



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES**  
**CURSO DE ENGENHARIA CIVIL**

**LUCAS MOREIRA MAGALHÃES**

**IDENTIFICAÇÃO DA CONDIÇÃO FUNCIONAL DE PAVIMENTOS**  
**URBANOS AUXILIADO POR *MACHINE LEARNING***

**FORTALEZA**

**2019**

LUCAS MOREIRA MAGALHÃES

IDENTIFICAÇÃO DA CONDIÇÃO FUNCIONAL DE PAVIMENTOS URBANOS  
AUXILIADO POR *MACHINE LEARNING*

Trabalho de conclusão de curso apresentada ao Curso de Engenharia Civil do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial para a obtenção do título de Graduado em Engenharia Civil.

Orientador: Prof. Dr. Francisco Heber Lacerda de Oliveira.

FORTALEZA

2019

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

M167i Magalhães, Lucas Moreira.  
Identificação da condição funcional de pavimentos urbanos auxiliado por machine learning / Lucas  
Moreira Magalhães. – 2019.  
87 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia,  
Curso de Engenharia Civil, Fortaleza, 2019.

Orientação: Prof. Dr. Francisco Heber Lacerda de Oliveira.

1. Smartphone. 2. Aprendizado de máquina. 3. Sensores. 4. Pavimento. I. Título.

CDD 620

---

LUCAS MOREIRA MAGALHÃES

IDENTIFICAÇÃO DA CONDIÇÃO FUNCIONAL DE PAVIMENTOS URBANOS  
AUXILIADO POR *MACHINE LEARNING*

Trabalho de conclusão de curso apresentada ao  
Curso de Engenharia Civil do Centro de  
Tecnologia da Universidade Federal do Ceará,  
como requisito parcial para a obtenção do título  
de Graduado em Engenharia Civil.

Aprovada em: 04/12/2019.

BANCA EXAMINADORA

---

Prof. Dr. Francisco Heber Lacerda de Oliveira (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Antônio Paulo de Hollanda Cavalcante  
Universidade Federal do Ceará (UFC)

---

Prof. Msc. Antonia Fabiana Marques Almeida  
Universidade Estadual do Ceará (UFC)

## AGRADECIMENTOS

Primeiramente a Deus, por permitir a conclusão dessa etapa acadêmica e por me assistir em toda a trajetória trilhada.

Aos meus pais, José Antônio e Lúcia, e irmãos, Antônio Filho e Augusto, cuja dedicação na criação e a frequente presença durante todo o caminho até este momento engrandeceram essa conquista.

À Ana Raquel, pela sua querida companhia e por encher de amor e carinho todo momento em que eu estava envolto de ansiedade e inseguranças, por me ajudar a achar forças para continuar onde eu pensava não existir. Muito obrigado por sempre acreditar em mim, mesmo quando nem mesmo eu conseguia, e por comemorar junto a mim cada conquista alcançada.

Ao Prof. Dr. Francisco Heber Lacerda de Oliveira, pela excelente orientação, pelas conversas descontraídas e pelos “cafezinhos” oferecidos, pela paciência de corrigir inúmeros deslizes e falhas presentes em correções preliminares desse documento, e um pedido de desculpa por fazê-lo gastar diversas canetas para corrigir tais deslizes.

Aos meus amigos do grupo “Panelinha”, que sempre pude contar em todo meu período dentro e fora da faculdade, às gargalhadas compartilhadas, a todos os momentos difíceis em que pude encontrar apoio em suas palavras reconfortantes, e faço questão de citá-los todos, a vocês Gabriel Amorim, Renata Sales, Beliza Carvalho, Diego da Ponte, João Lucas, Matheus Pires, David Harley, Jonas Aguiar, Isabel Nibon, Israel Rodrigues, Andrezza Rayanne, Kaio Gefferson, Altanízio e da agregada Aldaianny.

Ao mestrando Pedro Henrique Fontenele Costa Carvalho, por toda a ajuda fornecida em todo processo de execução desse trabalho e que, provavelmente, não teria sido terminado de forma satisfatória sem sua ajuda.

Aos participantes da banca examinadora Prof. Msc Antônio Paulo de Hollanda Cavalcante e Prof. Msc. Antonia Fabiana Marques Almeida por disponibilizarem seu tempo para analisarem esse trabalho e sugerirem as mudanças pertinentes para elevar a qualidade desse.

A todos os professores aos quais tive a honra de ser aluno durante toda a minha trajetória da graduação em engenharia civil, que contribuirão grandemente na minha formação como futuro profissional e como ser humano.

*“O passado é história, o futuro é mistério, o agora é uma dádiva e por isso se  
chama presente.”*

Mestre Oogway.

## RESUMO

A predominância do modo rodoviário no Brasil e seu uso intensivo por parte da população incumbem aos gestores competentes a responsabilidade da manutenção e reabilitação das vias construídas. Contudo, muitos municípios não dispõem de recursos suficientes para a execução de levantamentos de dados para avaliar a atual situação das vias sobre sua jurisdição. Devido às dificuldades financeiras recorrentes em diversas partes do país para com a manutenção de suas vias, este trabalho propõe um modelo de identificação das condições funcionais de pavimentos urbanos, para auxílio nas tomadas de decisões de gestores. O modelo proposto envolve a utilização de um algoritmo de *Machine Learning* não-supervisionado, denominado *k-means*, que, junto ao acelerômetro, giroscópio e receptor do Sistema de Posicionamento Global (GPS - *Global Positioning System*), presente em *smartphones*, geram imagens georeferenciadas que indicam, segundo a segundo, a condição do pavimento interpretada pelo modelo. Os dados de 135 km de trechos na cidade de Fortaleza estudados acerca da aceleração linear, provenientes do acelerômetro, e de aceleração angular, proveniente do giroscópio, foram processados em conjunto com a localização do veículo no momento da levantamento e parâmetros estatísticos obtidos em função dos valores numéricos das acelerações, formando assim quatro agrupamentos rotulados de diferentes tipos de condições do pavimento. Esse modelo tem como um de seus possíveis usos a geração de mapas de situação para auxílio na tomada de decisão de gestores em relação à manutenção e reabilitação de vias. Percebeu-se que o modelo produzido tem o potencial de se tornar uma ferramenta útil a gestores municipais como uma alternativa viável para substituir métodos mais onerosos e demorados, especialmente em locais com ausência ou restrição de recursos financeiros, materiais ou humanos para esse fim.

**Palavras-chaves:** *Smartphone*; Aprendizado de máquina; Sensores; Pavimento.

## ABSTRACT

The predominance of the highway mode in Brazil and its intensive use by the population make the responsible managers responsible for the maintenance and rehabilitation of the built roads. However, many municipalities do not have sufficient resources to perform data surveys to assess the current road situation under their jurisdiction. Due to the recurring financial difficulties in several parts of the country to maintain its roads, this work proposes a model for identifying the functional conditions of urban pavements, to help managers make decisions. The proposed model involves the use of an unsupervised Machine Learning algorithm called k-means, which, together with the accelerometer, gyroscope and receiver of the Global Positioning System (GPS), present in smartphones, generate georeferenced images. which indicate, every second, the condition of the pavement interpreted by the model. Data from 135 km of stretches in the city of Fortaleza studied about linear acceleration from the accelerometer and angular acceleration from the gyroscope were processed in conjunction with the vehicle location at the time of survey and statistical parameters obtained as a function of numerical values of accelerations, thus forming four labeled groupings of different types of pavement conditions. One of its possible uses of this model is the generation of situation maps to help managers make decisions regarding road maintenance and rehabilitation. It was realized that the model produced has the potential to become a useful tool for municipal managers as a viable alternative to replace more costly and time consuming methods, especially in places with no or limited financial, material or human resources for this purpose.

Keywords: Smartphone; Machine Learning; Sensors; App.



## LISTA DE FIGURAS

Figura 1 – Orientação dos eixos de detecção das componentes de aceleração .....	21
Figura 2 – Esquema de funcionamento de acelerômetro micromecânico .....	22
Figura 3 – Estabilização do fator de escala em função da estabilidade de erro bias. ....	24
Figura 4 - Localização das Redes de Monitoramento Contínuo do Brasil.....	26
Figura 5 – Interrelação entre componentes de SIG .....	27
Figura 6 – Smartphones utilizados na pesquisa.....	40
Figura 7 – Suportes e posição dos suportes dentro do veículo.....	41
Figura 8 – Tela do aplicativo Ionic Sensors durante o levantamento de dados .....	43
Figura 9 – Tela do aplicativo para verificação dos sensores do aparelho em repouso.....	44
Figura 10 – Tela do aplicativo para verificação dos sensores do aparelho em movimento. ....	44
Figura 11 – Tela do aplicativo GPS Test, apresentando os satélites do sistema GPS em uso e sua posição.....	45
Figura 12 – Mapa de local de levantamento: Avenida Governador Raul Barbosa .....	53
Figura 13 – Local escolhido para comparação de dados de levantamento.....	54
Figura 14 – Posição dos sinais interpretados para comparação entre suportes .....	55
Figura 15 – Aceleração linear média interpretada nos eixos coordenados dos Suportes 1 e 2	56
Figura 16 – Desvio padrão da aceleração linear interpretada nos eixos coordenados dos Suportes 1 e 2 .....	57
Figura 17 – Aceleração angular média interpretada nos eixos coordenados dos Suportes 1 e 2	58
Figura 18 – Desvio padrão da aceleração angular interpretada nos eixos coordenados dos Suportes 1 e 2 .....	59
Figura 19 – Posição dos sinais interpretados para comparação entre suportes .....	61
Figura 20 – Aceleração linear média interpretada nos eixos coordenados da carga Normal e Sobrecarga .....	62
Figura 21 – Desvio padrão da aceleração linear interpretada nos eixos coordenados da carga Normal e Sobrecarga .....	63
Figura 22 – Desvio padrão da aceleração linear interpretada nos eixos coordenados da carga Normal e Sobrecarga .....	64
Figura 23 – Desvio padrão da aceleração angular interpretada nos eixos coordenados da carga Normal Sobrecarga .....	65
Figura 24 – Local de transição entre padrões de pavimento .....	66

Figura 25 – Posição dos sinais interpretados para comparação entre aparelhos .....	67
Figura 26 – Aceleração linear média interpretada nos eixos coordenados dos Aparelhos 1 e 2 .....	68
Figura 27 – Desvio padrão da aceleração linear interpretada nos eixos coordenados dos Aparelhos 1 e 2 .....	69
Figura 28 – Aceleração angular média interpretada nos eixos coordenados dos Aparelhos 1 e 2 .....	70
Figura 29 – Desvio padrão da aceleração angular interpretada nos eixos coordenados dos Aparelhos 1 e 2 .....	71
Figura 30 – Aproximação à obstrução da via analisada levantamento com o Aparelho 2.....	72
Figura 31 – Teste do cotovelo para o modelo gerado.....	73
Figura 32 – Aplicação do modelo ao elemento 1 do grupo de teste.....	74
Figura 33 – Aplicação do modelo ao elemento 2 do grupo de teste.....	75
Figura 34 – Aplicação do modelo ao elemento 3 do grupo de teste.....	76
Figura 35 – Diferenças entre a identificação de características da via .....	77
Figura 36 – Identificação de mudança de padrão de pavimentação de via .....	78

## LISTA DE GRÁFICOS

Gráfico 1 – Regressão linear para exemplos unidimensionais .....	30
Gráfico 2 – Sobreajuste de modelo.....	30
Gráfico 3 – Influência da quantidade de dados sobre a acurácia de modelos de aprendizado para desambiguação de leitura de texto natural.....	31
Gráfico 4 – Exemplo de aplicação de PCA .....	33
Gráfico 5 – Posicionamento aleatório do centroide dos clusters.....	35
Gráfico 6 – Interação para definição de clusters com menor SSD.....	35

## LISTA DE TABELAS

Tabela 1 – Comparação entre limites de classificação .....	20
Tabela 2 – Categorias de dados brutos interpretados pelos sensores dos <i>smartphones</i> .....	46
Tabela 3 – Características analisadas no modelo preditivo .....	49
Tabela 4 – Classificação dos levantamentos do grupo de teste .....	50
Tabela 5 – Vias escolhidas para levantamento de dados .....	52

## SUMÁRIO

<b>1.</b>	<b>INTRODUÇÃO .....</b>	<b>14</b>
<b>1.1</b>	<b>Considerações iniciais .....</b>	<b>14</b>
<b>1.2</b>	<b>Justificativa .....</b>	<b>16</b>
<b>1.3</b>	<b>Objetivos.....</b>	<b>16</b>
<b>1.4</b>	<b>Estrutura do Trabalho .....</b>	<b>17</b>
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA.....</b>	<b>18</b>
<b>2.1</b>	<b>Pavimentos urbanos .....</b>	<b>18</b>
<b>2.2</b>	<b>Condições e Avaliação Funcional de Pavimentos Urbanos .....</b>	<b>19</b>
<b>2.3</b>	<b>Sensores de <i>smartphones</i> .....</b>	<b>21</b>
<b>2.3.1</b>	<b><i>Acelerômetro</i>.....</b>	<b>21</b>
<b>2.3.2</b>	<b><i>Giroscópio</i>.....</b>	<b>23</b>
<b>2.3.3</b>	<b><i>Sistema de posicionamento global – GPS</i>.....</b>	<b>24</b>
<b>2.4</b>	<b>Machine Learning .....</b>	<b>28</b>
<b>2.4.1</b>	<b><i>Tipos de learning</i>.....</b>	<b>28</b>
<b>2.4.2</b>	<b><i>Influência dos dados em modelos de algoritmos de aprendizado de máquina</i> .....</b>	<b>29</b>
<b>2.4.3</b>	<b><i>Modelos de Machine Learning</i>.....</b>	<b>32</b>
<b>2.5</b>	<b>Uso de sensores em <i>smartphones</i> na identificação de condições de pavimentos .</b>	<b>36</b>
<b>3</b>	<b>MÉTODO DE PESQUISA .....</b>	<b>37</b>
<b>3.1</b>	<b>Resumo do Método .....</b>	<b>37</b>
<b>3.2</b>	<b>Materiais.....</b>	<b>38</b>
<b>3.2.1</b>	<b><i>Veículo</i> .....</b>	<b>38</b>
<b>3.2.2</b>	<b><i>Smartphones</i>.....</b>	<b>39</b>
<b>3.2.3</b>	<b><i>Suportes</i>.....</b>	<b>41</b>
<b>3.2.4</b>	<b><i>Aplicativos</i>.....</b>	<b>42</b>
<b>3.3</b>	<b>Coleta de dados e locais de levantamento .....</b>	<b>46</b>
<b>3.4</b>	<b>Processamento de dados .....</b>	<b>46</b>
<b>3.5</b>	<b>Limpeza de dados (<i>data cleaning</i>) .....</b>	<b>47</b>
<b>3.6</b>	<b>Escala de características (<i>feature scaling</i>).....</b>	<b>48</b>
<b>3.7</b>	<b>Aplicação do modelo .....</b>	<b>50</b>
<b>4.</b>	<b>ANÁLISE DE RESULTADOS.....</b>	<b>51</b>
<b>4.1</b>	<b>Trechos selecionados para levantamento de dados .....</b>	<b>51</b>
<b>4.2</b>	<b>Comparação entre sinais interpretados pelos sensores.....</b>	<b>53</b>

