registros às coordenadas GPS em tempo real. Para validação dos resultados, os autores utilizaram a leitura do IRI realizada pelo perfilômetro, considerado equipamento de referência, com o objetivo de comparar os dados captados pelo *smartphone* com valores obtidos por método consagrado de medição do perfil longitudinal. Na etapa de processamento, os dados foram analisados no domínio da frequência através da aplicação da transformada de Fourier e foi aplicado um filtro do tipo passa-banda para atenuação de ruídos

provenientes de vibrações do veículo e interferências externas. Os resultados indicaram boa correlação entre os dados obtidos pelos dispositivos móveis e os valores de IRI medidos pelo perfilômetro, indicando o potencial da metodologia como alternativa viável e de baixo custo para monitoramento da qualidade do pavimento.

Em sua dissertação, Lima (2024) propôs um sistema de detecção de anomalias em pavimentos baseado em sensores inerciais embarcados e técnicas de aprendizado não supervisionado. O autor utilizou dados de aceleração coletados em tempo real por sensores fixados à bandeja inferior da suspensão do eixo dianteiro no lado do motorista de um veículo em circulação, analisando padrões para classificar trechos com e sem irregularidades, sem a necessidade de um modelo previamente treinado. Os testes apontaram uma taxa de assertividade de 94%. Muito embora o autor não utilize um *smartphone* para captação de dados, seu trabalho contribuiu com o tema ao destacar a fixação dos sensores abaixo do sistema de suspensão para evitar os efeitos de amortecimento e ao utilizar um modelo dinâmico de um quarto de carro em simulações, aliado à teoria de Nyquist, para fundamentar a definição da frequência mínima de amostragem necessária, ao invés de adotá-la de forma empírica como observado na maioria dos estudos semelhantes.

Diante dos trabalhos apresentados, nota-se um avanço significativo na utilização de smartphones como ferramenta de baixo custo para o monitoramento das condições das vias. As diferentes abordagens encontradas na literatura demonstram que os dados de aceleração são capazes de representar com precisão as respostas dinâmicas do veículo frente às irregularidades do pavimento, permitindo a aplicação de modelos baseados em métricas simples no domínio do tempo. Neste sentido, o presente trabalho fundamenta-se nos estudos revisados para propor uma metodologia prática e acessível de classificação de eventos, com base na análise de dados captados por acelerômetros de smartphones, contribuindo para o desenvolvimento de sistemas de detecção de anomalias presentes em pavimentos urbanos.

3. Fundamentação teórica

Este capítulo apresenta os conceitos básicos necessários para atingir os objetivos deste trabalho. Primeiramente são estudadas as condições das vias abertas à circulação no Brasil, seus problemas e impactos na sociedade para reforçar a importância do tipo de estudo do presente trabalho. Após o estudo da motivação, a busca por conceitos e técnicas para dar suporte ao trabalho contou com a revisão sobre comportamento dinâmico de um veículo, vibrações mecânicas, acelerômetros em dispositivos móveis, filtragem de sinais e modelos matemáticos para desenvolver classificadores multiclasse e matriz de confusão para avaliar os classificadores dos eventos.

3.1. Condições das vias abertas à circulação no Brasil

Segundo o Anexo I do CTB, via é definido como “superfície por onde transitam veículos, pessoas e animais, compreendendo a pista, a calçada, o acostamento, ilha e canteiro central”. Conforme o artigo 60 do CTB, as vias são classificadas segundo sua finalidade e espaço geográfico. As vias localizadas na área urbana são definidas como via de trânsito rápido, via arterial, via coletora e via local. Vias de trânsito rápido são descritas como vias de acessos especiais com trânsito livre de longo percurso, sem cruzamentos e semáforos, sem acesso aos lotes, sem travessia de pedestres e o limite de velocidade permitido é geralmente maior. Vias arteriais são comumente chamadas de avenidas e permitem tráfego de veículos a médias velocidades, possuem cruzamentos, semáforos, realizam conexões entre os bairros das cidades e permitem travessia de pedestres. Vias coletoras são as ruas que permitem o acesso às vias arteriais e vias de trânsito rápido, ou seja, possibilitam o trânsito que flui das áreas residenciais e comerciais em determinado bairro com destino a outras regiões da cidade. Vias locais são as ruas dentro dos bairros, caracterizadas pelo tráfego de menor intensidade e dimensões mais estreitas. As vias localizadas na área rural são definidas como estradas e rodovias. As estradas são definidas como qualquer via rural sem pavimento, enquanto as rodovias são as vias rurais pavimentadas.

De acordo com Neves et al. (2018), o transporte rodoviário representa 61,1% de todos os transportes do Brasil. Segundo a CNT (2022), em seu anuário do transporte do ano de 2022, 66,0% das rodovias brasileiras apresentam algum tipo de deficiência (40,7% regular, 18,8% ruim e 6,5% péssimo). Na pesquisa foram identificados 110.333 Km, onde 55,5% possuem problemas de pavimento, sendo 31,1% regular, 18,6% ruim e 5,8% péssimo. As


deficiências presentes nas rodovias, como buracos, ondulações e rugosidades, impactam na eficiência dos caminhões de carga uma vez que obrigam os motoristas a reduzir a velocidade com frequência durante o percurso, aumentando os custos de viagens devido ao desgaste dos componentes mecânicos e o aumento do consumo de combustível, que também impacta na emissão de poluentes.

A literatura carece de dados a respeito das condições gerais das vias urbanas, sendo dado nestas o desenvolvimento do presente trabalho, mais especificamente em vias locais. Segundo Aguiar et al. (2019) a malha viária nos perímetros urbanos não tem o mesmo investimento que as rodovias concedidas, que devem manter os padrões exigidos pelos órgãos reguladores, e este fato afeta a qualidade das vias abertas à circulação na área urbana, que caminha rumo a uma situação crítica no Estado de São Paulo.

3.2. Veículos como um sistema massa-mola-amortecedor

É de interesse deste trabalho compreender como o veículo que transita em vias urbanas se comporta ao atravessar discontinuidades. O modelo matemático mais simplificado que representa o comportamento de um veículo é o modelo quarto de carro. Esse modelo corresponde a quarta parte de um veículo e é constituído por uma mola que representa o pneu, conectada à uma massa associada ao conjunto pneu e suspensão, acima dela, uma mola e um amortecedor representam o sistema de suspensão responsável por sustentar a massa do veículo. A Figura 3 representa a estrutura do modelo de quarto de carro.

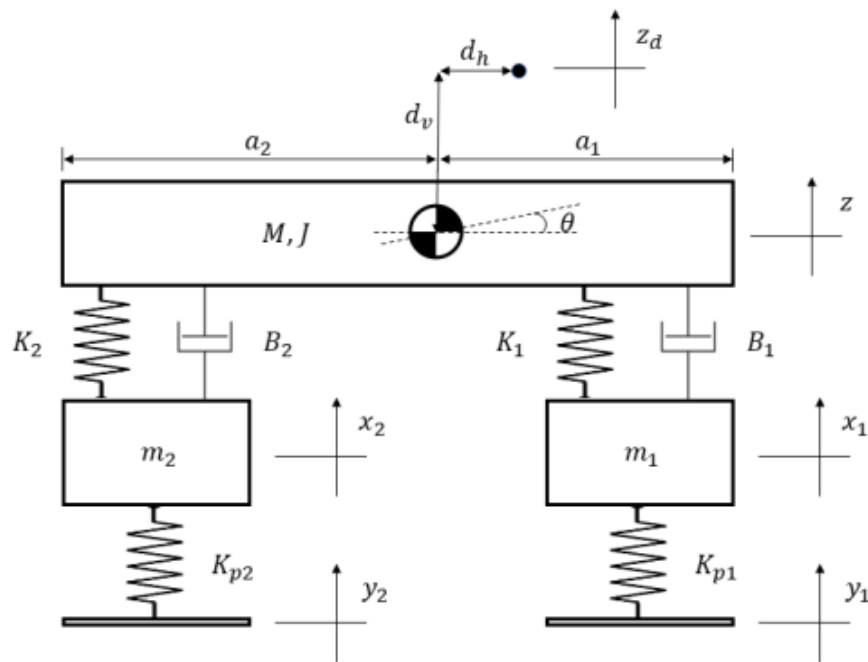
Figura 3 – Modelo de quarto de carro



Fonte: Adaptado de Hirpahuanca (2016)

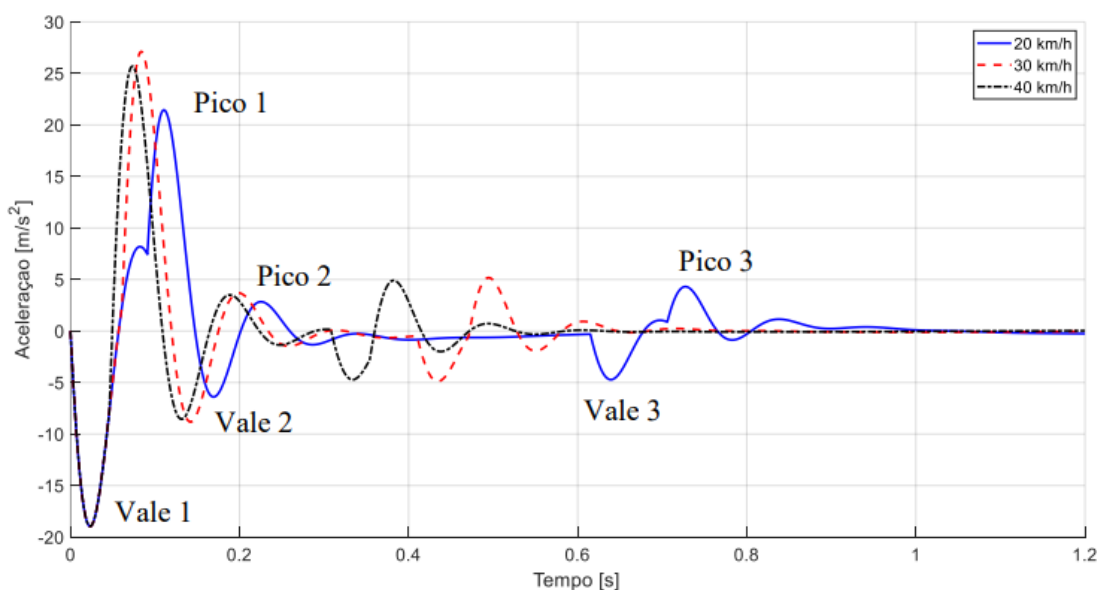
O modelo de meio carro utilizado por Valetta (2023), representado pela Figura 4, apresenta dois graus de liberdade sendo estes a rotação da massa M do veículo e os deslocamentos verticais. O autor considerou que a massa M representa a massa total do veículo que possui momento de inércia J , conectada às rodas por um par de molas e amortecedores K_1 e K_2 e B_1 e B_2 , respectivamente. Para as rodas, foram consideradas massas m_1 e m_2 e um par de molas K_{p1} e K_{p2} foi utilizado para representar a rigidez dos pneus. A representação do acelerômetro é dada por um ponto distante do centro de gravidade de massa M através de d_h e d_v . Em seu trabalho, foram aplicadas entradas com comportamentos conhecidos utilizando parâmetros do veículo constantes e seus resultados para a entrada tipo buraco são apresentadas na Figura 5.