<i>4.2.1</i>	<i>Comparação entre suportes.....</i>	<i>55</i>
<i>4.2.2</i>	<i>Comparação entre cargas.....</i>	<i>60</i>
<i>4.2.3</i>	<i>Comparação entre aparelhos .....</i>	<i>67</i>
<b>4.3</b>	<b>Formação do modelo e aplicação .....</b>	<b>72</b>
<b>5.</b>	<b>CONCLUSÕES E RECOMENDAÇÕES .....</b>	<b>79</b>
<b>5.1</b>	<b>Conclusões.....</b>	<b>79</b>
<b>5.2</b>	<b>Sugestões para trabalhos futuros.....</b>	<b>80</b>
	<b>REFERÊNCIAS .....</b>	<b>82</b>
	<b>APÊNDICE .....</b>	<b>86</b>
	<b>Apêndice A – Mapas dos locais de levantamento e direção de tráfego percorrido .....</b>	<b>86</b>

## 1. INTRODUÇÃO

Este capítulo mostra a abrangência deste Trabalho de Conclusão de Curso e apresenta a importância das condições funcionais do pavimento em vias urbanas, assim como a forma como o *Machine Learning* pode ser implementado na determinação dessas condições. São descritos, também, as considerações iniciais e a justificativa do trabalho, as questões de pesquisa e os objetivos do trabalho, bem como a sua estrutura.

### 1.1 Considerações iniciais

No Brasil existe uma predominância do modo rodoviário na movimentação de cargas e passageiros. Essa situação está aquém do ideal para o desenvolvimento dos transportes, podendo tornar mais onerosa a logística em rodovias de qualidade comprometida, afetando negativamente a economia em diversas partes do País.

O Brasil possui 213.453 km de rodovias pavimentadas, 1.349.939 km de rodovias não-pavimentadas e 157.309 km de rodovias planejadas (CNT, 2018). Dessa forma, têm-se 12,4% de vias pavimentadas em relação à extensão total da malha rodoviária, valor considerado insuficiente ao se observar dados da malha dos EUA, que segundo a FHWA (2015), detém 66,3% de suas rodovias pavimentadas, que representam 2.735.207 km. Ainda, se comparado à malha da Rússia, país de características territoriais e econômicas semelhantes ao Brasil, também se percebe a defasagem na malha rodoviária brasileira. Dados indicam que, dentre o total de 1.452.200 km das rodovias russas, 70,57% são pavimentadas (MEDVEDEV, 2016).

O nível de conservação de uma via pavimentada reflete bastante a segurança, a trafegabilidade e o desempenho dos transportes. Dados do *World Economic Forum* (2018) apontam que o Brasil está na posição 112 de 140 países em relação à qualidade da infraestrutura viária. Esse *ranking* de competitividade global ainda indica que, dentre os países da América do Sul, o Brasil se encontra na última posição dentre os contemplados, com nota menor que Chile, na 24ª posição, e Argentina, na 93ª posição. Esses dados revelam um desafio aos gestores responsáveis pelas rodovias no País em todas as esferas: federal, estadual e municipal.

O conhecimento da condição das rodovias brasileiras é indispensável para uma tomada de decisão acurada quanto ao gerenciamento de recursos destinados à sua manutenção. O não conhecimento dessas condições representa desconhecer problemas de segurança devido a diversos defeitos existentes nos pavimentos e os respectivos custos aos usuários. Um banco de dados amplo permite ao gestor o conhecimento de mais zonas críticas de segurança

rodoviária ao usuário e de vias onde já se tem capacidade de tráfego reduzida, assim, alertando-o da necessidade de intervenções com atividades de manutenção e reabilitação.

Tecnologias associadas ao processo de levantamento de dados são implementadas desde a década passada, como a utilização de GPS (*Global Positioning System*), a fim de tornar mais acurado e reduzir o tempo necessário do levantamento dos dados em campo. A utilização de *tablets*, *notebooks* e *softwares* que representam digitalmente os formulários, outrora físicos, são implementações favoráveis às pesquisas *in situ*, e à produtividade da coleta de dados.

Outra aplicação da tecnologia, que vem se mostrando promissora, é a utilização dos sensores embarcados em *smartphones*, acoplados a veículos de passeio, para identificação de características de pavimentos. Almeida (2018) desenvolveu um aplicativo, o *SmartIRI*, que gera como resultado o cálculo do Índice Internacional de Irregularidade (*International Roughness Index* – IRI) e qualifica o conforto ao rolamento das rodovias, a partir de sensores de um *smartphone*.

O *Machine Learning* é um termo relativamente antigo, com registros iniciais de seu uso feitos a partir de 1959 por cientistas da IBM (*International Business Machine Corporation*) (BURKOV, 2019), tem resultados promissores em sua aplicação nas Engenharias. A empresa Google utiliza essa ferramenta para enviar propagandas diretamente para um público-alvo, através de Redes Neurais Artificiais, uma ferramenta de *Machine Learning*.

No contexto da Engenharia de Transportes, mais especificamente na infraestrutura urbana, constata-se aplicações do *Machine Learning* por Eriksson *et al.* (2008), que utilizaram modelos para identificar buracos, bueiros, curvas, entre outros, utilizando as respostas de sensores embarcados em táxis, como parâmetros de velocidade, aceleração e posição relativa dos veículos utilizados para o levantamento de dados.

Diante do exposto, este Trabalho de Conclusão de Curso propõe a utilização da ferramenta do *Machine Learning* na interpretação de sinais de sensores de *smartphones* para a identificação de condição do pavimento de modo a substituir ou complementar o processo de levantamento de dados de condições funcionais. A implementação de novas tecnologias e ferramentas podem tornar menos dispendiosos, mais rápidos e confiáveis, quanto à condição de pavimentos urbanos, levantamentos de dados em relação aos métodos consagrados, além de inserir, no campo de inovação, a Engenharia de Transportes.



## 1.2 Justificativa

Os efeitos benéficos da manutenção de pavimentos urbanos são conhecidos, tanto do ponto de vista técnico sob os aspectos de segurança e conforto ao rolamento quanto econômico. Porém, na prática, não se percebe uma frequência adequada da manutenção de seus pavimentos pelos gestores responsáveis, culminando em condições insuficientes de trafegabilidade e segurança em pavimentos urbanos, causando desconforto aos passageiros, danos aos veículos e risco de acidentes. Isso pode ser ocasionado pelo desconhecimento da condição atual do pavimento, relacionado ao custo que proporciona aos órgãos devido ao levantamento e armazenamento de dados, bem como a complexidade e o valor de equipamentos envolvidos.

Nesse sentido, percebe-se a necessidade de desenvolvimento e implementação de um método de menor custo, que ofereça maior segurança ao operador, com menor grau de complexidade e eficiência em relação ao tempo. Essa forma de levantamento é almejada por gestores que tem a sua disposição receita limitada para aplicação em atividades de manutenção e reabilitação de pavimentos.

## 1.3 Objetivos

O objetivo geral deste trabalho é identificar condições funcionais de pavimentos urbanos, utilizando leituras de parâmetros dos sensores de *smartphone*, embarcados em veículos, com auxílio do *Machine Learning*.

Como objetivos específicos podem ser listados:

- a) Determinar as características de superfície dos pavimentos urbanos por meio da identificação de condições funcionais auxiliada por *Machine Learning*;
- b) Comparar os padrões de resposta dos sensores de *smartphones* em relação ao tipo de aparelho, condição de carregamento do veículo e suporte utilizado;
- c) Aplicar o modelo não-supervisionado de *Machine Learning* em locais conhecidos e averiguar as semelhanças com o cenário real.

## 1.4 Estrutura do Trabalho

Além desse capítulo introdutório, este trabalho contém mais quatro capítulos, os quais serão descritos a seguir: o Capítulo 2, a Revisão Bibliográfica, contém as descrições de artigos, dissertações, teses e livros necessárias para embasar os objetos de pesquisa, condições funcionais de vias urbanas, as ferramentas computacionais envolvidas na utilização de algoritmos de *Machine Learning*, as definições, tecnologias e usos de sensores de movimento e receptores de sinais embarcados em *smartphones* acoplados à veículos de passeio. O Capítulo 3, o Método de Pesquisa, descreve os materiais e equipamentos utilizados neste trabalho, a forma as quais foram utilizados, a descrição do processo de levantamento de dados em campo, os parâmetros buscados para a seleção de trechos a serem estudados e o método de processamento de dados obtidos. O Capítulo 4, os Resultados e Discussões, apresenta tabelas expondo os processamentos dos dados brutos obtidos dos levantamentos, a aplicação do modelo do algoritmo de *Machine Learning*, *k-means*, para classificação dos dados obtidos em agrupamentos adequados, comparação dos agrupamentos dos sinais interpretados com dados reais de campo e análise dos erros ocorridos no processamento e nos sinais obtidos pelos *smartphones*. O Capítulo 5, as Considerações Finais, são tomadas conclusões sobre todo o processo de pesquisa, e quais propostas para trabalhos futuros foram geradas em torno dessa mesma linha de pesquisa.

## 2 REVISÃO BIBLIOGRÁFICA

Nesse capítulo serão apresentados conceitos do objeto de estudo deste trabalho e de levantamentos de condições funcionais de pavimentos urbanos. Posteriormente, serão abordadas tecnologias associadas ao sistema de levantamento, como sensores móveis associados a *smartphones* e *machine learning* e sensores desses aparelhos para aplicações em engenharia de transportes.

### 2.1 Pavimentos urbanos

Bernucci *et al.* (2010) classificam pavimento como uma estrutura de diversas camadas de espessuras definidas, superpostas, construído sobre a superfície regularizada ou não de terraplanagem, destinado a resistir aos esforços do tráfego de veículos e aos efeitos do clima, propiciando assim condições adequadas de segurança e conforto ao rolamento.

Pavimentos podem ser classificados, quanto à distribuição de tensões de tráfego, em três tipos: flexível, rígido e semi-rígido (HUANG, 2004, *apud* PAIXÃO, CORDEIRO e CORREIA 2017, p.138), com as seguintes características:

- a) Flexível: pela sua menor rigidez, apresenta deformações elásticas significativas sob o carregamento de tráfego aplicado, tendo essa carga uma distribuição em parcelas aproximadamente iguais entre as camadas do pavimento (DNIT, 2006);
- b) Semi-rígido: diferente do pavimento flexível, pavimentos semi-rígidos possuem camadas de base ou sub-base com materiais estabilizados quimicamente. Podem ser do tipo direta ou inversa, dependendo de que camada, base ou sub-base, sendo estabilizada com materiais aglomerantes, como cimento e cal (DER/PR, 2006);
- c) Rígido: ainda segundo DER/PR (2006), um pavimento rígido é constituído por placas de concreto de cimento Portland apoiada sobre camada de material granular ou estabilizada quimicamente, assente sobre um subleito ou reforço de subleito. Devido à rigidez das placas de concreto, a dissipação das pressões verticais advindas do tráfego são bem distribuídas, aliviadas nas camadas abaixo, sub-base ou no reforço de subleito, se houver.

## 2.2 Condições e Avaliação Funcional de Pavimentos Urbanos

A condição funcional do pavimento rodoviário relaciona-se com sua capacidade de atender a função principal de implantação, e de fornecer um grau de serventia em relação à qualidade de rolamento adequada durante todo seu período de serviço (DNIT, 2006).

A serventia, forma de caracterização funcional de pavimentos, define um nível de estado de conforto ao rolamento e segurança e sua relação com a experiência do usuário na sua utilização, o Valor de Serventia Atual (VSA). Essa é uma medida subjetiva, e a classificação dada a cada trecho avaliado depende da percepção do avaliador. Esse procedimento de avaliação subjetiva é normalizado por DNIT (2003a).

O Levantamento Visual Contínuo (LVC) é uma técnica de levantamento de estado de superfície de pavimento que coleta informações de defeitos para preenchimento de formulários, como trincas de classes 1, 2 e 3, diferenciando-as quanto sua severidade e afundamentos de trilha de roda (SILVA *et al.*, 2015). Os defeitos levantados nessa avaliação são: Trincas, diferenciadas em Trincas Isoladas, Trincas Interligadas tipo Jacaré e Trincas Interligadas tipo Bloco, Remendos, Panelas, Afundamento plástico e de Trilhas de Roda, Ondulações, Escorregamento, Exsudação e Desgaste (DNIT, 2003b).