Figura 4 – Modelo de meio carro



Fonte: Valetta (2023)

Figura 5 – Resposta à entrada tipo buraco



Fonte: Valetta (2023)

É notável que ao passar por um buraco, o veículo sofre acelerações verticais bruscas que são minimizadas ao longo do tempo, chegando à estabilização do sistema após os picos e vales de menores intensidades. É de preocupação deste trabalho aplicar a metodologia adequada para destacar o início e fim de cada evento analisado uma vez que são esperadas leituras do acelerômetro presente no *smartphone* em trechos sem discontinuidades devido à vibração do funcionamento do veículo e a rugosidade do pavimento das ruas.

3.3. Vibrações mecânicas

De acordo com Rao (2008), sinais de vibração mecânica representam a variação do estado físico de um sistema dinâmico, sendo estes a aceleração, velocidade e deslocamento. De forma geral, estes sinais são emitidos por componentes mecânicos sujeitos ao movimento, como motores, eixos, bombas, turbinas, mancais de rolamento, entre outros. Vibração é qualquer movimento que se repete após um intervalo de tempo, como um pêndulo balançando. Ainda segundo o autor, um sistema vibratório possui um meio que armazena energia potencial (mola ou elasticidade), um meio para armazenar energia cinética (massa ou inércia) e um meio de perda de energia (amortecedor).

Ainda conforme Rao (2008), vibrações mecânicas podem ser classificadas de várias maneiras, como vibração livre e forçada, vibração não amortecida e amortecida, vibração linear e não linear e vibração determinística e aleatória. Vibração livre é aquela presente em

um sistema que após uma perturbação inicial continua a vibrar sem nenhuma força externa agindo sobre ele. A oscilação de um pêndulo simples é um exemplo de vibração livre. Vibração forçada está presente em um sistema que está sujeito a uma força externa, como motores a combustão interna. Vibração não amortecida é dita quando não há perdas de energia no sistema, seja por atrito ou qualquer resistência, por outro lado, quando há qualquer perda de energia no sistema, a vibração é classificada em vibração amortecida. Vibração linear ocorre quando todos os componentes do sistema vibratório (massa-mola-amortecedor) comportam-se de forma linear matematicamente, caso contrário, a vibração do sistema é definida como vibração não linear. Vibração determinística em um sistema vibratório é dita quando é possível conhecer o comportamento da curva resposta do sistema e esta apresenta repetitividade e pode ser aproximada ou definida por uma equação matemática, caso o sistema não apresente estas características, o mesmo é classificado como vibração aleatória.

Para este trabalho, o movimento do sistema vibratório massa-mola-amortecedor que representa um veículo pode ser representado por funções periódicas, portanto as definições e terminologias seguintes são aplicáveis ao estudo. Ciclo é dito quando ocorre o movimento de um corpo vibratório de sua posição de repouso até sua posição extrema em um sentido, retornando até a posição de equilíbrio, movimentando-se até sua posição extrema no outro sentido e por fim de volta à posição de equilíbrio. Amplitude é o máximo deslocamento de um corpo vibratório em qualquer sentido em relação à posição de equilíbrio. Período de oscilação é definido como o tempo necessário para concluir um ciclo de movimento. Frequência de oscilação é o número de ciclos que ocorrem no sistema vibratório em uma unidade de tempo. Frequência natural é aquela na qual o sistema oscila para retornar ao seu estado de equilíbrio sem ação de forças externas após sofrer uma perturbação (Rao, 2008). De acordo com Barreto (2003, apud Pereira, 2016) o nível RMS, também conhecido como valor eficaz, é uma das mais importantes formas de medição de amplitude, pois considera o nível de energia do sinal vibratório. Para sinais discretos, o nível RMS é dado por:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (1)$$

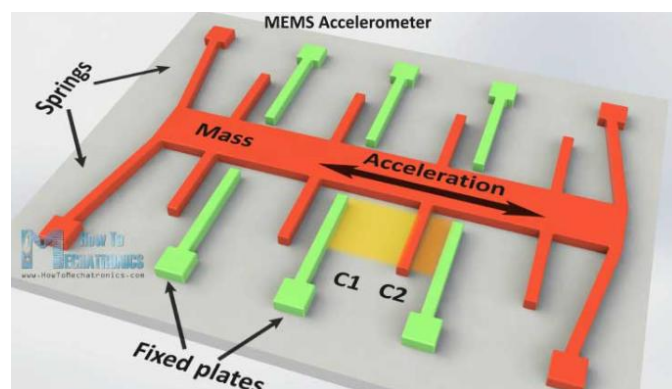
Onde N é o número total de amostras do sinal e x é o valor do sinal na posição i .

3.4. Acelerômetros e *smartphones*

O uso de sensores é essencial em aplicações tecnológicas, especialmente na análise de vibrações mecânicas, por permitirem a tradução de fenômenos físicos, como os impactos gerados ao transitar por buracos e lombadas, em sinais digitais processáveis. No contexto deste trabalho, os acelerômetros de *smartphones* desempenham papel fundamental ao registrar e fornecer dados que possibilitam a avaliação da resposta dinâmica do veículo ao experimentar as irregularidades do pavimento. Segundo Calache (2013), seu princípio de funcionamento é um sistema massa-mola-amortecedor onde uma massa de prova é conectada a uma referência por uma mola com coeficiente elástico k e um amortecedor com coeficiente de amortecimento γ .

O tipo de acelerômetro presente nos *smartphones* é de uma classe denominada Acelerômetro Baseados em Sistemas Microeletromecânicos (MEMS) e sua utilização é muito popular motivado pela alta demanda do mercado de dispositivos móveis. Conforme descrito por Shaeffer (2013), esses sensores consistem em dispositivos micromecânicos capazes de converter movimento físico em sinais elétricos. Funcionam com base em variações capacitivas geradas pelo deslocamento de massas suspensas internamente, sendo essas variações interpretadas por circuitos eletrônicos específicos que determinam a aceleração sofrida pelo dispositivo. Ainda segundo o autor, acelerômetros MEMS possuem frequência natural tipicamente na faixa de alguns quilohertz, mas operam bem abaixo dessa frequência. A Figura 6 ilustra os componentes de um acelerômetro MEMS, onde uma massa presa por uma mola se movimenta em uma única direção. Acelerações aplicadas nessa direção específica farão com que a massa se desloque e a capacitância entre as placas e a massa sofra variação, que é medida e processada para determinar o valor de aceleração.

Figura 6 – Representação dos componentes de um acelerômetro MEMS



Fonte: How To Mechatronics ([s.d.])

De acordo com Dadafshar (2014), os acelerômetros têm sido usados há muito tempo em automóveis para detectar colisões e acionar *airbags*. Ainda de acordo com o autor, em dispositivos móveis, os acelerômetros tem aplicações como alternar entre modos retrato e paisagem, reconhecimento de gestos e detectar toques através da roupa quando o dispositivo está no bolso. Os acelerômetros presentes nos *smartphones* são capazes de medir as acelerações nos três eixos cartesianos x , y e z , seu posicionamento é ilustrado na Figura 7. Para o presente trabalho, foi preciso que um dos eixos do *smartphone* estivesse alinhado com o eixo vertical do veículo para proporcionar uma coleta de dados apropriada.

Figura 7 – Orientação dos eixos de um *smartphone*



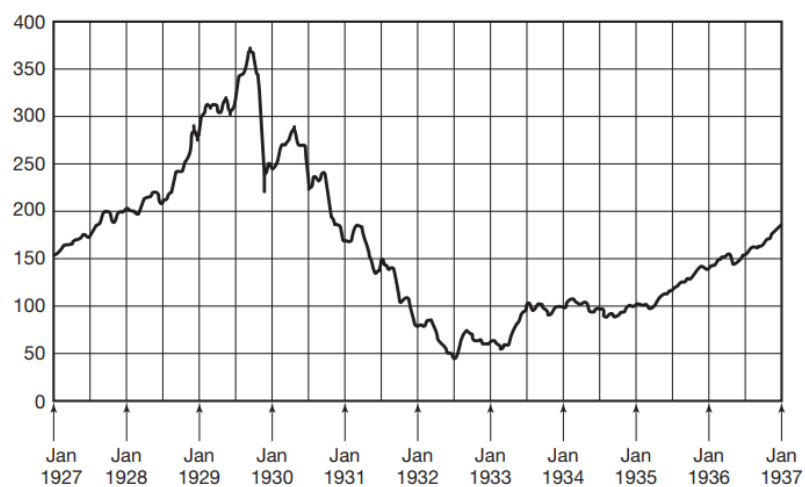
Fonte: Rodrigues (2019)

3.5. Filtragem de sinais

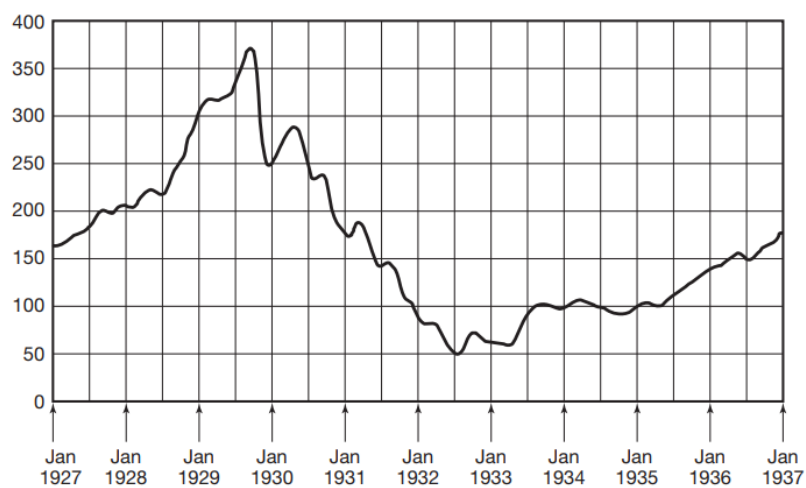
Avaliar os sinais de vibração de experimentos quando ocorre poluição por ruído nem sempre é uma tarefa fácil. Neste trabalho, a aquisição de dados foi prejudicada pela vibração do veículo com o motor ligado e pelas condições do pavimento.