Após a realização de um LVC, são utilizados os de defeitos para definir três diferentes índices de avaliação de condição de pavimento: Índice de Condição dos Pavimentos Flexíveis (ICPF), Índice de Gravidade Global Expedito (IGGE) e Índice do Estado de Superfície do Pavimento (IES) (DNIT, 2003a). Para ICPF e IGGE, utilizam-se tipos específicos de defeitos para o cálculo do índice, sendo que ICPF, variando entre valores de 0 a 5, indica a necessidade de intervenções de reconstrução, manutenção ou conservação rotineira. O IES é um índice composto do ICPF e IGGE que indica a condição do pavimento entre conceitos: Ótimo, Bom, Regular, Ruim e Péssimo (DNIT, 2003b).

Outro parâmetro considerado para avaliar a condição funcional do pavimento é a irregularidade longitudinal. Ela pode ser definida como a irregularidade da superfície do pavimento em relação a uma seção plana de referência ideal, que pode interferir no conforto ao rolamento, drenagem, distribuição do carregamento dinâmico dos veículos e em sua dinâmica (PATERSON, 1987). Essa irregularidade é medida paralelamente ao pavimento, ao longo de uma linha imaginária, que varia de milímetros a centímetros, a depender do equipamento de levantamento (BERNUCCI *et al.*, 2006). Um índice bastante utilizado para mensuração de irregularidade longitudinal é o Índice Internacional de Irregularidade (*International Roughness Index* – IRI).

Proposto pelo Banco Mundial em 1986, o IRI foi desenvolvido após experimentos de correlação realizados no Brasil, denominados de *International Road Roughness Experiment*, com o objetivo de correlacionar e calibrar um modelo padrão de medida de irregularidade (SAYERS, GILLESPIE e QUEIROZ, 1995). O IRI é mais frequentemente utilizado que outros índices de avaliação de serventia (DNIT, 2006). Por ser um índice padronizado e utilizado em diversos países, é usado com frequência como mecanismo de controle e aceitação de obras rodoviárias

O IRI pode ser definido como um índice estatístico que quantifica o desvio da superfície do pavimento implantado em relação ao projetado (BERNUCCI *et al.*, 2006). Segundo Almeida (2018), valores de medição de IRI, dados em m/km, são afetados, de forma crescente, por fatores como: ação do clima, ação da carga dinâmica de tráfego e outros fatores de deterioração da superfície.

Diferentes modelos de desempenho rodoviários, que se aplicam à gerência de pavimentos, classificam a mensuração do IRI de maneiras distintas. Modelos como o programa *Highway Development and Maintenance* (HDM-4), citado por DNIT (2011), o próprio DNIT no Brasil e em outras localidades, como Honduras e Chile, revelam tolerâncias para as condições de trafegabilidade bem distintas. Na Tabela 1 estão listados os limites das escalas de classificação de IRI.

Tabela 1 – Comparação entre limites de classificação

<b>Condições para Tráfego</b>	<b>HDM – 4 (m/km)</b>	<b>DNIT (2011) (m/km)</b>	<b>Honduras (m/km)</b>	<b>Chile (m/km)</b>
<b>Boa</b>	$IRI \leq 2$	$IRI \leq 2$	$IRI \leq 3$	$IRI \leq 3$
<b>Regular</b>	$2 < IRI \leq 4$	$2,7 < IRI \leq 3,5$	$3,5 < IRI \leq 6$	$3,0 < IRI \leq 4$
<b>Ruim</b>	$4 \leq IRI \leq 6$	$3,5 \leq IRI \leq 5,5$	$6 < IRI$	$4 < IRI$
<b>Péssimo</b>	$6 < IRI$	$5,5 < IRI$	-	-

Fonte: Adaptado de Benevides (2006) e Almeida (2018).

## 2.3 Sensores de *smartphones*

A maioria dos *smartphones* mais modernos estão equipados com sensores que captam diversos tipos de sinais, sendo a interpretação desses sinais fundamental para a obtenção de dados relevantes para solução de problemas atuais de engenharia, inclusive a Engenharia de Transportes. Para o propósito deste trabalho, serão descritos sensores que captam sinais necessários, como aceleração, aceleração angular e direções de movimento, para a posterior identificação de condições funcionais de pavimentos urbanos.

### 2.3.1 *Acelerômetro*

Segundo Vieira (2013), acelerômetros podem ser compreendidos como pequenos sistemas mecânicos compostos por capacitores, cuja finalidade são detectar acelerações através do afastamento de placas dos capacitores. A posição de placas e a disposição dos capacitores permitem a determinação da aceleração em três eixos ortogonais entre si, como pode ser observado na Figura 1.


Figura 1 – Orientação dos eixos de detecção das componentes de aceleração



Fonte: Vieira (2013)

Beeby *et al.* (2004) explicam o funcionamento da vasta maioria dos acelerômetros micromecânicos, de tamanho reduzidos, a partir de seus elementos de detecção mecânica sendo baseados em massas de prova fixados por um sistema de suspensão mecânica em uma estrutura-base. A Figura 2 apresenta um esquema da estrutura de um acelerômetro micromecânico.

Figura 2 – Esquema de funcionamento de acelerômetro micromecânico



Fonte: Adaptado de Beeby *et al.* (2004)

Os resultados obtidos das aferições de um acelerômetro micromecânico são acelerações relativas ( $\vec{a}'$ ) a gravidade do local ( $\vec{g}$ ). O estado estacionário do sensor, com a massa de prova em repouso, apenas indica a mensuração do valor  $\vec{g}$  no sentido negativo do eixo y, enquanto qualquer movimentação dessa massa de prova indica alterações nos eixos coordenados correspondentes. Por meio de aplicativos, as variações de aceleração podem gerar resultados de velocidade translacional e posição do sensor, e possui diversas aplicações.

A sensibilidade do sensor é importante para definir pequenas variações de aceleração e detectar movimentação em pequenas escalas, ou de rápida variação. Vieira (2013) indica resoluções de até 0,002 vezes a aceleração da gravidade, a depender da capacidade mecânica do sensor a detecção das vibrações.

### 2.3.2 Giroscópio

De acordo com Verboski (2007, p.18)

O giroscópio é um dispositivo inercial que mede velocidades angulares sem a necessidade de um sistema de referência de coordenadas externo. Sua sensibilidade baseia-se em seu eixo de referência interno, assim os movimentos rotacionais aplicados à sua estrutura são medidos.

Giroscópios são sensores inerciais que se diferenciam de acelerômetros por sua capacidade de detectar a rotação dos eixos coordenados x, y e z. Enquanto acelerômetros mensuram uma vibração para definir acelerações lineares, um giroscópio detecta taxas de conservação do movimento angular em eixos particulares. Dessa forma, diversos tipos de giroscópios ópticos obtêm valores de velocidades angulares ( $\Omega$ ) através da integração de dados de entrada (localização angular), com boa resolução e imunes a acelerações (SANTOS, 2003). Erros nas medições de velocidades angulares estão relacionados à sensibilidade do aparelho ou componente, e à sua acurácia, que envolve a detecção de sinais sem ruídos na informação. Esses parâmetros são inversamente proporcionais, e uma melhoria simultânea requer uma solução mais refinada e, conseqüentemente, mais cara.

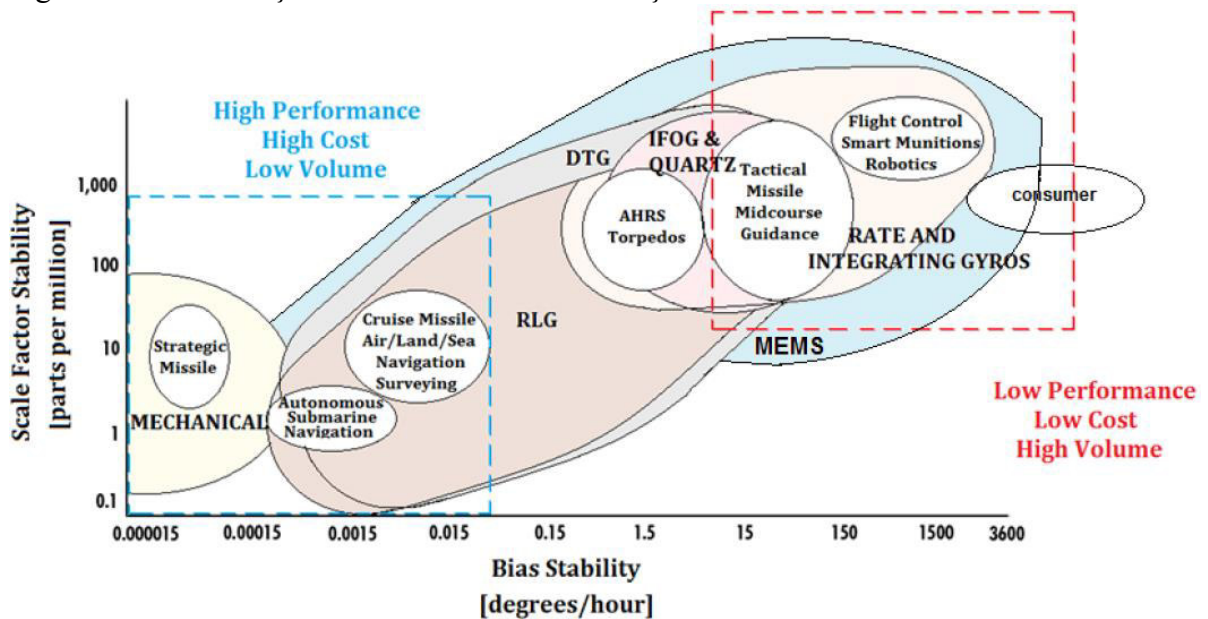
Alguns maquinários utilizam o giroscópio dedicado, como sensores para a determinação de característica de pavimentos. Barella (2007) cita o CHLOE (*Carey, Hutchkins, Lathers and Other Engineers*), um equipamento desenvolvido para o AASHO Road Test (*American Association of State Highway Officials*), que utiliza um giroscópio para a determinação de um plano de referência. Esse plano de referência é utilizado para comparar uma sequência de inclinações geradas por duas rodas ligadas a uma carreta rebocada gerando, como resultado, uma variância da declividade longitudinal da via aferida.

Passaro *et al.* (2017) citam que a miniaturização progressiva da tecnologia dos giroscópios ópticos e vibracionais, em detrimento dos giroscópios mecânicos, de difícil miniaturização, possibilitou sua inserção em diversos produtos que se beneficiaram de suas medições. Os giroscópios do tipo MEMS (*Micro-Electrical-Mechanical Systems*) são giroscópios muito leves e de consumo energético menor que os do tipo FOG (*Fibre-Optic Gyroscope*), dessa forma, tendo um potencial comercial bem maior (CHOI, 2008), e tem miniaturização facilitada quando se abstêm de qualquer tipo de parte rotativa que necessite de rolamentos, dessa forma, geralmente contém elementos de vibração mecânica como parte sensível na detecção de  $\Omega$  (PASSARO *et al.*, 2017).



Ainda segundo Passaro *et al.* (2017), sensores MEMS tem maiores valores de estabilização de fator de escala, que representa uma menor sensibilidade, e um maior estabilidade de qualquer erro viesado, que representa uma menor acurácia, em relação a outras tecnologias de giroscópio ópticos, como RLG (*Ring-Laser Gyroscope*) e FOG. Na Figura 3 está representada uma relação entre a estabilidade do fator de escala e estabilidade para erro viesado e as tecnologias de giroscópio que se enquadram nessas relações.

Figura 3 – Estabilização do fator de escala em função da estabilidade de erro bias.



Fonte: Passaro *et al.* (2017)

### 2.3.3 Sistema de posicionamento global – GPS

Criado pelo Departamento de Defesa dos Estados Unidos (*Department of Defense - DoD*), o Sistema de Posicionamento Global (*The Navstar Global Positioning System - GPS*) substituiu o sistema TRANSIT em 1991, um sistema de levantamento cartográfico concebido inicialmente pela Marinha dos Estados Unidos para localização de navios e aviões militares. Composto por 6 satélites em órbita polar, o TRANSIT tinha dois problemas principais: acurácia relativamente baixa e um tempo de orbita dos satélites de 90 minutos, o que tornava necessário uma interpolação entre os resultados obtidos nas passagens dos satélites (HOFMANN-WELLENHOF; LICHTENEGGER; COLLINS, 2001).

Segundo SILVA (2003), o sistema GPS, ou GNSS (*Global Navigation Satellite System*), possui, atualmente, 24 satélites em atuação e 4 sobressalentes, em 6 órbitas circulares distintas de 12 horas, em 6 planos orbitais inclinados à  $55^\circ$  em relação ao equador. Esse posicionamento permite a recepção de sinais de, pelo menos, 4 satélites ao mesmo tempo em qualquer posição da Terra. Receptores em terra recebem sinais de longitude, latitude e altitude, processadas por dados de distâncias entre o satélite e o receptor ao centro da terra.

Receptores e satélites são equipados com relógios internos para o cálculo de distâncias através do tempo decorridos da emissão e recepção dos sinais (HOFMANN-WELLENHOF; LICHTENEGGER; COLLINS, 2001). Esses relógios, que tem diferenças de construção e valor, estão sujeitos a discrepâncias de mensuração. Essas diferenças são erros sistemáticos, que devem ser considerados para o processo de geolocalização, juntamente com a influência do efeito *doppler* sobre o sinal emitido pelo satélite. Dessa forma, os sinais enviados carregam quatro informações: longitude, latitude, altitude e um erro viesado  $\delta$ , um *bias*, o que torna necessário a presença de quatro ou mais satélites no alcance da inclinação do receptor do sinal.

O uso extensivo do GPS para diversas finalidades comerciais, acadêmicas e sociais tornou evidente a necessidade de um referencial geodésico, um sistema de referência geocêntrico (BERNARDI; LANDIM, 2002). Em 2005, o sistema geodésico Sistema de Referência Geocêntrico para as Américas (SIRGAS-2000) começou a substituir o sistema anterior SAD-69 E SAD-69/96 (*South American Datum*), com fim do período de transição ocorrendo em 2015 (IBGE, 2015).

O SIRGAS-2000 tem como objetivo estabelecer um centro de referência geocêntrica dedicado à América do Sul (BERNARDI; LANDIM, 2002). Centros de processamentos e bancos de dados foram estruturados pelo Brasil para estabelecer uma rede robusta de posicionamento, com diversas estações de monitoramento em tempo real e de pós-processamento de dados, formando a Rede Brasileira de Monitoramento Contínuo dos Sistema GNSS – RBMC. A Figura 4 mostra o posicionamento no território brasileiro das estações.

Figura 4 - Localização das Redes de Monitoramento Contínuo do Brasil.

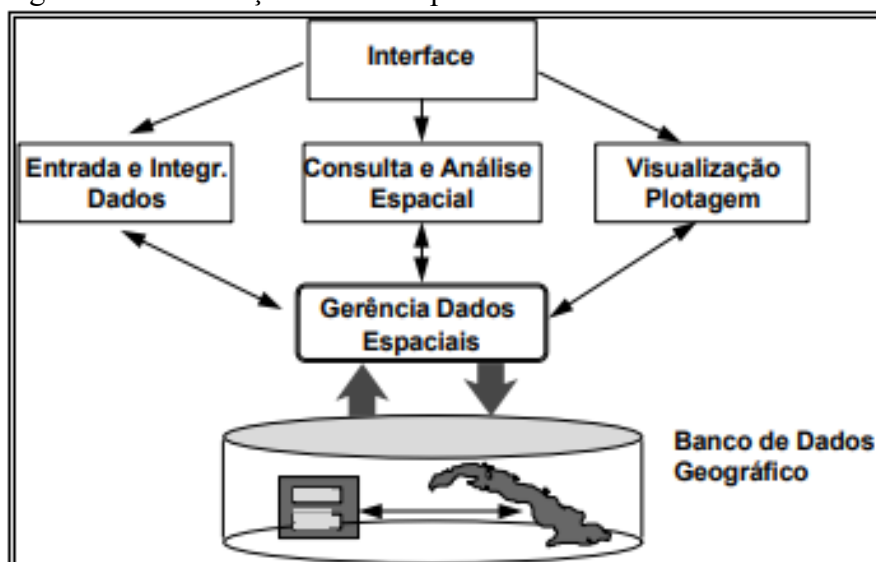


Fonte: IBGE (2017)

Para o uso civil cotidiano, o serviço prestado de GPS chamasse *Standard Positioning Service* – SPS, e é o sinal recebido por receptores de *smartphones*. A precisão desse tipo de serviço é diretamente afetada por *bias* e por erros randômicos (LAVETI *et al.*, 2014). Mesmo com custo reduzido, receptores em celulares recebem sinais de sua geolocalização de forma bastante rápida, não necessitando de minutos para receber sinais de satélites e decodificar as diferentes frequências, devido ao efeito doppler presente nos sinais pela velocidade de movimento dos satélites (DIGGELEN, 2009). Ainda segundo Diggelen (2009), essas velocidades de obtenção da localização se deve ao uso do *Assisted GPS*, ou A-GPS, que utiliza o sinal de torres de telefonia para armazenar o sinal dos satélites, enviando um sinal mais forte e sem interferências e de maneira mais rápida que um satélite, mesmo que esse não esteja de alguma forma bloqueado por barreiras físicas.

A associação da tecnologia do GPS ao Sistema de Informações Georeferenciadas (SIG) é indispensável para a correta representação de dados de localização e posicionamento de pontos de interesse. SIG pode ser definido como um sistema que, através de um banco de dados em meio digital, espacialmente referenciados, visa analisar e converter em informações para usos diversos, como planejamento e gerenciamento (FICCDC, 1998 e SILVA, 2003). A Figura 5 mostra componentes de um SIG, que podem estar presentes ou não, a depender da finalidade de sua aplicação.

Figura 5 – Interrelação entre componentes de SIG



Fonte: Câmara e Ortiz (2006)

## 2.4 Machine Learning

*Machine learning*, ou aprendizado de máquina, é a criação e uso de modelos de interpretação de dados, com objetivo de aprender com os dados de entrada e prevê os resultados (BURKOV, 2015). Esses algoritmos são primeiramente treinados a partir de dados de entrada, chamados de *training data*, para produzir a saída de dados desejada, ou *output*. Dessa forma, a criação de um modelo vai ter como objetivo produzir um *output* pertinente para dados diferente do conjunto de dados de treino na condição desses dados de entrada seguirem uma distribuição estatística similar ao conjunto de treino (BURKOV, 2019).

### 2.4.1 Tipos de learning

Segundo Burkov (2019), podem ser contabilizados três tipos de aprendizados de modelos de *machine learning*, que são:

- a) Aprendizado supervisionado, o conjunto de dados de entrada são etiquetados, com as características das informações em cada dado de entrada sendo as mesmas. Por exemplo, cada dado de entrada teria altura e peso como característica da informação, sempre associados. Como objetivo, o algoritmo busca produzir modelos que recebam esses dados etiquetados e possa fazer previsões diversas;
- b) Aprendizado não-supervisionado, ao contrário do supervisionado, os dados de treino e de entrada são não-etiquetados. Assim, o algoritmo cria modelos para ou agrupar os dados de entradas em grupos ou usá-los separadamente para a obtenção das previsões;
- c) Aprendizado semi-supervisionado contém tanto dados de entrada etiquetados quanto não-etiquetados. O objetivo ainda é o mesmo, produzir um modelo de previsão a partir dos dados recebidos, porém a presença de dados não-etiquetados no grupo de treino deve fazer com que o algoritmo produza um modelo melhor, pois a adição de dados leva a uma melhor reflexão da distribuição probabilística dos dados de entrada. (BURKOV, 2019).

Segundo Géron (2017), aprendizado de máquina ainda pode ser classificado também pelo tipo reforço. Esse tipo de aprendizado, nomeado de agente, se baseia em escolhas de opções para atingir um determinado objetivo, e nas recompensas de cada passo para atingir o objetivo, ou penalidades caso a opção escolhida se afaste do objetivo. Dessa forma, o algoritmo visa obter um caminho ótimo de ação para atingir um objetivo, uma política.

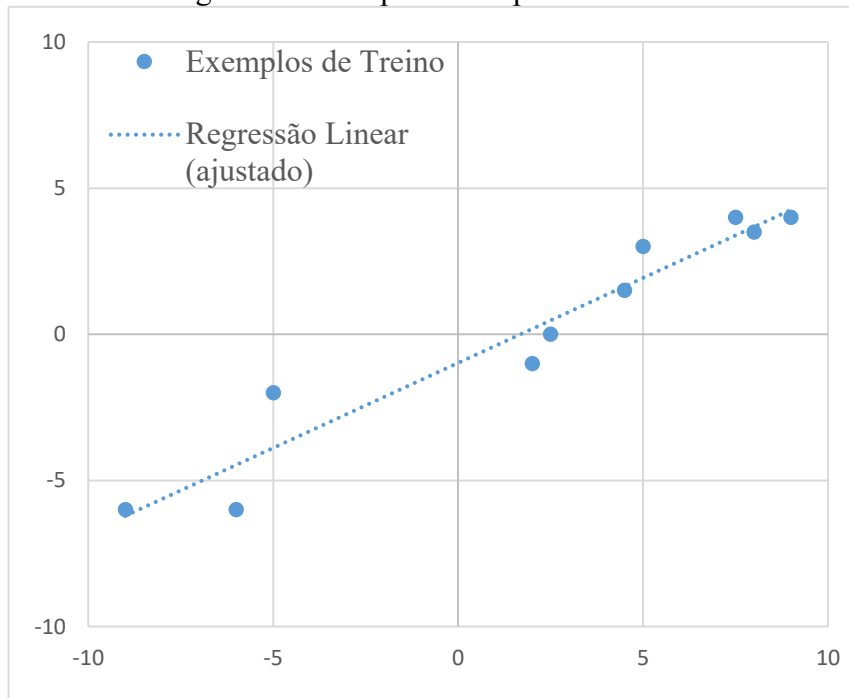
Outra forma de classificar o aprendizado de máquina, além da forma com que é treinado o sistema com as características as quais deseja-se prever, é a forma de generalização que é utilizado para a previsão dessas características. Duas abordagens principais, citados por Géron (2017) são: o aprendizado baseado em instâncias (*instance-based learning*) e o aprendizado baseado em modelos (*model-based learning*).

#### ***2.4.2 Influência dos dados em modelos de algoritmos de aprendizado de máquina***

Para cada tipo de aprendizado de máquina utilizado, os modelos gerados podem sofrer com problemas, como o sobreajuste (*overfitting*) e sub-ajuste (*underfitting*). Sobreajuste é a condição de um modelo a qual ele desempenha bem com os dados do grupo de treino, porém não lida bem com dados novos, não visto durante o treinamento do algoritmo de aprendizado (GRUS, 2015). Isso pode ocorrer por alguns motivos, principalmente quando o modelo é muito complexo para os dados disponibilizados ou há muitas características que se deseja explicação, porém pouco exemplos de treino (BURKOV, 2019).

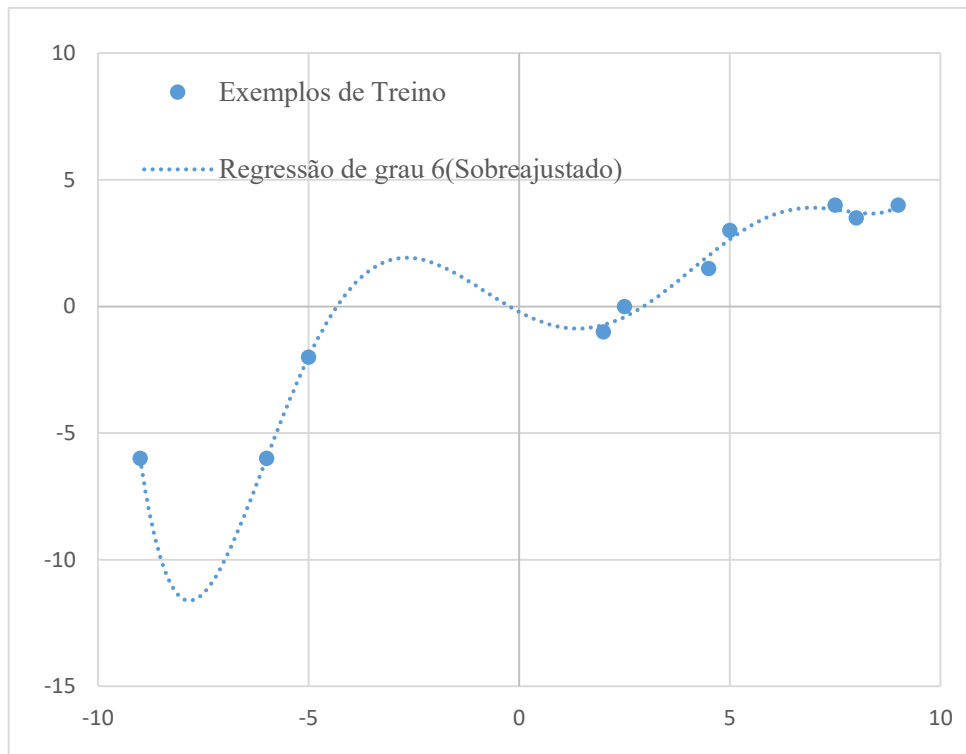
Dados de treino que aderem bem a uma regressão linear podem ser representados por equações de ordens maiores, porém, com o surgimento de novos dados, esse modelo mais complexo pode se mostrar sobreajustado. O Gráfico 1 e Gráfico 2 mostram os mesmos dados, ajustado a diferentes equações explicativas.

Gráfico 1 – Regressão linear para exemplos unidimensionais



Fonte: Adaptado de Burkov (2019)

Gráfico 2 – Sobreajuste de modelo




Fonte: Adaptado de Burkov (2019)

O sub-ajuste produz um modelo que não apresenta com desempenho com os dados disponíveis no treinamento do modelo. Esse problema descreve a incapacidade do modelo de prever bem as etiquetas (*labels*), a caracterização dos dados recebidos, na qual foi treinado. Os principais motivos do sub-ajuste, descritos por Burkov (2019), são:

- a) O modelo é muito simples para os dados disponibilizados;
- b) As características projetadas não são suficientemente informativas.

O problema de quantidade de dados insuficientes é um grande empecilho para a formulação de algoritmos de aprendizado de máquina. Géron (2017) denota a grande quantidade de dados necessários para o funcionamento correto de qualquer algoritmo. Banko e Brill (2001) evidenciam, por meio da comparação entre métodos de aprendizado para desambiguação de leitura de texto natural, como o Perceptron, baseada em memória (*memory-based*) e Naïves Bayes, que esses diversos modos de desambiguação tem uma eficácia semelhantes com uma grande quantidade de dados. Dessa forma, demonstra-se que a eficiência de um modelo pode estar na quantidade de dados utilizados para gerá-lo ou na quantidade de dados utilizados para obter os resultados esperados. No Gráfico 3 é exposta a influência na quantidade de dados na acurácia dos modelos no trabalho de Banko e Brill (2001).

Gráfico 3 – Influência da quantidade de dados sobre a acurácia de modelos de aprendizado para desambiguação de leitura de texto natural



Fonte: Adaptado de Banko e Brill (2001).



Da mesma forma que foi mostrado o efeito dos dados sobre diversos tipos de modelos de aprendizado, é observado, no Gráfico 3, que a qualidade dos modelos em si pode se diferenciar bastante pela quantidade reduzida de dados como *inputs* do sistema.