Para Oppenheim (2010), modificar as amplitudes relativas dos componentes em frequência de sinais ou eliminar determinados componentes em frequência é interessante para diversas aplicações. Filtros seletivos em frequência são uma classe de filtros que trabalham selecionando as bandas de frequência que serão descartadas ou preservadas para a situação específica da análise dos sinais. O filtro passa-baixa é um tipo de filtro seletivo em frequência que permite passar frequências baixas e rejeita frequências mais altas que a frequência de corte. A Figura 8 apresentada por Oppenheim (2010), ilustra o efeito da filtragem passa-baixa em um sinal que em (a) representa o índice semanal do mercado de ações Dow Jones de dez anos, em (b) representa a média móvel de 51 dias aplicada a (a) e em (c) representa a média móvel de 201 dias aplicada a (a).


Figura 8 – Efeito da filtragem em frequência – passa-baixa



(a) Índice semanal do mercado de ações Dow Jones



(b) Média móvel de 51 dias aplicada ao índice semanal



(c) Média móvel de 201 dias aplicada ao índice semanal

Fonte: Adaptado de Oppenheim (2010)

A filtragem de sinais utilizando filtro seletivo em frequência é de interesse deste trabalho pois permite a suavização do comportamento em frequências mais altas, que não contribuem significativamente para a análise do sinal do evento e sua retirada não prejudica a forma da curva analisada.

3.6. Classificador multiclasse baseado na mínima distância ao centróide (MDC)

O classificador de mínima distância ao centróide é amplamente utilizado em problemas de classificação multiclasse devido à sua simplicidade e baixo custo computacional. Conforme descrito por Duda, Hart e Stork (2001), essa técnica consiste em calcular a distância euclidiana entre os dados de uma amostra e os centróides das classes, atribuindo a classe correspondente à menor distância calculada. Essa abordagem permite a construção de um classificador eficaz sem a necessidade de técnicas mais complexas de aprendizagem de máquina. A equação da distância euclidiana é dada por:

$$D(x, c) = \sqrt{\sum_{i=1}^n (x_i - c_{k,i})^2} \quad (2)$$

onde x representa o vetor de características da amostra e c é o vetor médio (centróide) da classe k . Essa definição matemática para o classificador de mínima distância também é apresentada por Theodoridis e Koutroumbas (2009), que discutem sua aplicação em classificadores multiclasse. No trabalho de Nery et al. (2013), foi demonstrada a aplicabilidade desse método em contextos de classificação de uso e cobertura do solo, evidenciando sua eficiência entre diferentes classes.

3.7. Métricas para avaliação de classificadores

Para avaliar o desempenho dos classificadores dos eventos, os conceitos de verdadeiro positivo (VP), falso positivo (FP), verdadeiro negativo (VN) e falso negativo (FN) são amplamente utilizados pelo meio acadêmico. Possibilitam o cálculo de indicadores importantes, como acurácia, precisão, sensibilidade, especificidade e F1-score do classificador. São ditos VP os dados que o classificador previu como positivo e realmente pertencem à classe. Quando um dado é classificado em uma classe à qual ele não pertence realmente, tem-se um FP. O VN ocorre quando o classificador previu que o dado não pertence à classe e de fato ele não pertence. Por fim, o FN acontece quando o classificador previu como negativo para a classe, mas o dado pertence a ela.

Acurácia é o número de amostras corretamente classificadas em relação ao total de amostras presentes no estudo. Sua equação é dada por:

$$Acurácia = \frac{VP+VN}{VP+FP+VN+FN} \quad (3)$$

Precisão é o número de amostras que realmente pertencem à classe em relação a todas as amostras que foram classificadas pelo modelo como pertencentes à classe. Sua equação é dada por:

$$Precisão = \frac{VP}{VP+FP} \quad (4)$$

Sensibilidade é o número de amostras corretamente classificadas como pertencentes à classe em relação a todas as amostras que realmente pertencem à classe. Sua equação é dada por:

$$Sensibilidade = \frac{VP}{VP+FN} \quad (5)$$

Especificidade é o número de amostras corretamente classificadas como não pertencentes à classe em relação a todas as amostras do conjunto de dados que realmente não pertencem à classe. Sua equação é dada por:

$$Especificidade = \frac{VN}{VN+FP} \quad (6)$$

F1-score é a média harmônica entre os valores de precisão e sensibilidade obtidos para a classe. Sua equação é dada por:

$$F1 - Score = \frac{2 \times Precisão \times Sensibilidade}{Precisão+Sensibilidade} \quad (7)$$

No contexto de classificadores multiclasse com classes desbalanceadas e alta sobreposição entre os valores das classes, como é o caso do presente trabalho, o indicador F1-score assume papel central na avaliação do desempenho do classificador. De acordo com Powers (2011), o F1-score representa a média harmônica entre precisão e sensibilidade, proporcionando uma medida equilibrada que penaliza tanto falsos positivos quanto falsos negativos. Essa característica é fundamental em cenários onde a simples acurácia pode ser enganosa, pois o desbalanceamento pode favorecer a classe de maior ocorrência, mascarando o desempenho real do classificador nas classes de menor ocorrência. Embora os indicadores

acurácia, precisão, sensibilidade e especificidade também sejam considerados neste estudo para oferecer uma avaliação completa do desempenho, a atenção principal será dada ao F1-score.

4. Metodologia

No presente trabalho foram extraídos dados experimentais referentes ao comportamento dinâmico de veículos ao transitar por vias locais e ao sofrer impactos em obstáculos, como buracos, lombadas, faixas elevadas e tachões.

A coleta de dados foi realizada com o uso do acelerômetro de um *smartphone*, fixado ao painel de um veículo, conforme realizado por outros autores, como Manzi (2019). Durante o trajeto em regiões que contêm os obstáculos definidos para este estudo, foi possível compreender como o sistema responde, em termos de aceleração, aos impactos sofridos pelo veículo ao atravessar os eventos.

Para atingir os resultados propostos pelo trabalho, os dados foram tratados com técnicas como filtragem em frequência. A partir dos sinais tratados, métricas foram selecionadas e calculadas para cada dado do experimento. Por fim, modelos matemáticos foram aplicados com o intuito de desenvolver classificadores capazes de identificar corretamente os eventos.

4.1. Aquisição de dados

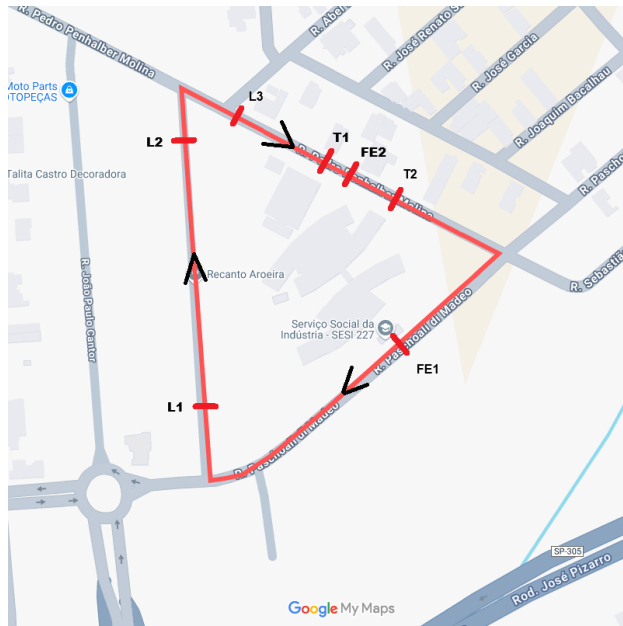
Para a etapa de aquisição de dados foram utilizados dois veículos de acordo com a Tabela 2 em um trajeto destacado na Figura 9, percorrido em velocidades entre 8 e 31 km/h, que contém duas faixas elevadas, três lombadas e dois tachões, ilustrados na Figura 10. Além disso, foram analisados três buracos tipo cratera com comprimentos de aproximadamente 30, 50 e 90 cm na direção do deslocamento do veículo, denominados Buraco 1, Buraco 2 e Buraco 3, respectivamente. Esses buracos estão localizados em regiões diferentes na cidade de Monte Alto – SP, como mostra a Figura 11, e foram atravessados em velocidades entre 8 e 27 km/h.

Tabela 2 – Lista de veículos utilizados no trabalho

Veículo	Marca	Modelo	Ano
1	Chevrolet	Onix 1.4 Activ	2017
2	Fiat	Toro Volcano Diesel AT9	2018