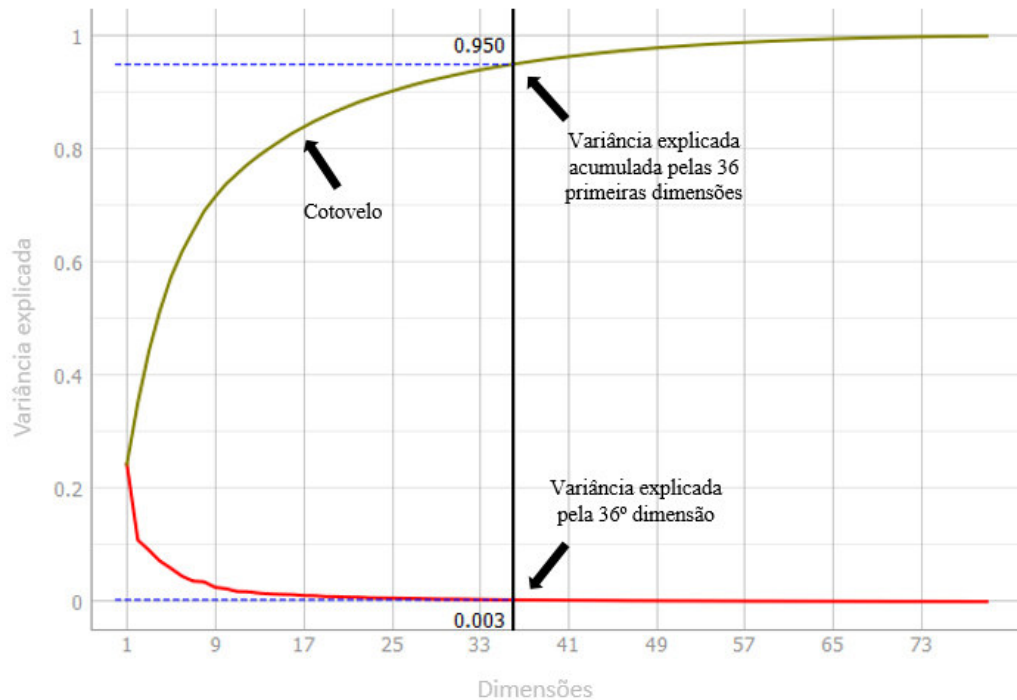
### 2.4.3 Modelos de Machine Learning

Décadas de pesquisa na área do *machine learning* resultaram no desenvolvimento de diversas técnicas novas de aprendizado e aplicações bem-sucedidas dessa ferramenta, como explana Bishop (2012). Um modelo carrega consigo um algoritmo de inferência associado, que são ajustados para as necessidades de uma aplicação particular. Exemplos de algoritmos associados a modelos preditivos são a análise de componentes principais (*Principal Components Analysis – PCA*) e os k-médias (ou *k-means*).

A PCA, proposta originalmente por Karl Pearson, é um algoritmo de redução de dimensionalidade, que busca descobrir como variáveis do grupo de dados numéricos covariam (BRUCE; BRUCE, 2017). Reunindo as variáveis preditoras possivelmente correlacionadas em conjuntos de variáveis linearmente não correlacionadas em um hiperplano de dimensões inferiores, sendo esse um conjunto igual ou menor de variáveis, chamadas de componentes principais, que preservam a quantidade máxima da variância (GERÓN, 2017).

Para a seleção da quantidade de dimensões “ótima” para o PCA, deve-se atentar a taxa de variância explicada de cada componente principal, que indica o quanto as características dos dados são explicadas pela quantidade de componentes principais utilizados, sendo 95% de variância explicada um valor comumente utilizado. Os vetores ortogonais (dessa forma, não correlacionados) dos componentes principais somam a sua variância explicada, dessa forma, preservando a informação trazida pela quantidade original de dados, porém, caso a variância explicada aproxime-se demasiadamente de 100%, os ganhos em visualização das informações e velocidade computacional tornam-se irrelevantes, pois as quantidades de dados associados às características iniciais aproximam-se da quantidade associada aos componentes principais (GERÓN, 2017). O Gráfico 4 representa a variação explicada em relação a aumento das dimensões dos componentes principais.

Gráfico 4 – Exemplo de aplicação de PCA



Fonte: *software* Orange 3

Algoritmos preditivos de agrupamentos, ou *clustering*, são exemplos de aprendizado não-supervisionado bastante utilizados, como o *k-means*, o primeiro algoritmo de *clustering* desenvolvido e ainda usado de forma extensiva pela sua capacidade de trabalhar com grande quantidade de dados e sua relativa simplicidade (BRUCE; BRUCE, 2017). As *k-means* tem como objetivo identificar clusters com valores de entrada (*input*) similares e valores representativos para cada cluster gerado (GRUS, 2015). Nesse algoritmo, a posição dos *clusters* são definidos previamente, de modo que seus dados, tratados como vetores em um espaço de  $d$ -dimensões, resultem em uma mínima soma dos quadrados dentro de *clusters* (*within cluster sum of squares* – WCSS) em relação ao centroide de cada *cluster*. A Equação 1 traz a definição matemática para o WCSS para todos os clusters de um algoritmo de *k-means*.

$$\sum_{i=1}^k \sum_{x \in C_i} \|x - \mu_i\|^2 \quad (1)$$

Onde:

$x$  representa os valores numéricos associados aos vetores do grupo de dados

$\mu_i$  representa os valores numéricos associados ao vetor do centroide


$C_i$  representa o *cluster* do centroide definido

O processo de escolha dos *clusters*, computacionalmente, são interativos, para buscar um valor ótimo da WCSS para o número  $k$  de *clusters* escolhidos. Os centroides dos *clusters* são deslocados para o menor valor do WCSS, porém, esse valor pode ser um ponto ótimo local, não configurando no ponto ótimo global, dessa forma, o método de interação chamado *k-means++* é recomendado. Essa forma de interação tem como princípio a escolha inicial dos centroides dos *clusters* baseados nas distâncias dos *clusters* já escolhidos, ao invés de uma escolha uniformemente ao acaso (ARTHUR; VASSILVITSKII, 2007), sendo a forma de interação padrão em diversas bibliotecas de programação.

A definição do número de *clusters* a serem utilizados em uma classificação também advém de soma de valores quadráticos, mas comumente referidos como Soma dos erros quadráticos, ou erro quadrático total (*total squared error*). O método que se baseia nesses valores para propor uma decisão sobre a quantidade de *clusters* é o “método do cotovelo”. Esse método indica que se use o número de *clusters* indicado por uma curva acentuada em um gráfico, mais um.


Como exposto anteriormente, as interações para a definição do ponto ótimo dos *clusters*, que representa o mínimo SSD (*Sum of Squared Distances*), podem não resultar o menor valor global, mas no menor valor local. Para contornar esse problema, deve-se executar algumas vezes o algoritmo com “chutes” de centroides diferentes, e escolher o que tiver o menor SSD, sendo a posição desses centroides provavelmente os pontos ótimos globais. O Gráfico 5 e Gráfico 6 representam, respectivamente, o posicionamento aleatório do centroide do *cluster* em um grupo de dados bidimensional e uma interação para determinação do ponto ótimo global de centroides de *clusters* de *k-means*.

Gráfico 5 – Posicionamento aleatório do centroide dos clusters



Fonte: *software* Orange 3

Gráfico 6 – Interação para definição de clusters com menor SSD



Fonte: *software* Orange 3.

## 2.5 Uso de sensores em *smartphones* na identificação de condições de pavimentos

A utilização de sensores de *smartphones* para verificação de condições funcionais de pavimentos rodoviários e urbanos já é linha de pesquisa de vários pesquisadores, com diversas abordagens para o seu uso. Biscosini (2016) evidencia o uso de *smartphones* em avaliação funcional, por vários pesquisadores, devido ao baixo custo envolvido, ter boa produtividade e não requerer mão-de obra especializada.

Um trabalho de Sattar *et al.* (2018) compilou diversos trabalhos relacionados a monitoramento de vias utilizando sensores de *smartphones*. Esse trabalho evidencia os passos tomados por diversos autores, como decisões tomadas em pré-processamento e seleção de sensores para tipos de levantamentos de dados diferentes, assim como métodos de pesquisa semelhantes. Ainda, são expostos 3 principais tipos de abordagem de processamento de dados: limiares (*threshold*), *machine learning* e *Dynamic Time Wrapping* (DTW).

Bhoraskar *et al.* (2012) desenvolveram o *Wolverine*, um método de utilizar sensores de *smartphones* para monitoramento de estado de tráfego. Baseia-se em obter dados de acelerômetros para, após criar um modelo com algoritmos de *machine learning*, especificamente *k-means* e máquina de suporte de vetores (*Support Vector Machine* – SVM), caracterizar uma via *bumpy*, onde há características que afetam negativamente o conforto ao rolamento, ou em suave (*smooth*) e detectar frenagem. Zonas com alta detecção de frenagem foram associadas a congestionamento de via pelo *Wolverine*.

Outros sistemas propõem a detecção de defeitos específicos no pavimento, como panelas, com a utilização de *smartphones* para coleta de dados. Mohan *et al.* (2008) propõem o sistema Nericell, que utiliza sensores como microfone, acelerômetro e GPS para a detecção de buracos, frenagens e solavanco sofridos pelo veículo onde está embarcado o *smartphone*, com uma abordagem do tipo *threshold*.

Pesquisas conduzidas no Brasil, como Biscosini (2016) e Almeida (2018), propuseram a utilização de *smartphones* como opção a métodos específicos e mais caros, como *Falling Weight Deflectometer* (FWD) e perfilômetros a *laser*, para a avaliação da irregularidade longitudinal de rodovias. O método consiste na formação de um modelo que, em associação de um aplicativo desenvolvido para esse fim, o SmartIRI, possibilita a informação em tempo real do IRI da via trafegada e sua localização, através do uso de dados provenientes de acelerômetros e receptor de sinal.

### 3 MÉTODO DE PESQUISA

Neste capítulo são descritos os procedimentos para a coleta de dados de sinais de sensores de *smartphone* em flexíveis e calçamento em pedra paralelepipedal, selecionados para esta pesquisa, os equipamentos utilizados para a realização dos levantamentos, as etapas de processamento de dados e o uso de um modelo de algoritmo de *machine learning* não-supervisionado.

#### 3.1 Resumo do Método

As etapas do método realizadas para esta pesquisa foram:

- a) Utilização de um aplicativo para registrar, na memória interna dos *smartphones*, dados de sinais interpretados pelos sensores embutidos nos aparelhos, como aceleração, velocidade, orientação e localização dos dispositivos em todos os eixos coordenados;
- b) Escolha dos trechos urbanos levantados, com análise dos possíveis tipos de respostas recebidas pelos sensores dos *smartphones*, por meio de observação preliminar dos trechos por visita ao local;
- c) Levantamento de dados de condições funcionais de pavimentos urbanos por meio de aplicativo de *smartphones*, embarcados em veículo automotor, com gravação simultânea de vídeo como auxílio à etapa de interpretação dos resultados;
- d) Utilização de um código computacional do algoritmo de aprendizado não-supervisionado, *k-means*, disponibilizado por Carvalho, Oliveira e Reis (2019), com o agrupamento de dados e rotulação dos agrupamentos necessários, com tipologias dos pavimentos urbanos e interferências (panelas, lombadas, etc.) apresentadas nos trechos selecionados;
- e) Processamento de novos dados de campo coletados por *smartphones* embarcados em um veículo, com o modelo desenvolvido utilizado na etapa anterior, comparando os resultados (*outputs*) do algoritmo com as condições reais de pavimentos urbanos por meio de vídeo, com posterior geração de um mapa de características dos trechos estudados em Sistema de Informação Geográfica (SIG).

## 3.2 Materiais

Neste tópico, apresentam-se os equipamentos definidos que viabilizaram os levantamentos de dados para a pesquisa, incluindo as condições físicas e características avaliadas para a sua forma de uso no decorrer do método de pesquisa.

### 3.2.1 Veículo

O veículo utilizado para a coleta de dados foi um modelo Yaris, marca Toyota, motor 1.5, ano 2019. Para minimizar qualquer acréscimo de erros aleatórios nas leituras devido às condições mecânicas do veículo, houve análise no alinhamento das rodas e revisão geral da parte mecânica, cedida pela concessionária onde o veículo foi adquirido. A calibração das rodas foi feita sob pressão de 30 psi para as rodas traseiras e 32 psi para as rodas dianteiras, conforme indicado pelo manual veicular.

Os levantamentos foram executados de forma duplicada, com uma variação da carga transportada pelo veículo utilizado por meio do acréscimo do número de ocupantes, para determinar, de forma preliminar, a influência desse carregamento adicional sobre os resultados de levantamento obtidos.

As coletas de dados foram efetuadas com um e cinco ocupantes presentes no veículo, e essas situações de carregamento foram diferenciadas da seguinte forma: normal, para a carga apenas do motorista, e carregado, para a situação de quatro ocupantes extras e o motorista. As influências da variação no peso do veículo sobre os dados levantados, devido ao consumo de combustível, não foram analisadas, devido à dificuldade da mensuração exata da variação de volume durante o trajeto percorrido. Para minimizar os possíveis erros advindos dessa variação, todos os levantamentos foram feitos com 50 % ou mais da capacidade do tanque de combustível do veículo, como uma forma de controlar o peso do veículo durante os levantamentos.

### 3.2.2 Smartphones

As coletas de dados foram efetuadas utilizando dois modelos distintos de *smartphones*. Esses aparelhos são dos modelos Xiaomi Mi 9 e Motorola Moto Z2 Force, que serão referidos como Aparelho 1 e Aparelho2 (A1 e A2), respectivamente. Optou-se por esses modelos pela sua disponibilidade imediata para os levantamentos e por suas capacidades de processamento elevadas. Ambos os aparelhos apresentaram recepção satisfatória de sinal de GPS, com acesso continuado ao sinal de 4 satélites ou mais. Dessa forma, as coordenadas geográficas fornecidas possuíam precisão satisfatória e representavam, com grau elevado de confiança, os trechos levantados durante a pesquisa.

Ambos os dispositivos possuíam os sensores de movimento (giroscópio e acelerômetro) para coletas de dados de valores de aceleração, velocidade e orientação dos dispositivos em todos os eixos coordenados (X, Y e Z). A taxa de coleta dos dispositivos foi fixada em 20 Hz, que é a frequência de coleta do aplicativo utilizado para os levantamentos.

Um terceiro *smartphone*, de modelo Motorola Moto G7, foi incluído nos levantamentos para gravação de vídeos dos levantamentos, com finalidade de auxiliar na análise dos resultados, comparando-se o estado atual da via e o resultado obtido pela aplicação do modelo de identificação de condições do pavimento pelo algoritmo de aprendizado não-supervisionado *K-means*. A Figura 6 expõe os smartphones utilizados por essa pesquisa.



Figura 6 – Smartphones utilizados na pesquisa



a) Smartphone Motorola Moto Z2 Force



b) Smartphone Xiaomi Mi 9



c) Smartphone Motorola Moto G7

### 3.2.3 Suportes

Os *smartphones* utilizados foram fixados à parte interna do para-brisa do veículo por meio de suportes veiculares, que tinham como objetivo transmitir as vibrações resultante da interação do veículo com o pavimento e evitar problemas nos sinais interpretados pelo *smartphone* devido à falta de qualquer fixação do aparelho ao veículo.


Os suportes veiculares utilizados foram do tipo *car mount*, um de modelo *Wireless Car Charger*, de marca Xiaomi, que será referido como Suporte 1, ou S1, e dois modelos sem marca definida, um utilizado em conjunto com o Suporte 1 no levantamento de dados dos sensores, referido como Suporte 2, ou S2, e um para filmagens dos levantamentos.

O posicionamento dos suportes no veículo foi preferencialmente no centro do para-brisa dianteiro, para evitar influência das vibrações em relação ao eixo central do veículo sobre os sinais interpretados pelos sensores dos *smartphones*. A Figura 7 apresenta os suportes veiculares utilizados nos levantamentos.

Figura 7 – Suportes e posição dos suportes dentro do veículo



(a) Da esquerda para a direita: Suporte 2 e suporte para filmagem  
Fonte: O autor



(b) Suporte 1

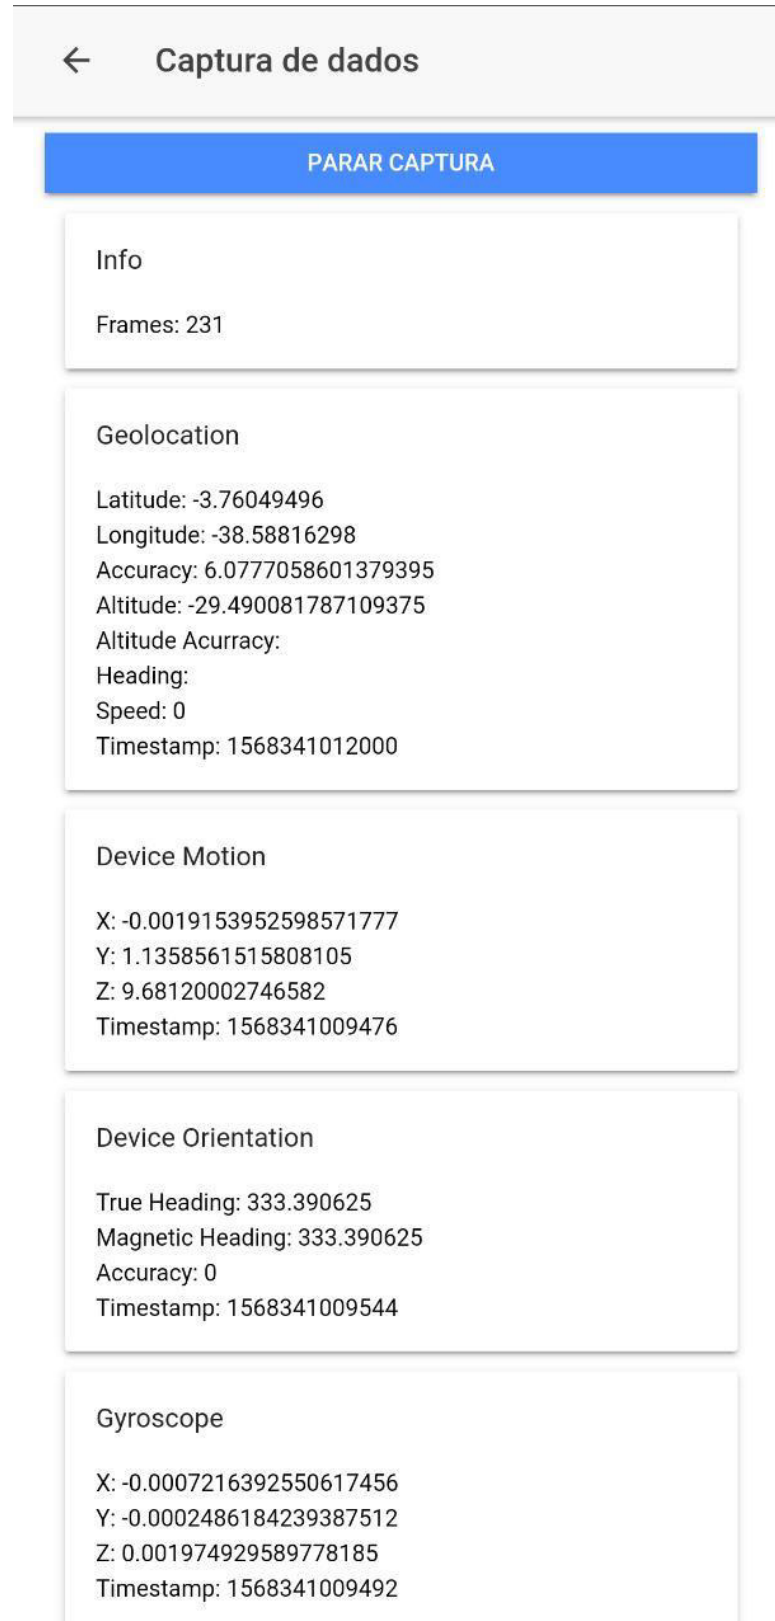
### 3.2.4 Aplicativos

O aplicativo utilizado para a captura de sinais dos sensores dos *smartphones* foi o *Ionic Sensors*, coletando de forma simultânea os dados de *output* interpretados pelos sensores e armazenando-os na memória dos *smartphones*. O aplicativo é capaz de capturar os sinais de GNSS, acelerômetro e giroscópio embarcados em *smartphones*, com saída de dados em formato *.csv* (*comma separated values*) de planilhas eletrônicas.

A frequência de aquisição de dados fixado pelo aplicativo *Ionic Sensors* foi de 20 Hz, que foi suficiente para gerar entradas de dados satisfatórias e consumo reduzido de bateria do aparelho pelo aplicativo, prevenindo aquecimento excessivo dos *smartphones* utilizados durante os levantamentos, o que poderia prejudicar o funcionamento do aparelho e inviabilizar algum levantamento pelo travamento do sistema ou dos sensores utilizados. A Figura 8 expõe a tela de exibição do aplicativo de coleta, mostrando informações em tempo real dos sinais recebidos pelo aparelho.

Outro aplicativo utilizado, porém, antes de cada levantamento de dados, foi o *SensorLab* e o *GPS Test*. O *SensorLab* é um aplicativo que teve como finalidade analisar o funcionamento dos sensores embarcados no aparelho, pois uma coleta de dados com falhas nos sensores pode criar de dados em valores potencialmente essenciais ao posterior processamento, como dados do acelerômetro ou giroscópio.

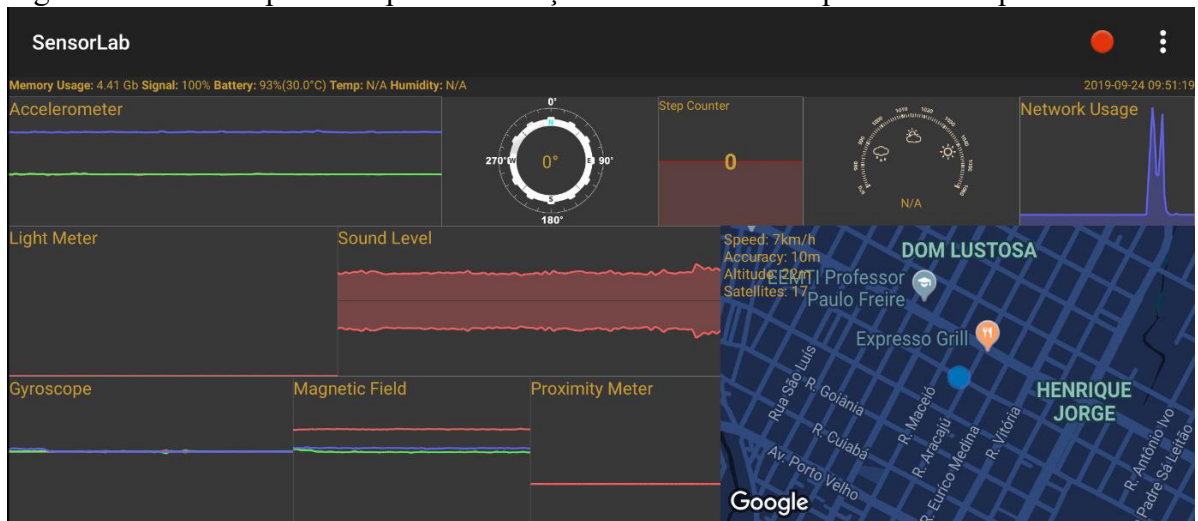
Figura 8 – Tela do aplicativo *Ionic Sensors* durante o levantamento de dados



Fonte: O autor

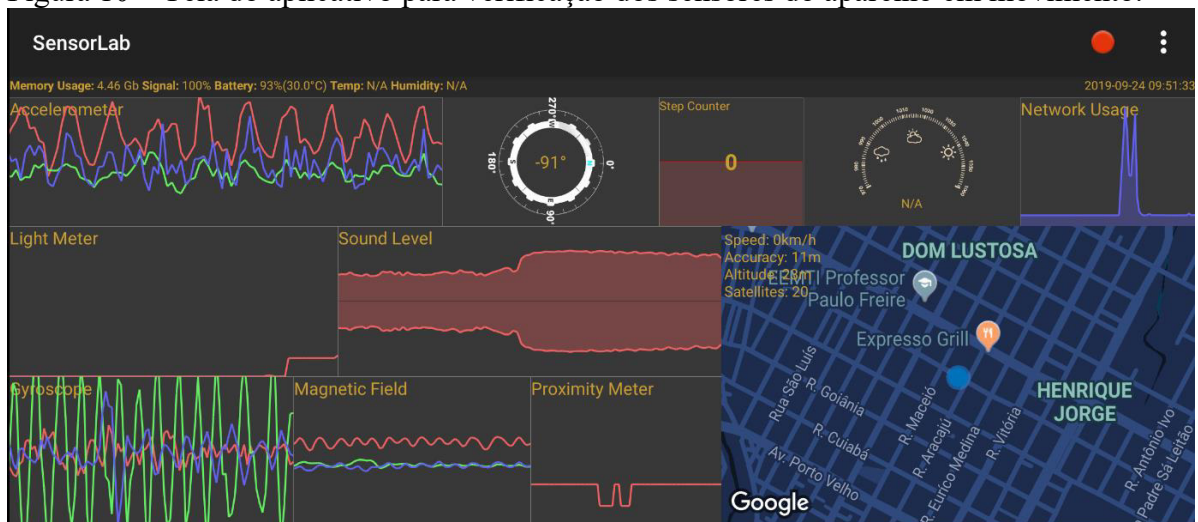
Os dois *smartphones* utilizados foram comparados diretamente por meio do *SensorLab* para verificar a orientação pela função Bússola (*Compass*), valores de aceleração pela função Acelerômetro (*Accelerometer*) e as velocidades angulares pela função Giroscópio (*Gyroscope*) e a posição geográfica através da função GPS. A Figura 9 e Figura 10 mostram a tela de exibição do aplicativo de verificação dos sensores, expondo todas as funções disponíveis simultaneamente.

Figura 9 – Tela do aplicativo para verificação dos sensores do aparelho em repouso.