Fonte: Próprio Autor

Figura 9 – Localização do percurso trafegado



Fonte: Próprio Autor

Figura 10 – Eventos presentes no percurso trafegado



(a) Faixa Elevada 1



(b) Faixa Elevada 1 - Lateral



(c) Faixa Elevada 2



(d) Faixa Elevada 2 - lateral



(e) Lombada 1



(f) Lombada 1 - Lateral



(g) Lombada 2



(h) Lombada 2 - Lateral



(i) Lombada 3



(j) Lombada 3 - Lateral



(k) Tachão 1



(l) Tachão 1 – lateral



(m) Tachão 2



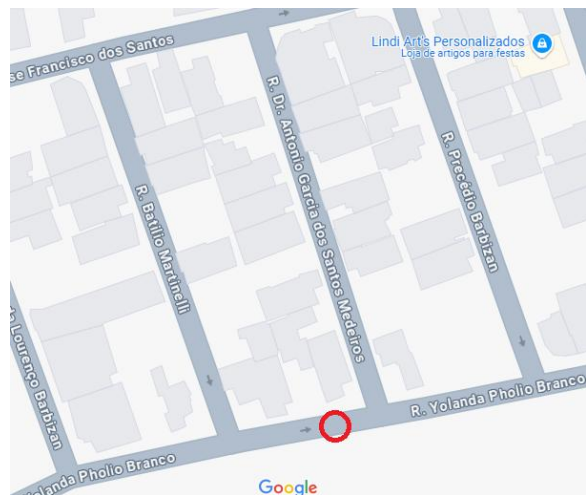
(n) Tachão 2 - lateral

Fonte: Próprio Autor

Figura 11 – Buracos selecionados para o trabalho e suas localizações




(a) Buraco 1



(b) Localização Buraco 1




(c) Buraco 2



(d) Localização Buraco 2



(e) Buraco 3




(f) Localização Buraco 3

Fonte: Próprio Autor

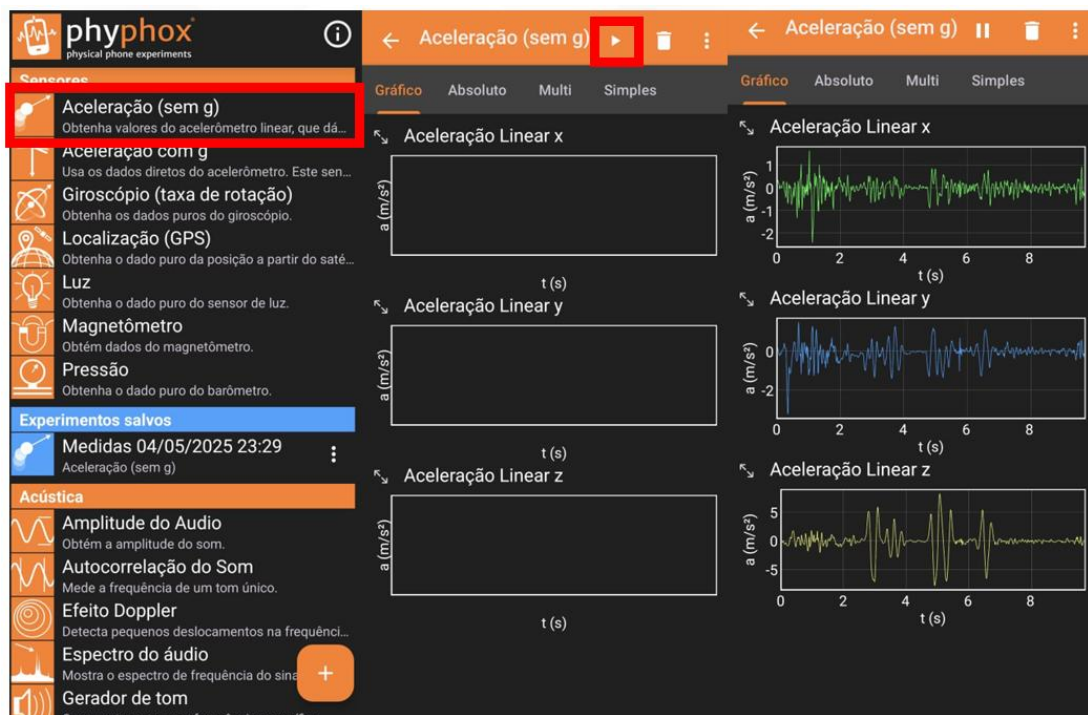
O *smartphone* utilizado no experimento foi um Samsung Galaxy S24 fixado ao painel dos veículos conforme ilustrado na Figura 12. A fixação foi realizada com fita dupla face 3M Scotch. O *software* utilizado para a aquisição dos dados foi o *Phyphox*, ilustrado na Figura 13, disponível na *Play Store*, no qual utilizou-se a opção aceleração sem gravidade a uma taxa de aquisição de dados de 125 Hz. O *Phyphox* permite exportar os sinais em arquivo Excel com cinco colunas que representam, respectivamente, tempo, aceleração em x, aceleração em y, aceleração em z e aceleração absoluta.

Figura 12 – Fixação do *smartphone*



Fonte: Próprio Autor

Figura 13 – Capturas de tela do *Phyphox*



Fonte: Próprio Autor

Com o *smartphone* fixado no veículo, a aquisição de dados é realizada ao trafegar por obstáculos conhecidos com velocidades conhecidas. No primeiro momento, adquiriu-se os dados dos eventos da Figura 10 no circuito da Figura 9 e, posteriormente, coletou-se os dados dos buracos da Figura 11. Para os circuitos foram percorridas pelo menos 25 voltas para cada veículo, trabalhando com cinco faixas de velocidades em cada um dos sete obstáculos. Os

sinais para os buracos foram coletados em sequências nos eventos isoladamente, onde o veículo transita para frente, passando as duas rodas do lado do motorista pelo buraco, percorre mais um pequeno percurso até parar, então a marcha ré é engatada e o veículo é posicionado em um ponto que antecede o buraco, assim o veículo arranca novamente e passa pelo buraco até terminar o número mínimo definido para cada sequência. A dinâmica do trabalho contou com o auxílio do gravador de voz do *smartphone* operando em conjunto com o *Phyphox* de forma sincronizada. Para cada obstáculo atravessado a velocidade observada no painel do veículo no instante em que as rodas dianteiras sofrem o impacto do evento foi dita em voz alta, desta forma foi possível separar um sinal grande referente a uma volta completa no circuito ou referente à uma sequência dos buracos em sinais individuais dos eventos com as respectivas velocidades indicadas.

As Tabelas 3, 4 e 5 apresentam a quantidade de dados adquirida no experimento. Considerou-se 10 o número mínimo de dados desejados para buracos em cada faixa de velocidade para cada veículo e 5 o número mínimo de dados desejados para as demais discontinuidades em cada faixa de velocidade para cada veículo.

Tabela 3 – Quantidade de dados coletados Onix

Evento	8-12	13-17	18-22	23-27	28-31	Parcial
Buraco 1	14	20	10	12	0	56
Buraco 2	10	11	10	0	0	31
Buraco 3	10	10	10	10	0	40
Faixa Elevada 1	5	5	5	6	5	26
Faixa Elevada 2	5	5	7	4	5	26
Lombada 1	5	5	5	6	5	26
Lombada 2	5	5	5	6	5	26
Lombada 3	5	5	6	4	6	26
Tachão 1	5	5	5	7	4	26
Tachão 2	5	5	5	6	5	26
					Total	309

Fonte: Próprio Autor

Tabela 4 – Quantidade de dados coletados Toro

Evento	8-12	13-17	18-22	23-27	28-31	Parcial
Buraco 1	8	14	11	11	0	44
Buraco 2	10	11	9	0	0	30
Buraco 3	10	12	14	6	0	42
Faixa Elevada 1	5	5	5	5	5	25
Faixa Elevada 2	5	5	5	5	5	25
Lombada 1	5	6	4	5	5	25
Lombada 2	5	5	5	5	5	25
Lombada 3	5	5	5	5	5	25
Tachão 1	5	5	5	5	5	25
Tachão 2	5	5	5	5	5	25
					Total	291

Fonte: Próprio Autor

Tabela 5 – Total de dados coletados

Evento	8-12	13-17	18-22	23-27	28-31	Parcial
Buraco 1	22	34	21	23	0	100
Buraco 2	20	22	19	0	0	61
Buraco 3	20	22	24	16	0	82
Faixa Elevada 1	10	10	10	11	10	51
Faixa Elevada 2	10	10	12	9	10	51
Lombada 1	10	11	9	11	10	51
Lombada 2	10	10	10	11	10	51
Lombada 3	10	10	11	9	11	51
Tachão 1	10	10	10	12	9	51
Tachão 2	10	10	10	11	10	51
					Total	600

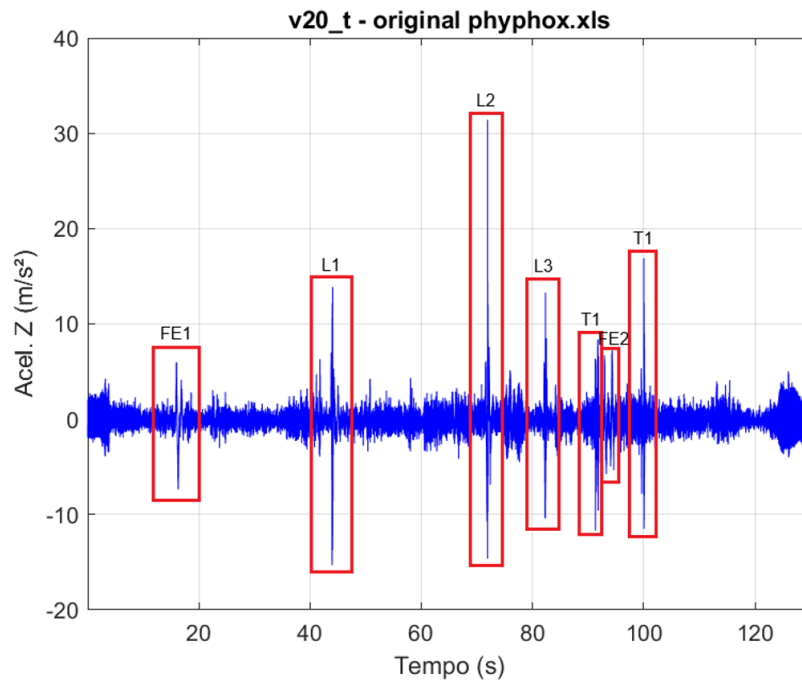
Fonte: Próprio Autor

4.2. Gerenciamento dos dados

Na etapa de aquisição de dados, planilhas do Excel foram exportadas através do *software* de captura de dados utilizado do experimento. Estes arquivos representam todos os sinais captados por volta, para obstáculos do tipo faixa elevada, lombada e tachão, e sequência, para obstáculos do tipo buraco. Nas Figuras 14 e 15 são ilustrados,

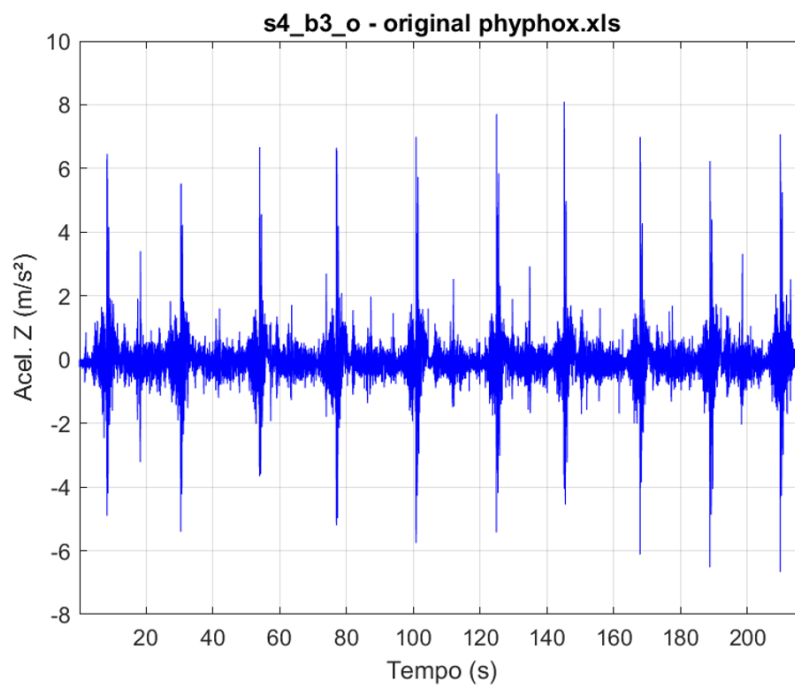
respectivamente, o sinal gerado por um arquivo que representa uma volta e um buraco. Os gráficos foram construídos utilizando o MATLAB.