Fonte: O autor

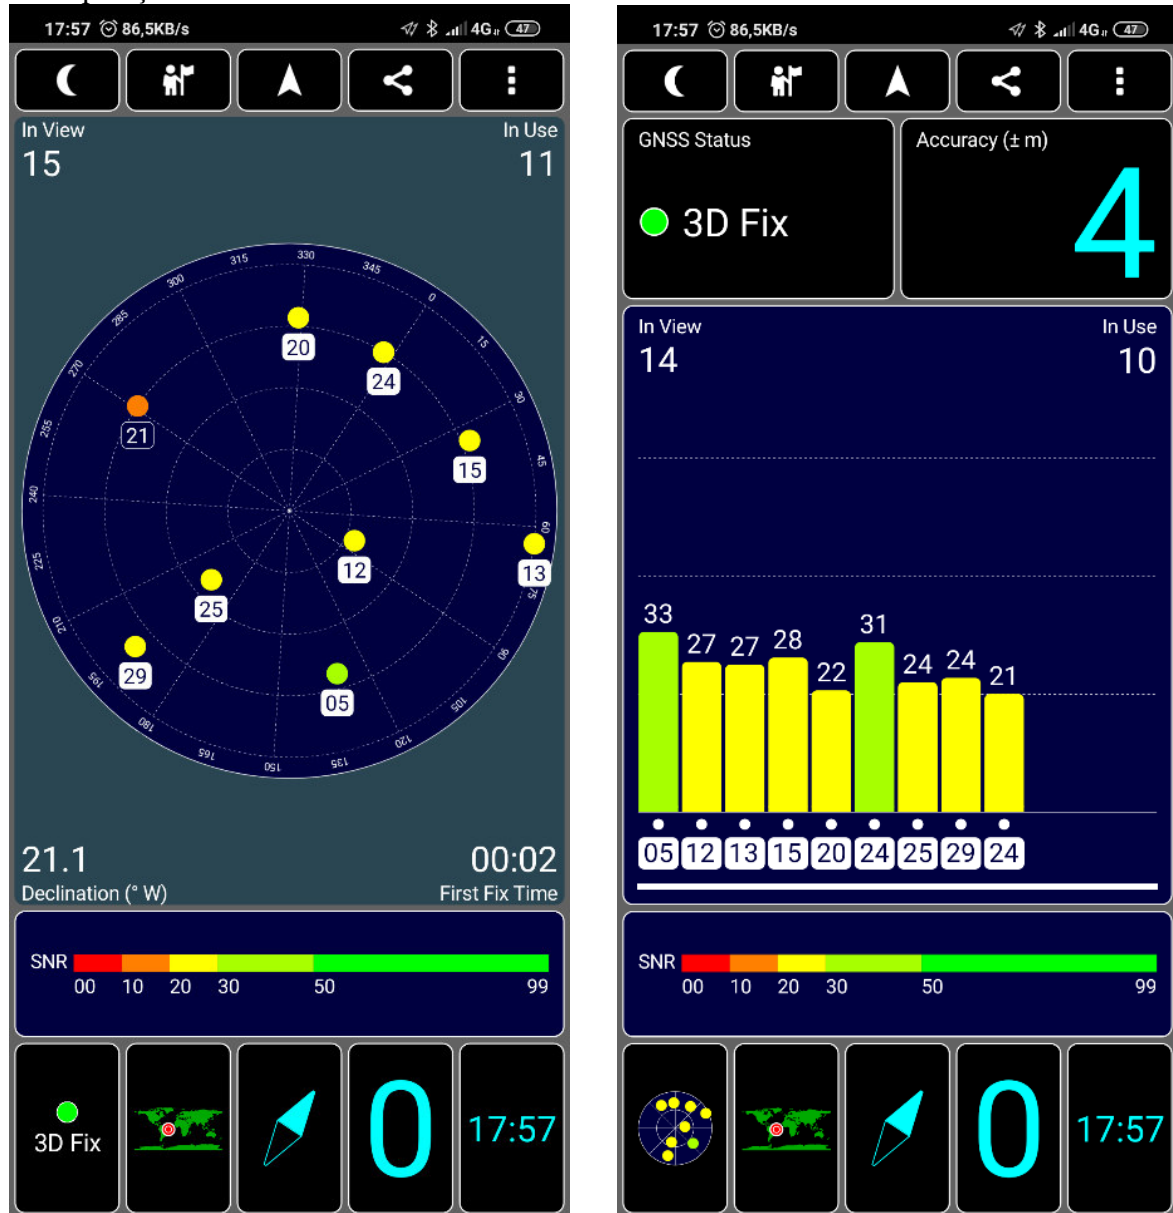
Figura 10 – Tela do aplicativo para verificação dos sensores do aparelho em movimento.



Fonte: O autor

O aplicativo *GPS Test* foi utilizado para a verificação da recepção de sinal de GPS para ambos os aparelhos *smartphone*, auxiliando na identificação da ocorrência da quantidade mínima de satélites (quatro) para a obtenção da localização com precisão. A Figura 11 indica a tela inicial do aplicativo e seu funcionamento.

Figura 11 – Tela do aplicativo GPS Test, apresentando os satélites do sistema GPS em uso e sua posição.



Fonte: O autor



### 3.3 Coleta de dados e locais de levantamento

Antes do início de cada coleta, certificou-se que os dois *smartphones* tinham seus sensores operantes, para evitar qualquer perda de dados e inviabilizar o processamento de dados posteriormente. Os posicionamentos iniciais dos suportes veiculares foram ajustados para permanecerem na posição mais verticalizada possível durante os levantamentos, de modo a evitar a alteração do posicionamento durante o processo, causando possíveis erros nas leituras.

Os suportes para os *smartphones* foram posicionados mais próximo ao centro do para-brisas do veículo, para evitar qualquer variação da recepção dos sinais devido a movimentações em relação ao eixo do veículo, ou interferências na via que a pode afetar de forma diferenciada um dos lados do veículo, como painéis, e comprometer a comparação dos dados levantados pela diferença dos dados interpretados pelos sensores dos *smartphones* nos diferentes suportes. Mapas dos locais de coletas foram gerados para ilustrar a posição em relação a cidade de Fortaleza e a direção do tráfego da via escolhida.

### 3.4 Processamento de dados

Após a coleta, os dados foram exportados da memória interna do *smartphone* para um dispositivo externo e convertidos para uma planilha (*dataframe*) para que, além da visualização dos dados dentro do ambiente de trabalho de programação, em linguagem Python, seja possível a visualização em um *software* externo a esse ambiente. A Tabela 2 expõe os tipos de dados brutos obtidos pelo aplicativo após um levantamento de dados.

Tabela 2 – Categorias de dados brutos interpretados pelos sensores dos *smartphones*

Sensor	Leitura
Acelerômetro	Dm <sub>x</sub> , Dm <sub>y</sub> , Dm <sub>z</sub> , Dm Timestamp
Giroscópio	Gy <sub>x</sub> , Gy <sub>y</sub> , Gy <sub>z</sub> , Gy Timestamp
GPS	Geolocation Spd, Geolocation Longitude, Geolocation Latitude

Fonte: O autor

Na Tabela 2, os dados representados como de Dm são o *device motion*, sendo isso a aceleração linear obtido pelo acelerômetro. Já o Gy representa a aceleração angular obtido pelo giroscópio do *smartphone*. As informações obtidas através do receptor GPS foram a

latitude e longitude do aparelho e a velocidade desse calculado pelo deslocamento em relação aos dados anteriores de longitude e latitude e o tempo decorrido para o deslocamento.

### 3.5 Limpeza de dados (*data cleaning*)

Após a exportação dos dados, fez uma limpeza e tratamento dos dados, ou higienização, para que esses estejam de forma a serem aceitos como entrada para o modelo utilizado. Primeiramente, são removidas as células sem dados numéricos, representados no *dataframe* como *NaN*, ou *not a number* (não é um número), que indica que aquele quadro da captura não registrou o valor detectado pelos sensores, tendo sua linha de dados excluída.

Linhas associadas a velocidades menores que 10km/h foram excluídas, pois os processos de acelerações a partir do repouso do veículo e frenagens para parada foram recorrentes nessa faixa de velocidade, e afetavam a interpretação dos resultados obtidos pelos sensores. Para manter o máximo de dados intactos possível, todo levantamento que teve mais de 10% de suas linhas excluídas por conterem *NaN* foram descartadas, e um novo levantamento foi executado.

Com a arquivo de dados sem células registradas como *NaN*, novos parâmetros foram calculados e adicionados ao *dataframe*, como novas características para o modelo. Para cada parâmetro calculado, utilizou-se uma série temporal de 20 registros (ou frames), que corresponde à frequência de captura do aplicativo utilizado, sendo esse agrupamento de 20 registros chamados de janelas. Janelas representam séries temporais de 1 segundo de dados interpretados pelos sensores, e seus valores numéricos são a média dos *frames* que os compõem. Dessa forma, o valor de cada parâmetro adicionado representa a média desse parâmetro em cada janela de dados correspondente. Os parâmetros adicionados foram:

- a) Desvio padrão;
- b) Variância;
- c) Coeficiente de correlação de Pearson das acelerações lineares.
- d) Resultante de acelerações lineares (*Device Motion Resultant*).

O coeficiente de correlação de Pearson é uma variante padronizada útil, que oferece uma estimativa de correlação, positiva ou negativa, entre duas variáveis em uma mesma escala (BRUCE; BRUCE, 2017). Essa nova característica foi escolhida para compor a base de dados pois pode fornecer informações importantes sobre as alterações de padrões da via analisada,



como a passagem de um padrão em concreto asfáltico para um em pedra poliédrica, por exemplo. O valor numérico do coeficiente de correlação de Pearson é dado pela Equação 2.

$$r = \frac{\sum_{i=1}^N (x_i - \bar{x}) \cdot (y_i - \bar{y})}{(N - 1) \cdot s_x \cdot s_y} \quad (2)$$

Onde:

$r$ : Coeficiente de correlação de Pearson

$x - \bar{x}$ ,  $y - \bar{y}$ : Desvio da média

$N$ : Número de elementos

$s_{x,y}$ : Desvio padrão

Outro preditor adicionado para compor a base de dados foi a resultante de acelerações lineares interpretadas pelo acelerômetro, calculada pela Equação 3.

$$DM_R = \sqrt{(DM_x)^2 + (DM_y)^2 + (DM_z)^2} \quad (3)$$

Onde:

$DM_R$ : Aceleração linear resultante

$DM_{x,y,z}$ : Aceleração linear nos eixos coordenados

### 3.6 Escala de características (*feature scaling*)

Após a adição dos novos parâmetros preditivos ao *dataframe*, os dados não relacionados ao tempo (*timestamp*) e localização (longitude e latitude) passam por uma padronização (*standardization*), para que o alcance dos dados seja reduzido. Por exemplo, o valor numérico da velocidade tem grandeza maior que valores de aceleração linear do acelerômetro (*device motion X, Y e Z*) e angular do giroscópio (*gyroscope X, Y e Z*), afetando negativamente o modelo utilizado. A padronização de valores de um grupo de dados qualquer é calculada pela Equação 4.

$$z = \frac{x - \mu}{\sigma} \quad (4)$$

Onde:

$z$ : valor padronizado

$x$ : valor à ser padronizado

$\mu$ : média numérica da característica

$\sigma$ : Desvio padrão da característica

O processo de padronização foi preferido ao de normalização de dados (*normalization*) por *Min-Max scaling* pois esse processo, tendo uma alteração dos valores para uma escala de 0 a 1, pode “esmagar” (*crush*) os dados caso haja grande discrepância entre os valores, concentrando valores próximo a 0, enquanto *outliers*, erros nos sensores, ect., ocupam valores próximos a 1, comprometendo a formação dos agrupamentos pelo modelo. Já a padronização é menos sensível a *outliers*, não esmagando os dados com a presença deles, pois o desvio padrão e a média variam conforme a presença de valores discrepantes.

Com a higienização, padronização e integração de novos preditores ao *dataframe*, têm-se 24 características analisadas pelo modelo para indicação da condição funcional do pavimento. A Tabela 3 as características avaliadas na predição da condição funcional do pavimento urbano.

Tabela 3 – Características analisadas no modelo preditivo

Sensor	Leitura	Parâmetros calculados
Acelerômetro	$Dm_x$	Média, desvio padrão e variância
	$Dm_y$	Média, desvio padrão e variância
	$Dm_z$	Média, desvio padrão e variância
Giroscópio	$Gy_x$	Média, desvio padrão e variância
	$Gy_y$	Média, desvio padrão e variância
	$Gy_z$	Média, desvio padrão e variância
Acelerômetro (resultante)	$Dm_r$	$r_{Dm_r}$ Média, desvio padrão e variância
GPS	$Spd$	Desvio padrão e variância

Fonte: O autor

### 3.7 Aplicação do modelo

O modelo utilizará o banco de dados formado pelos dados das características estudadas levantadas de locais escolhidos para treinar o modelo, um grupo de treino, informando as características de todos os pontos levantados, para a formação dos *clusters* de caracterização da condição do pavimento. Cada *cluster* será rotulado conforme sua classificação observada em campo, pela análise das filmagens feitas em paralelo as coletas de dados.

Para a definição do número de *clusters* do modelo, será utilizado o método do cotovelo para obter uma estimativa do valor compatível de grupos para o banco de dados utilizado para a formação do modelo de identificação. Ainda será sugerido rótulos para cada agrupamento formado, com as características observadas com auxílio das filmagens feitas simultaneamente as leituras dos sinais interpretados pelos sensores.

Os dados para um grupo de teste serão levantados no mesmo veículo utilizado na pesquisa, com ambos os suportes, com carga aplicada normal e aparelho 2. Em adição a esses dados semelhantes aos usados para a formação do modelo, será utilizado um veículo da marca Hyundai, modelo HB20, com um suporte diferente em relação ao dessa pesquisa, e um aparelho modelo Samsung S8. A adição de equipamentos não utilizados na pesquisa no grupo de teste, citado acima, servirá para observar o comportamento do modelo em equipamentos diferentes, se ocorrem incoerências nos resultados obtidos para equipamento diferentes dos utilizados para a formação do grupo de treino. A classificação do grupo de teste está exposta na Tabela 4.

Tabela 4 – Classificação dos levantamentos do grupo de teste

Classificação	Descrição
1	Aparelho 2, carga normal e suporte 1
2	Aparelho 2, carga normal e suporte 2
3	Equipamentos externos à pesquisa

Fonte: o autor

## 4. ANÁLISE DE RESULTADOS

Neste capítulo está contido a caracterização das informações levantadas a partir da coleta de dados nos locais determinados, descrita no método de pesquisa, assim como o resultado do processamento dos dados baseados no modelo de *machine learning* utilizado, comparação entre as diferentes formas de levantamento de dados propostas, com uma geração posterior de mapas de situação em SIG para cada caso estudado.

### 4.1 Trechos selecionados para levantamento de dados

A avaliação das vias urbanas a serem escolhidas para a coleta de dados dos sensores de *smartphone* teve como base a proximidade com o local do processamento dos dados, a uma análise preliminar das condições funcionais do pavimento, na qual foram selecionados trechos que apresentavam quantidades razoáveis de características presentes no modelo do algoritmo preditivo *k-means* de *machine learning* utilizado. Na Tabela 5 estão listados os locais levantados, assim como a condição de carregamento no momento do levantamento e a disposição da aparelhagem de levantamento. Apenas a rota 3 do Campus do Pici foi levantado de forma diferenciada, utilizando a combinação A1S1/A2S2 do arranjo de suporte e aparelho e com carga normal.