Figura 14 – Gráfico da aceleração no eixo z da volta 20 da Toro



Fonte: Próprio Autor


Figura 15 – Gráfico da aceleração no eixo z da sequência 4 do buraco 3 do Onix



Fonte: Próprio Autor

Conforme informado no item anterior, o uso de um gravador de voz foi indispensável para a metodologia utilizada. As planilhas originais das voltas e sequências foram divididas em planilhas menores referentes a cada evento e armazenadas com um padrão de nome de arquivo que permite conhecer o obstáculo, velocidade de entrada e saída, volta ou sequência e veículo. A vinculação da velocidade foi realizada arquivo por arquivo, ouvindo as velocidades gravadas no momento do experimento para cada obstáculo trafegado. O padrão utilizado para voltas foi `Obstáculo_(VelocidadeEntrada-VelocidadeSaída)_Volta_Veículo` e para sequências foi `Obstáculo_(VelocidadeEntrada-VelocidadeSaída)_Sequência_esq_Veículo`. Ao final foram criadas 600 planilhas de Excel que representam cada evento do trabalho. A Figura 16 ilustra o gráfico gerado no MATLAB para um evento do estudo.

Figura 16 – Gráfico da aceleração no eixo z da lombada 1 à velocidade de entrada de 15 km/h na volta 14 do Onix – 125 Hz



Fonte: Próprio Autor

4.3. Definição de início e fim do evento

A definição do intervalo referente ao evento foi realizada com base no nível RMS dos sinais filtrados em frequência com um filtro passa-baixa de segunda ordem com frequência de corte de 20 Hz utilizando as funções *butter* e *filtfilt* no MATLAB. Para eliminar o efeito de

borda, foram desconsiderados os 15 primeiros e 15 últimos pontos do sinal após a aplicação da filtragem. Para cada planilha, foi calculado o nível RMS do ruído que antecede o início do sinal do evento para os 0,5 s iniciais do arquivo. Posteriormente foi calculado em janelas flutuantes de 0,1 s o nível RMS do sinal do arquivo a partir dos 0,5 s iniciais, quando o nível de RMS das janelas flutuantes ultrapassa um limiar, definido como o produto entre uma constante e o nível RMS do ruído, o início do evento é dado. Verificou-se, a partir dos dados captados no experimento, que o nível RMS do sinal do evento é significativamente maior que o nível RMS do trecho inicial que o antecede. Com base nessa observação, considerou-se que para níveis RMS menores de ruído o fator de ampliação deve ser maior para evitar que a detecção do início do evento seja precoce e para níveis RMS maiores de ruído, este fator deve ser menor para evitar a detecção tardia ou a não detecção do início do evento. Os valores das constantes que definem o limiar dependem do nível RMS do ruído e são apresentados na Tabela 6.

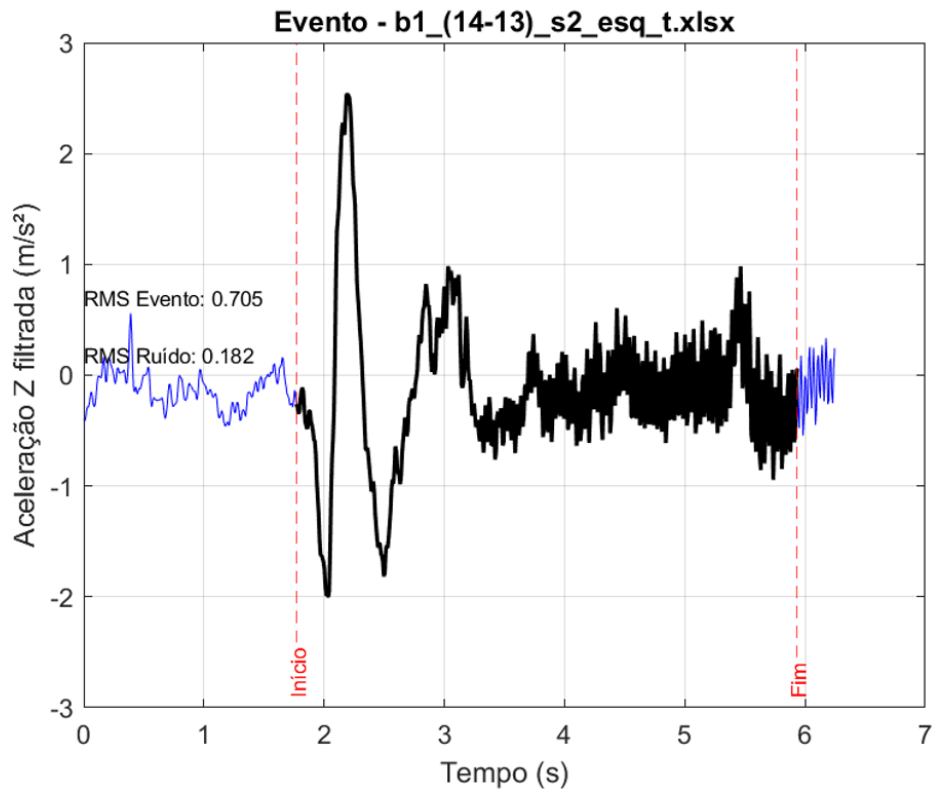
Tabela 6 – Fator de ampliação do RMS para detectar o início do evento

RMS ruído	Fator
(0 ; 0,1)	10
[0,1 ; 0,2)	6
[0,2 ; +∞)	3

Fonte: Próprio Autor

De forma análoga, o fim do evento foi definido no MATLAB quando o nível de excitação do sinal volta a um nível parecido com o do ruído. A Figura 17 ilustra a seleção do intervalo que define o acontecimento do evento.

Figura 17 – Início e fim de um evento calculado via MATLAB comparando os níveis RMS




Fonte: Próprio Autor

4.4. Métricas

Para determinar as regras dos classificadores este trabalho considerou trabalhar, no primeiro momento, com as métricas pico global, vale global e nível RMS. Posteriormente incluiu-se uma inclinação média da curva definida entre o início do evento e o primeiro pico ou vale local. Todas as métricas foram calculadas via MATLAB e são apresentadas na Figura 18.

Figura 18 – Indicação das métricas utilizadas



Fonte: Próprio Autor

4.5. Classificadores multiclasse

Com as métricas definidas e calculadas para todos os dados do experimento, foram desenvolvidos dois classificadores multiclasse baseados na distância euclidiana mínima em relação ao centróide de cada classe, utilizando duas abordagens distintas: uma considerando a média e outra a mediana dos valores das métricas de cada classe de eventos. Assim, um dado é classificado como pertencente à classe cujo centróide apresenta a menor distância euclidiana considerando os valores de nível RMS, pico global, vale global e inclinação média.

A escolha por centróides baseados em média e mediana visa avaliar a influência de possíveis valores extremos nas distribuições das métricas, uma vez que os dados apresentam sobreposição significativa entre as classes. A mediana tende a ser mais robusta a *outliers*, enquanto a média pode refletir melhor a tendência geral. Essa comparação permite investigar qual abordagem apresenta melhor desempenho para os dados captados para o presente trabalho.

4.6. Avaliação dos classificadores

Por fim, avaliou-se o desempenho dos classificadores por meio de uma matriz de confusão, conforme apresentada na Tabela 7.

Tabela 7 – Matriz de confusão para classificador multiclasse

		Previsto				Desempenho				
		Classe A	Classe B	Classe C	Classe D	Sens (%)	Spec (%)	Acur (%)	Prec (%)	F1-Score (%)
R	Classe A	a_{11}	a_{12}	a_{13}	a_{14}	–	–	–	–	–
e	Classe B	a_{21}	a_{22}	a_{23}	a_{24}	–	–	–	–	–
a	Classe C	a_{31}	a_{32}	a_{33}	a_{34}	–	–	–	–	–
l	Classe D	a_{41}	a_{42}	a_{43}	a_{44}	–	–	–	–	–

Fonte: Próprio Autor

Onde a_{ij} é o número de amostras da classe real i classificadas como pertencentes à classe j . A partir desses valores, os indicadores de sensibilidade, especificidade, acurácia, precisão e F1-score foram calculados para cada classe, permitindo uma análise detalhada do desempenho, com ênfase especial no F1-score, conforme discutido anteriormente devido ao desbalanceamento entre as classes. Por fim, calculou-se o F1-score global para cada um dos dois classificadores para avaliar o desempenho geral do modelo utilizado.


5. Resultados e discussão

Neste capítulo, são apresentados e discutidos os resultados obtidos, com ênfase na avaliação do desempenho dos classificadores desenvolvidos. Os indicadores de desempenho são analisados separadamente para cada uma das variações descritas na metodologia.

5.1. Análise dos sinais


Inicialmente, os arquivos de cada trajeto percorrido pelos veículos foram analisados visualmente com o objetivo de compreender em amplitude se é possível diferenciar com clareza os locais onde existem irregularidades dos locais onde o pavimento é contínuo. Nas Figuras 19 e 20 é possível visualizar o comportamento dos dados referentes a voltas e sequências, descritas na metodologia.

Figura 19 – Circuito que contém faixas elevadas, lombadas e tachões



Fonte: Próprio Autor

Figura 20 – Sequência de extração de dados para um buraco




Fonte: Próprio Autor

Conforme ilustradas nas Figuras 19 e 20, a resposta do veículo em aceleração na presença de um obstáculo é visualmente possível de ser identificada. Isso está de acordo com o esperado para o comportamento de um sistema dinâmico quando excitado por alguma entrada de impacto. Esta observação colabora para o progresso deste trabalho uma vez que evidencia o potencial da detecção do sinal através de um classificador.


Na próxima etapa do estudo, foram separados todos os sinais referentes aos eventos do experimento. Conforme mencionado na Metodologia, com o auxílio das gravações realizadas, foram construídas novas planilhas para cada volta e sequência para cada veículo. Ao final deste processo, o trabalho contou com 600 planilhas, referentes a todos os dados obtidos. Os valores são ilustrados na Tabela 5. Para cada nova planilha, o gráfico da aceleração no eixo z foi construído no MATLAB para analisar visualmente a existência de padrões que são semelhantes para um mesmo obstáculo e padrões que diferem as curvas quando analisados eventos diferentes. Os gráficos utilizados nesta análise inicial foram construídos com os dados originais a 125 Hz. Curvas de aceleração para as velocidades de 10, 15 e 20 km/h são apresentadas na Figura A.1 (Apêndice A), organizadas de modo que permitem a comparação visual para observação da existência de padrões.

A visualização dos gráficos evidencia a proximidade que existe entre a forma das curvas de eventos do mesmo tipo. Por exemplo, o comportamento da resposta da aceleração em z para a entrada tipo lombada converge para um mesmo padrão considerando os obstáculos lombada 1, lombada 2 e lombada 3. A mesma interpretação é estendida para as demais curvas, nota-se que para cada grupo de evento um padrão bem nítido é formado. A análise visual dos gráficos também permite perceber que existem diferenças expressivas entre o formato das curvas em eventos diferentes. Em outras palavras, os gráficos da aceleração em z para um evento específico não são confundidos visualmente com o gráfico dos demais. A discussão apresentada é ilustrada pela Figura 21, que evidencia em (a) a semelhança entre as curvas fixando obstáculo e veículo, variando velocidade; em (b) a semelhança entre as curvas fixando obstáculo e velocidade, variando veículo; e em (c) as diferenças entre as curvas fixando velocidade e veículo, variando o obstáculo.


Figura 21 – Semelhanças e diferenças entre curvas



(a) Semelhanças observadas fixando obstáculo e veículo



(b) Semelhanças observadas fixando obstáculo e velocidade



(c) Diferenças observadas fixando velocidade e veículo

Fonte: Próprio Autor

5.2. Filtragem do sinal

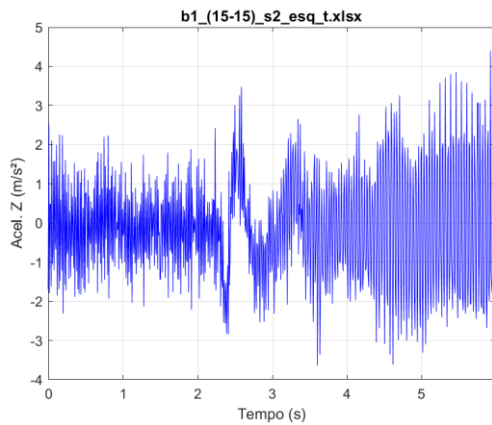
Após a etapa de interpretação visual das curvas dos obstáculos, concluiu-se que é possível identificar o início e o fim dos eventos com base no nível de vibração do sistema no trecho em que os eventos acontecem em relação ao trecho de pavimento sem anomalias. Conforme descrito na Metodologia, optou-se por considerar o nível RMS como parâmetro que determina o início e o fim do evento.

Em uma primeira tentativa, utilizou-se o MATLAB para identificar o início dos eventos nos dados com frequência de 125 Hz, originados pelo *software Phyphox* utilizado na etapa de captação de dados. Os resultados foram satisfatórios para o Onix, onde todos os inícios detectados para as curvas do experimento deste veículo convergiam para o início real do evento. Ao aplicar o mesmo código para os dados com frequência de 125 Hz coletados com a Toro, o código não identificou nenhum início de evento. Verificou-se que o nível de ruído proveniente do funcionamento do conjunto mecânico deste veículo e que não contribui para este estudo é muito maior que o do Onix, principalmente em velocidades mais baixas.


Este fato impossibilita a identificação do nível do evento pelo MATLAB. Neste momento a taxa de detecção da presença de eventos era de 51,5%.

Para contornar esta dificuldade, optou-se por aplicar uma filtragem em frequência com o uso de um filtro passa-baixa de segunda ordem com frequência de corte em 20 Hz aos dados antes da busca pelo início do evento utilizando as funções *butter* e *filtfilt* no MATLAB. A Figura 22 apresenta um conjunto de dados onde à esquerda são ilustrados os gráficos dos obstáculos com frequência de 125 Hz e à direita os mesmos obstáculos filtrados em frequência.


Figura 22 – Comparação entre gráficos originais e filtrados



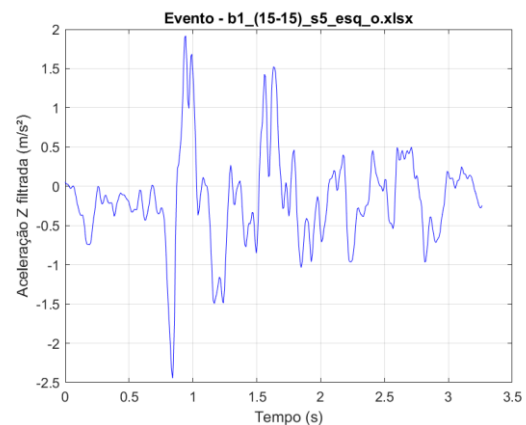
(a) Buraco 1 – Toro – 125 Hz




(b) Buraco 1 – Toro – Sinal filtrado




(c) Buraco 1 – Onix – 125 Hz




(d) Buraco 1 – Onix – Sinal filtrado




(e) Lombada 3 – Onix – 125 Hz



(f) Lombada 3 – Onix – Sinal filtrado



(g) Lombada 3 – Toro – 125 Hz



(h) Lombada 3 – Toro – Sinal filtrado

Fonte: Próprio Autor


Verificou-se que após a aplicação da filtragem em frequência, o nível de ruído diminuiu em dimensões consideráveis e a forma das curvas foi mantida, o que contribui de forma positiva para o estudo. Por outro lado, os valores das amplitudes dos picos e vales das acelerações diminuíram.

Com a filtragem em frequência aplicada a todos os dados do experimento, foi possível, através do MATLAB, detectar automaticamente todos os 309 eventos para o Onix e 288 eventos para a Toro. O código falhou em detectar a presença de evento em apenas três casos para a Toro. A nova taxa de detecção de presença de evento após a aplicação da filtragem em frequência subiu para 99,5%. Para todos os dados em que o evento foi detectado, o ponto onde o código sinalizou o início do evento estava próximo do início real do evento.


5.3. Aplicação das métricas aos dados do estudo

Com o auxílio do MATLAB, após a filtragem em frequência, foram extraídas as quatro métricas citadas na Metodologia – nível RMS, pico global, vale global e inclinação no início do evento – para cada dado do experimento. Para cada métrica, gráficos de dispersão em função da velocidade foram gerados com o objetivo de avaliar a influência dos veículos e dos obstáculos diferentes, mas de mesma classe, nos valores das métricas. A Figura 23 apresenta os gráficos de dispersão do nível RMS em função da velocidade para buracos. As Figuras de A.2 a A.9 (Apêndice A) podem ser consultadas para verificação de todos os gráficos relevantes para esta análise.


Figura 23 – Distribuição do nível RMS em função da velocidade para buracos




(a) Nível RMS Buraco 1



(b) Nível RMS Buraco 2



(c) Nível RMS Buraco 3





(d) Nível RMS categoria buraco

Fonte: Próprio Autor

O comportamento observado nos gráficos da Figura 23 se estende para as demais curvas do estudo. Com base nisso, nota-se que as nuvens de pontos dos gráficos de dispersão dos eventos indicam um padrão que permite considerar que a variação entre veículos é pouco significativa sobre as métricas analisadas. De forma análoga, obstáculos diferentes, mas de mesma classe, podem ser considerados como um único grupo, por exemplo, Buraco 1, Buraco 2 e Buraco 3 foram analisados apenas como eventos da categoria buraco. Essa simplificação contribuiu para a sequência do trabalho, possibilitando a construção de classificadores mais confiáveis. Observou-se ainda que, nos gráficos de dispersão do vale global para tachões e inclinação para buracos a distribuição dos pontos formou uma nuvem mais espalhada. Este fato é ilustrado na Figura 24. Por serem casos isolados, buscando simplificar as regras para desenvolvimento dos classificadores, este fato foi desconsiderado para a continuidade deste trabalho.


Figura 24 – Dispersão espalhada: vale global de tachões e inclinação de buracos



Fonte: Próprio Autor


Por fim, nota-se que, de forma geral, a intensidade das métricas é crescente em função da velocidade. Visando minimizar a sobreposição dos valores das métricas das classes com finalidade de melhorar a eficiência dos classificadores, todos os valores obtidos do cálculo das métricas foram normalizados pela velocidade. O resultado deste processo suavizou a influência da velocidade. A Figura 25 ilustra este fato para os gráficos *boxplot* com os eventos e veículos unificados, onde à esquerda estão apresentados os gráficos antes da normalização e à direita os gráficos com as métricas normalizadas. Nota-se que a normalização pela velocidade implicou em uma redução considerável na distância entre os limites inferior e superior das métricas calculadas para os eventos do experimento.

Figura 25 – Comparação entre as métricas antes e após a normalização




(a) Nível RMS antes da normalização

(b) Nível RMS após a normalização



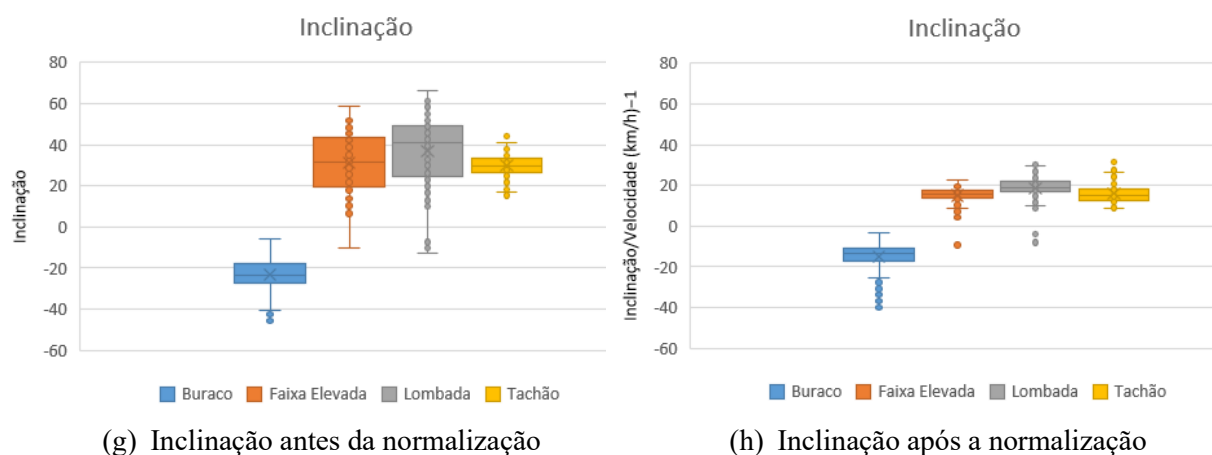
(c) Pico global antes da normalização

(d) Pico global após a normalização



(e) Vale global antes da normalização

(f) Vale global após a normalização



Fonte: Próprio Autor

Tabela 8 – Limiares estatísticos dos *Boxplots* - método *IQR*

Pré normalização								
	LI RMS	LS RMS	LI Pico	LS Pico	LI Vale	LS Vale	LI Inc	LS Inc
Buraco	0.20	1.46	-0.21	6.26	-5.95	-0.13	-40.82	-4.25
Faixa Elevada	-0.40	3.33	-0.49	9.06	-10.51	2.57	-15.90	78.80
Lombada	0.30	4.51	1.97	10.20	-18.00	1.18	-12.78	86.37
Tachão	0.06	2.64	1.07	6.26	-10.80	-0.80	16.22	43.50
Pós normalização								
	LI RMS	LS RMS	LI Pico	LS Pico	LI Vale	LS Vale	LI Inc	LS Inc
Buraco	0.07	0.95	-0.26	4.06	-2.97	-0.78	-25.98	-2.12
Faixa Elevada	0.46	1.06	1.26	3.02	-3.47	-0.57	8.43	23.17
Lombada	0.30	2.17	-1.17	7.90	-6.18	-1.67	9.35	29.14
Tachão	0.07	1.31	0.77	3.09	-6.17	0.12	4.38	26.54

Fonte: Próprio Autor

Conforme observado nos gráficos *boxplot* da Figura 22 e nas informações da Tabela 8, mesmo após a normalização das métricas pela velocidade, ainda há intersecções consideráveis entre as classes para as métricas utilizadas, o que indica sobreposição nas distribuições dos dados.

5.4. Indicadores de desempenho dos classificadores

Diante da dificuldade de separação clara das classes evidenciada nos resultados discutidos anteriormente, optou-se por adotar classificadores multiclasse baseados na distância euclidiana mínima aos centróides de cada classe, conforme citado na metodologia,

utilizando tanto a média quanto a mediana das métricas. Os desempenhos dos classificadores considerando a média e a mediana são apresentados, respectivamente, nas matrizes de confusão das Tabelas 9 e 10.

Tabela 9 – Matriz de confusão do classificador desenvolvido com a distância euclidiana mínima com relação às médias das métricas

		Previsto				Desempenho				
		Buraco	Faixa Elevada	Lombada	Tachão	Sens	Espec	Acur	Prec	F1-Score
R E A L	Buraco	231	0	0	0	100.0%	98.3%	99.0%	97.5%	98.7%
	Faixa Elevada	1	49	19	31	49.0%	85.8%	79.5%	41.5%	45.0%
	Lombada	5	14	105	29	68.6%	88.9%	83.6%	68.6%	68.6%
	Tachão	0	55	29	18	17.6%	89.0%	75.4%	23.1%	20.0%
									Global	58.1%

Fonte: Próprio Autor

Tabela 10 – Matriz de confusão do classificador desenvolvido com a distância euclidiana mínima com relação às medianas das métricas

		Previsto				Desempenho				
		Buraco	Faixa Elevada	Lombada	Tachão	Sens	Espec	Acur	Prec	F1-Score
R E A L	Buraco	231	0	0	0	100.0%	98.3%	99.0%	97.5%	98.7%
	Faixa Elevada	1	38	16	45	38.0%	96.9%	86.9%	71.7%	49.7%
	Lombada	5	8	115	25	75.2%	88.7%	85.2%	70.1%	72.6%
	Tachão	0	7	33	62	60.8%	87.4%	81.2%	47.0%	53.0%
									Global	68.5%

Fonte: Próprio Autor

Observa-se que a dificuldade imposta pela sobreposição dos valores das métricas das classes implicou em desempenhos das classes Faixa Elevada, Lombada e Tachão significativamente mais baixos com relação aos apresentados para a classe Buracos. Nota-se que a classe Buracos apresenta desempenho elevado em todos os indicadores de desempenho para ambas as abordagens: média e mediana. Este fato pode ser associado à característica da métrica inclinação, que contém apenas valores negativos para a classe Buracos, diferente das demais classes que contém valores positivos em quase todos os dados.

Comparando os classificadores, verifica-se que a abordagem utilizando mediana como centróide apresentou desempenho superior em praticamente todos os indicadores e classes, especialmente para Lombada e Tachão. O F1-score global aumentou de 58,1% para 68,5%, o

que representa uma melhora significativa na capacidade geral do classificador em distinguir as classes de eventos. Para a classe Lombada, por exemplo, o F1-score aumentou de 68,6% para 72,6%, enquanto para a classe Tachão o ganho foi ainda mais expressivo, subindo de 20,0% para 53,0%.

Esses resultados indicam que a mediana se mostrou uma melhor medida de centralidade para o conjunto de dados do experimento, possivelmente por ser menos sensível à presença de valores extremos e à dispersão dos dados dentro de cada classe.

Apesar da melhora geral, as classes Faixa Elevada e Tachão continuam apresentando desempenho limitado, com sensibilidade e F1-score relativamente baixos em ambas as abordagens. Isso pode ser atribuído à forte sobreposição dos pontos das métricas das classes Faixa Elevada, Lombada e Tachão, dificultando a separação clara pelo classificador. Mesmo com o uso da mediana, que suaviza o impacto de *outliers* e reduz o efeito do desbalanceamento de classes, a clara separação entre essas classes não ocorreu de forma suficiente com as métricas disponíveis.

Como possibilidade para melhorar a separação entre essas classes, sugere-se para trabalhos futuros a inclusão de novas métricas, como a duração do sinal do evento, que pode oferecer informações adicionais relevantes para diferenciar Faixa Elevada, Lombada e Tachão.

6. Considerações finais

Os objetivos do trabalho foram atingidos, em relação à quantidade de amostras coletadas – 600 amostras entre os dois veículos – e à análise realizada, reforçando, assim como os trabalhos usados como referência, que é possível detectar e identificar as irregularidades presentes nas ruas.

Os resultados apontaram que, para eventos diferentes, porém de mesma classe, as respostas do sistema dinâmico de um veículo para as entradas destes obstáculos podem ser integradas em uma única base de dados para as métricas utilizadas neste trabalho. Conclui-se o mesmo para os dois veículos utilizados no experimento, não foram percebidas variações significativas nos gráficos de dispersão das métricas do projeto em função da velocidade.

A detecção do início e fim do evento através do MATLAB por meio de comparações de nível RMS entre o ruído que antecede o evento e o calculado em janelas flutuantes mostrou-se eficiente para os dez obstáculos, em velocidades entre 8 e 33 km/h, utilizando os dois veículos do trabalho. A aplicação de um filtro passa-baixa ao sinal captado pode ser um ponto positivo do projeto. Na aquisição de dados, a taxa de amostragem depende do *hardware* e *software* do *smartphone*. Em aparelhos de entrada ou intermediários, os valores podem variar bastante e não atingir os 125 Hz utilizados no experimento.

Dada a dificuldade de classificar corretamente os eventos por meio de métricas não mutuamente exclusivas, os indicadores de desempenho mostraram números interessantes, principalmente para classificação da classe Buraco, que é o elemento principal a ser monitorado pelo modelo proposto pelo presente trabalho. Os melhores resultados foram obtidos utilizando a mediana como centróide. O F1-score para a classe Buraco atingiu 98,7% e o F1-score global foi de 68,5%.

Assim como demonstrado por outros estudos presentes na literatura, este trabalho confirma que o uso de *smartphones* para aquisição e análise de dados provenientes das vibrações do veículo ao sofrer o impacto de um obstáculo no pavimento é uma alternativa atraente do ponto de vista prático e oferece boas condições para realizar classificações corretas.

As limitações do projeto incluem:

- Necessidade de fixação do *smartphone* com o eixo z alinhado com o eixo gravitacional;
- Necessidade de detecção da velocidade para normalização das métricas;
- Uso de apenas dois veículos de passeio;
- Aquisição de dados para obstáculos de características físicas semelhantes dentro de suas classes;
- Análise dos dados com métricas no domínio do tempo;
- Uso de um modelo matemático simples para desenvolvimento dos classificadores.

As melhorias propostas para os projetos na mesma linha de pesquisa deste são:

- Uso de GPS para monitorar velocidade e localizar o obstáculo;
- Extinguir a necessidade do alinhamento de um dos eixos do *smartphone* com o eixo gravitacional;
- Incluir outros tipos de irregularidades;
- Considerar a inclusão de veículos de portes diferentes;
- Trabalhar em outros domínios além do domínio do tempo;
- Utilizar Aprendizagem de Máquina para desenvolver classificadores mais robustos.

Referências

AGUIAR, G. B. T.; MARIANO, H. R. P.; RODRIGUES, I. M.; CAMAROTTO, L. C.; CUNHA, W. N. **Gerenciamento de vias urbanas com a utilização do *software* HDM.** Trabalho de Conclusão de Curso (Engenharia Civil) – Escola de Engenharia, Universidade Presbiteriana Mackenzie, São Paulo, 2019.

ALMEIDA, L. C. **Aplicativo para smartphone destinado à medição da irregularidade longitudinal em rodovias.** Dissertação (Mestrado em Engenharia de Transportes) – Departamento de Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, 2018.

CALACHE, D. C. **Caracterização de um acelerômetro baseado em sistemas microeletromecânicos (MEMS).** Trabalho de Conclusão de Curso (Engenharia Elétrica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2013.

CNT. **Anuário CNT do transporte 2022.** Disponível em: <https://anuariodotransporte.cnt.org.br/2022/>. Acesso em: 09 de ago. de 2024.

CTB. **CTB Digital - Código de trânsito brasileiro.** Anexo I. Disponível em https://www.ctbdigital.com.br/arquivos/anexo_I.pdf. Acesso em: 16 de nov. de 2024.

CTB. **CTB Digital - Código de trânsito brasileiro.** Comentário Artigo 60. 2017. Disponível em <https://www.ctbdigital.com.br/comentario/comentario60>. Acesso em: 09 de ago. de 2024.

DADAFSHAR, M. **Accelerometer and Gyroscopes Sensors: Operation, Sensing, and Applications. Analog Devices.** Disponível em: <https://www.analog.com/en/resources/technical-articles/accelerometer-and-gyroscopes-sensors-operation-sensing-and-applications.html>. Acesso em: 24 de nov. de 2024.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification.** 2nd ed. New York: Wiley-Interscience, 2001

FARIAS, B. A.; PEREIRA, D. S.; SPECHT, L. P.; PEGORINI, V.; BISCONSINI, D. R. **Aplicação de dados de smartphones a Sistemas de Informações Geográficas para a avaliação da irregularidade longitudinal de pavimentos.** Revista Técnico-Científica do CREA-PR, p. 1–14, 2023. Disponível em: <https://revistatecie.crea-pr.org.br/index.php/revista/article/view/933>. Acesso em: 15 jul. 2025.

HARIKRISHNAN, M.; VARUN, P. **Vehicle Vibration Signal Processing for Road Surface Monitoring.** *IEEE Sensors Journal*, v. 17, n. 16, p. 13-16, 2017.

HIRPAHUANCA, D. L. **Determinación y Comparación de la Regularidad Superficial del Pavimento de la Carretera Cusco-Urcos, Usando Teléfonos Inteligentes y el Rugosímetro de MERLIN.** Trabalho de Conclusão de Curso (Engenharia Civil) – Universidad Andina del Cusco, Cusco, 2016.

How To Mechatronics. *What is MEMS? Accelerometer, Gyroscope and Magnetometer with Arduino*. Disponível em: <https://howtomechatronics.com/how-it-works/electrical-engineering/mems-accelerator-gyroscope-magnetometer-arduino/>. Acesso em: 29 jul. 2025.

LIMA, G. S. **Detecção de anomalias em pavimentos utilizando sensores inerciais**. Dissertação (Mestrado em Engenharia de Sistemas) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2024.

LUZ, G. B. S. **Estudo da sensibilidade de aplicativos para smartphones na avaliação da irregularidade longitudinal de pavimentos urbanos**. Trabalho de Conclusão de Curso (Engenharia Civil) – Departamento de Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, 2019.

MANZI, C. **Detecção de irregularidades em estradas por meio de dados de acelerômetros de smartphones**. Trabalho de Conclusão de Curso (Engenharia Mecânica) – Departamento de Engenharia Mecânica, Universidade Federal de São Carlos, São Carlos, 2019.

MEDNIS, A.; STRAZDINS, G.; ZVIEDRIS, R.; KANONIRS, G.; SELAVO, L. **Real Time Pothole Detection Using Android Smartphones with Accelerometers**. *International Conference on Distributed Computing in Sensor Systems and Workshops (DCOSS), IEEE*, 2011.

NERY, C. V. M.; FERNANDES, F. H. S.; MOREIRA, A. A.; BRAGA, F. L. **Avaliação das técnicas de classificação MAXVER, MAXVER – ICM e distância mínima euclidiana de acordo com Índice Kappa**. *Revista Brasileira de Geografia Física*, v. 6, n. 2, p. 320–328, 2013.

NEVES, Eduarda A. et al. **Modais de transporte: análise do panorama atual brasileiro e um estudo bibliométrico**. Maceió, 2018. Disponível em: https://abepro.org.br/biblioteca/TN_STP_258_481_35131.pdf. Acesso em: 15 de jul. De 2025.

OPPENHEIM, A. V.; WILLSKY, A. S.; HAMID, N. **Sinais e sistemas**. 2. ed. São Paulo: Pearson Prentice Hall, 2010.

PASSOS, B. T.; PARREIRA, W. D.; FERNANDES, A. M. R.; COMUNELLO, E. **Detecção de buracos em pavimento asfáltico com base em Processamento Digital de Imagens e Deep Learning**. *XII Computer on the Beach, Camboriú*, v. 12, p. 422-427, 2021. Disponível em: <https://periodicos.univali.br/index.php/acotb/article/view/17434>. Acesso em: 14 jul. 2025.

PEREIRA, R. L. **Estudo das técnicas nível global RMS e energia residual para detecção de falhas em engrenagens**. Trabalho de Conclusão de Curso (Engenharia Mecânica) – Departamento de Engenharia Mecânica, Universidade Federal do Ceará, Fortaleza, 2016.

POWERS, D. M. W. *Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation*. *Journal of Machine Learning Technologies*, p. 1557–1581, 2017. Disponível em:

https://www.researchgate.net/publication/220320084_Evaluation_From_precision_recall_and_F-measure_to_ROC_informedness_markedness_and_correlation. Acesso em: 17 jul. 2025.

RAO, S. **Vibrações mecânicas**. 4. ed. São Paulo: Pearson Prentice Hall, 2008.

RODRIGUES, R. S. **Detecção de buracos em estradas: uma abordagem automatizada baseada na transformada wavelet de Haar**. 2019. Dissertação (Mestrado em Ciências da Computação) – Centro de Tecnologia, Universidade Federal de Santa Maria, Santa Maria, 2019.

SANTHIER, A. J.; LUVIZÃO, G. **Análise da irregularidade longitudinal do pavimento por meio de comparação de dois métodos: perfilômetro a laser e aplicativo de smartphone SmartIRI – Estudo de caso SC-355**. *Conhecimento Em Construção*, v.9, p. 7–32, 2022. Disponível em: <https://periodicos.unoesc.edu.br/conheconstr/article/view/30050>. Acesso em: 14 jul. 2025.


SHAEFFER, D. K. *MEMS inertial sensors: A tutorial overview*. *IEEE Communications Magazine*, p. 100–109, 2013.

THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern recognition*. 4th ed. Amsterdam: Academic Press, 2009.


VALETTA, B. D. **Análise da resposta dinâmica de um veículo sob entradas provenientes de irregularidades em estradas usando um modelo de meio carro**. Trabalho de Conclusão de Curso (Engenharia Mecânica) – Departamento de Engenharia Mecânica, Universidade Federal de São Carlos, São Carlos, 2023.

Apêndice A – Gráficos complementares à análise e discussão dos resultados


Figura A.1 – Gráficos da aceleração em z dos obstáculos percorridos




(a) Buraco 1: 10 km/h




(b) Buraco 1: 15 km/h




(c) Buraco 1: 20 km/h




(d) Buraco 2: 10 km/h




(e) Buraco 2: 15 km/h




(f) Buraco 2: 20 km/h




(g) Buraco 3: 10 km/h



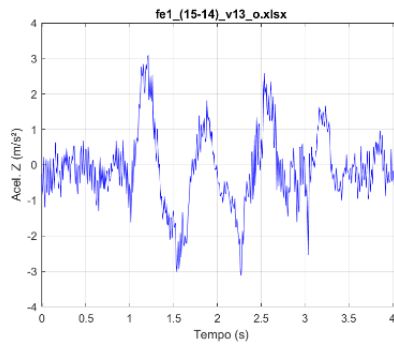
(h) Buraco 3: 15 km/h




(i) Buraco 3: 20 km/h




(j) Faixa Elevada 1: 11 km/h




(k) Faixa Elevada 1: 15 km/h




(l) Faixa Elevada 1: 20 km/h




(m) Faixa Elevada 2: 10 km/h




(n) Faixa Elevada 2: 15 km/h




(o) Faixa Elevada 2: 20 km/h




(p) Lombada 1: 10 km/h




(q) Lombada 1: 15 km/h




(r) Lombada 1: 20 km/h




(s) Lombada 2: 10 km/h




(t) Lombada 2: 15 km/h




(u) Lombada 2: 20 km/h




(v) Lombada 3: 10 km/h




(w) Lombada 3: 15 km/h




(x) Lombada 3: 20 km/h




(y) Tachão 1: 10 km/h




(z) Tachão 1: 15 km/h




(aa) Tachão 1: 20 km/h



(bb) Tachão 2: 9 km/h




(cc) Tachão 2: 15 km/h




(dd) Tachão 2: 20 km/h

Fonte: Próprio Autor


Figura A.2 – Distribuição do nível RMS em função da velocidade para buracos




(e) Nível RMS buraco 1



(f) Nível RMS buraco 2




(g) Nível RMS buraco 3




(h) Nível RMS categoria buraco

Fonte: Próprio Autor


Figura A.3 – Distribuição do nível RMS em função da velocidade para faixas elevadas



(a) Nível RMS faixa elevada 1




(b) Nível RMS faixa elevada 2




(c) Nível RMS categoria faixa elevada

Fonte: Próprio Autor



Figura A.4 – Distribuição do nível RMS em função da velocidade para lombadas



(a) Nível RMS lombada 1






(b) Nível RMS lombada 2



Fonte: Próprio Autor


Figura A.5 – Distribuição do nível RMS em função da velocidade para tachões






Fonte: Próprio Autor

Figura A.6 – Distribuição do pico global em função da velocidade para buracos




Pico Global - Buraco 2




(b) Pico global buraco 2

Pico Global - Buraco 3



(c) Pico global buraco 3


Pico Global - Buraco - Onix + Toro




(d) Pico global categoria buraco

Fonte: Próprio Autor


Figura A.7 – Distribuição do pico global em função da velocidade para faixas elevadas



(a) Pico global faixa elevada 1



(b) Pico global faixa elevada 2




(c) Pico global categoria faixa elevada

Fonte: Próprio Autor


Figura A.8 – Distribuição do pico global em função da velocidade para lombadas

Pico Global - Lombada 1




(a) Pico global lombada 1

Pico Global - Lombada 2




(b) Pico global lombada 2

Pico Global - Lombada 3




(c) Pico global lombada 3




(d) Pico global categoria lombada

Fonte: Próprio Autor


Figura A.9 – Distribuição do pico global em função da velocidade para tachões



(a) Pico global tachão 1




(b) Pico global tachão 2




(c) Pico global categoria tachão

Fonte: Próprio Autor


Figura A.10 – Distribuição do vale global em função da velocidade para buracos




(a) Vale global buraco 1



(b) Vale global buraco 2




(c) Vale global buraco 3




(d) Vale global categoria buraco

Fonte: Próprio Autor


Figura A.11 – Distribuição do vale global em função da velocidade para faixas elevadas



(a) Vale global faixa elevada 1




(b) Vale global faixa elevada 2



(c) Vale global categoria faixa elevada


Fonte: Próprio Autor

Figura A.12 – Distribuição do vale global em função da velocidade para lombadas




(a) Vale global lombada 1

Vale Global - Lombada 2




(b) Vale global lombada 2

Vale Global - Lombada 3



(c) Vale global lombada 3




Vale Global - Lombada - Onix + Toro



(d) Vale global categoria lombada


Fonte: Próprio Autor

Figura A.13 – Distribuição do vale global em função da velocidade para tachões




Fonte: Próprio Autor


Figura A.14 – Distribuição da inclinação em função da velocidade para buracos




(a) Inclinação buraco 1



(b) Inclinação buraco 2




(c) Inclinação buraco 3




(d) Inclinação categoria buraco

Fonte: Próprio Autor

Figura A.15 – Distribuição da inclinação em função da velocidade para faixas elevadas



(a) Inclinação faixa elevada 1



(b) Inclinação faixa elevada 2









Figura A.16 – Distribuição da inclinação em função da velocidade para lombadas






Fonte: Próprio Autor

Figura A.17 – Distribuição da inclinação em função da velocidade para tachões




Inclinação - Tachão 2



(b) Inclinação tachão 2

Inclinação - Tachão - Onix + Toro



(c) Inclinação categoria tachão

Fonte: Próprio Autor