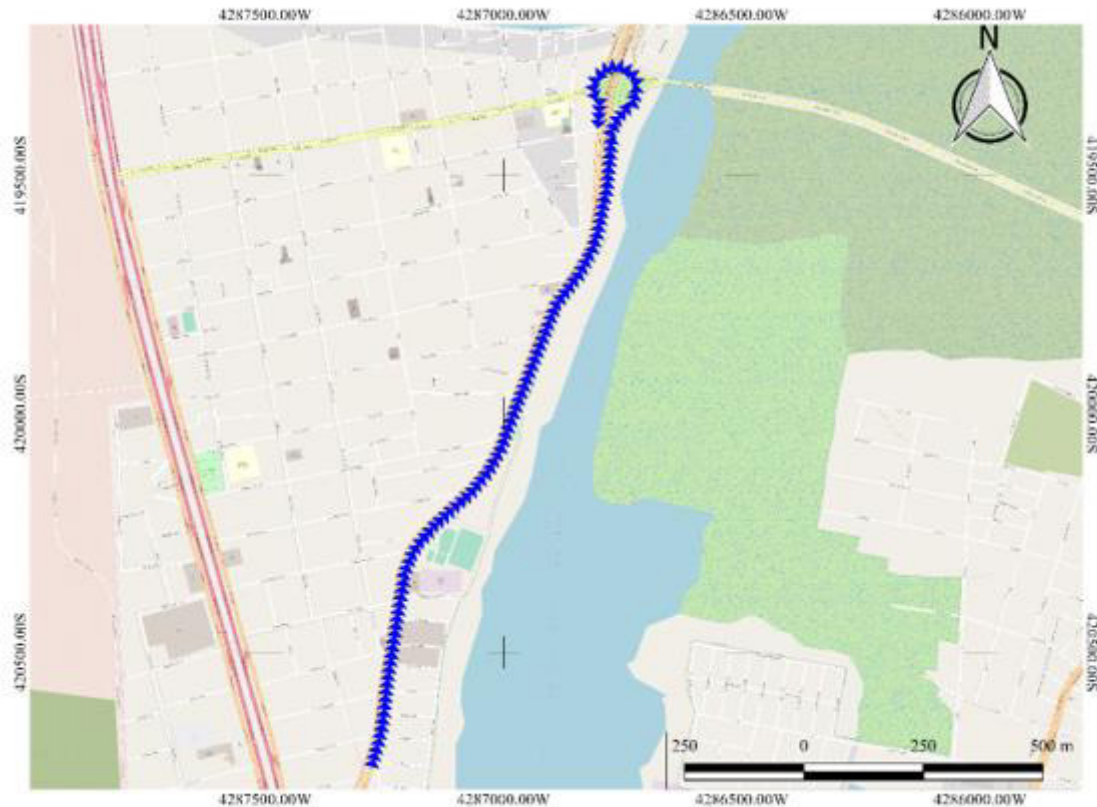
Para uma melhor visualização preliminar dos locais de levantamento, e a diferenciação entre as rotas tomadas, diferenciadas entre rotas 1, 2 e 3, nas áreas do *Campus* do Pici e Avenida Carlos Jereissati, foram gerados mapas, através do *software* QGis, para verificar o posicionamento dos locais na cidade de Fortaleza e a identificação da direção de tráfego. A Figura 12 mostra uma visão da Avenida Governador Raul Barbosa e a direção de tráfego avaliada. Os outros mapas gerados estão contidos no Apêndice A.

Tabela 5 – Vias escolhidas para levantamento de dados

Local	Comprimento (km)	Distância Percorrida (km)
Campus do Pici Rota 1	4,389	35,112
Campus do Pici Rota 2	2,350	18,800
Campus do Pici Rota 3	3,137	6,270
Avenida Carlos Jereissati – Rota 1	2,920	23,360
Avenida Carlos Jereissati – Rota 2	2,976	23,808
Avenida Governador Raul Barbosa	1,782	14,256
	<b>Distância Total Percorrida</b>	<b>121,606</b>

Fonte: O autor

Figura 12 – Mapa de local de levantamento: Avenida Governador Raul Barbosa




Fonte: O autor

## 4.2 Comparação entre sinais interpretados pelos sensores

Após os levantamentos e tratamento dos dados, algumas características interpretadas pelos sensores dos smartphones foram comparadas em relação ao seu estado de carga, suporte e dispositivo utilizados no levantamento. Para cada comparação, são fixadas as outras condições de levantamentos, que são: trajeto, carga, suporte e dispositivo. A fixação dos aspectos busca a mínima influência desses sobre as comparações, dessa forma, as mudanças nos padrões de respostas se devem principalmente a condição de levantamento comparada. A Figura 13 expõe os locais do Campus do Pici escolhidos para a comparação dos dados interpretado.

Figura 13 – Local escolhido para comparação de dados de levantamento



Fonte: O autor

Esse ponto foi escolhido por ser um local com variações aparentemente notáveis em relação ao padrão de resposta do veículo ao pavimento e, conseqüentemente, dos sinais interpretados pelos *smartphones*. Esse padrão de resposta do veículo referido advém da sensação de conforto dos ocupantes e da percepção de trepidação e solavancos durante trajeto percorrido. Esse ponto representa uma intervenção para redução de velocidade com uso de dispositivo auxiliar do tipo tachão.

As características comparadas foram selecionadas com base na percepção da variação dos valores dessas características. A comparação direta dos valores e o desvio padrão dos sensores acelerômetro e giroscópio foram definidos pela representatividade de seus valores, que definem bem a resposta do veículo sobre os suportes e *smartphones* utilizados. Como cada levantamento feito percorre o trajeto de forma diferente, e mantém uma velocidade média diferente, as posições dos sinais interpretados foram registradas e expostas nos tópicos referentes a essas comparações.

#### 4.2.1 Comparação entre suportes


Dentre os suportes estudados, foi constatado que o Suporte 1, devido a ter uma liberdade maior de movimentação, tenha respostas maiores em relação ao Suporte 2, percebido como mais fixo ao veículo. A Figura 14 expõe as posições geográficas registradas pelos dispositivos utilizados e a Figura 15 à Figura 18 expõem o padrão de sinais dos levantamentos.

Figura 14 – Posição dos sinais interpretados para comparação entre suportes

**Legenda:**

✦ Suporte 1


✦ Suporte 2



Fonte: O autor




Figura 15 – Aceleração linear média interpretada nos eixos coordenados dos Suportes 1 e 2




Fonte: o autor

Figura 16 – Desvio padrão da aceleração linear interpretada nos eixos coordenados dos Suportes 1 e 2




Fonte: o autor

Figura 17 – Aceleração angular média interpretada nos eixos coordenadas dos Suportes 1 e 2



Fonte: o autor

Figura 18 – Desvio padrão da aceleração angular interpretada nos eixos coordenadas dos Suportes 1 e 2



Fonte: o autor

Observando a Figura 15 à Figura 18, percebeu-se que os desvios padrões de ambas as acelerações, linear e angular, demonstram nitidamente a presença de uma alteração do padrão da via: a intervenção para redução de velocidade. Porém, ainda observando as figuras, observa-se que as respostas do Suporte 2 tem valores numéricos menores, tanto para a média das respostas quanto para seu desvio padrão.

A interpretação dos sinais do giroscópio após a presença da intervenção para redução de velocidade, presente no ponto 1480 para o suporte 1 e no ponto 870 para o Suporte 2, tem respostas de valores numéricos menores que as respostas do sensor 1, porém isso pode ser devido à velocidade média inferior para essa situação, que é exposta na Figura 15. A influência da velocidade é percebida também na plotagem dos pontos de representação da posição de cada leitura, sendo os pontos plotados do Suporte 2 menos espaçados.

#### ***4.2.2 Comparação entre cargas***

Para a comparação entre as cargas, constatou-se que a resposta para o veículo com sobrecarga foi representativa da real condição do pavimento e refletiu melhor a condição superficial, pois o contato do pneu com o pavimento é aumentado pelo maior peso distribuídos aos pneus, aumentando a área de contato pneu-pavimento.


Porém, deve-se levar em consideração na comparação, assim como na comparação entre suportes, a variação da velocidade média nos trajetos, que foi maior para a sobrecarga, então deve-se observar um valor numérico maior em relação aos sinais interpretados pelos sensores. A Figura 19 expõe as posições geográficas registradas pelos dispositivos utilizados e a Figura 20 à Figura 23 expõem o padrão de sinais dos levantamentos.

Figura 19 – Posição dos sinais interpretados para comparação entre suportes

Legenda:


☆ Suporte 1

☆ Suporte 2




Fonte: o autor

Figura 20 – Aceleração linear média interpretada nos eixos coordenados da carga Normal e Sobrecarga



Fonte: o autor


Figura 21 – Desvio padrão da aceleração linear interpretada nos eixos coordenados da carga Normal e Sobrecarga



Fonte: o autor




Figura 22 – Desvio padrão da aceleração linear interpretada nos eixos coordenados da carga Normal e Sobrecarga



Fonte: o autor

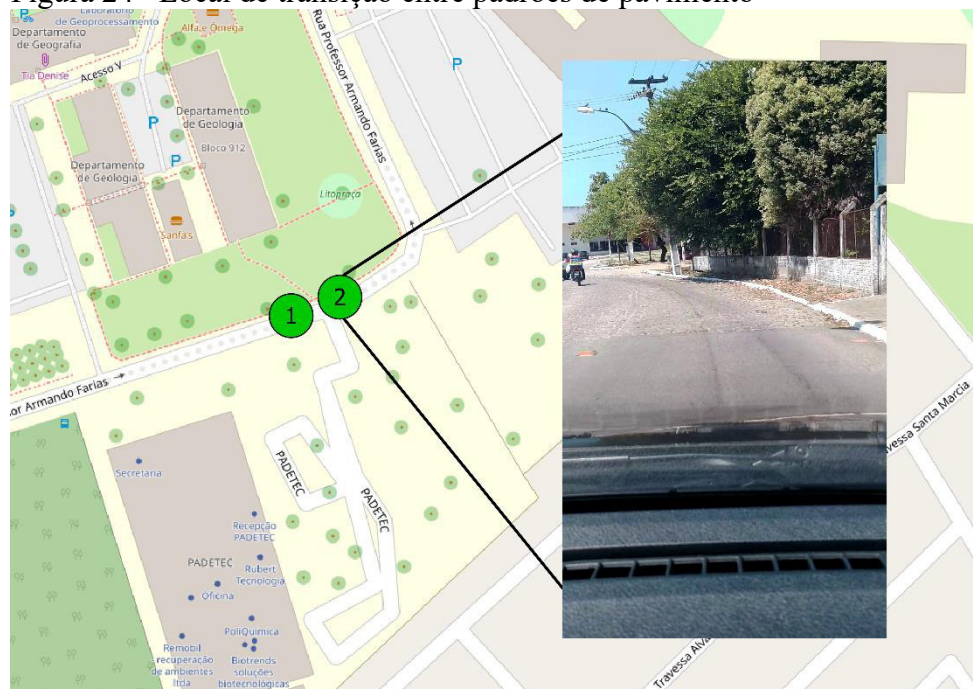
Figura 23 – Desvio padrão da aceleração angular interpretada nos eixos coordenados da carga Normal Sobre carga



Fonte: o autor

Da mesma forma da comparação em relação aos suportes utilizados, os sinais de desvio padrão apresentaram a diferença entre os sinais interpretados. Os sinais observados para o trecho percorrido em sobrecarga são similares aos observados para o carregamento normal do veículo, sendo as diferenças na plotagem dos gráficos causados pela maior velocidade média, mostrando observações de partes mais à frente em relação ao trecho com carregamento normal. Esse tipo de mudança foi percebido nos sinais relacionados a comparação de suporte, e se deveu a mudança no padrão de pavimentação da via, uma mudança de revestimento asfáltico para calçamento em pedra paralelepípedica. A Figura 24 mostra a localização dessa variação no *Campus* do Pici como ponto 2, posicionado logo após o ponto 1

Figura 24 – Local de transição entre padrões de pavimento



Fonte: o autor

### 4.2.3 Comparação entre aparelhos


Para a comparação entre os aparelhos utilizados, observou-se uma resposta similar entre ambos sinais interpretados de acelerômetro e giroscópio para os Aparelhos 1 e 2, pois mantendo as condições de carga e de suporte nos levantamentos, a parte mecânica na construção dos dispositivos não deve apresentar grande mudança, pois o custo da introdução dessa tecnologia a dispositivos é bastante reduzida em relação ao custo do aparelho. A Figura 25 expõe as posições geográficas registradas pelos dispositivos utilizados e a Figura 26 à Figura 29 expõem padrão de sinais dos levantamentos executados.

Figura 25 – Posição dos sinais interpretados para comparação entre aparelhos

Legenda:


✚ Aparelho 1

✚ Aparelho 2




Fonte: o autor

Figura 26 – Aceleração linear média interpretada nos eixos coordenados dos Aparelhos 1 e 2




Fonte: o autor

Figura 27 – Desvio padrão da aceleração linear interpretada nos eixos coordenados dos Aparelhos 1 e 2




Fonte: o autor

Figura 28 – Aceleração angular média interpretada nos eixos coordenados dos Aparelhos 1 e 2



Fonte: o autor

Figura 29 – Desvio padrão da aceleração angular interpretada nos eixos coordenados dos Aparelhos 1 e 2




Fonte: o autor



Valores de resposta da aceleração linear e angular do acelerômetro e giroscópio, respectivamente, tiveram valores discrepantes entre os Aparelhos 1 e 2. Os padrões observados foram diferentes em relação às comparações entre carga aplicadas e suportes utilizados no ponto verificado, mostrando respostas prolongadas após a passagem da intervenção para redução de velocidade em tachão. Na filmagem auxiliar foi observado que houve uma mudança de faixa durante a passagem sobre o tachão, provocando uma resposta intercalada de cada pneu do veículo, sendo interpretado assim como uma resposta prolongada. Na Figura 30 é mostrado o momento da mudança de faixa registrado pela filmagem auxiliar, causado pelo bloqueio da via.

Figura 30 – Aproximação à obstrução da via analisada levantamento com o Aparelho 2

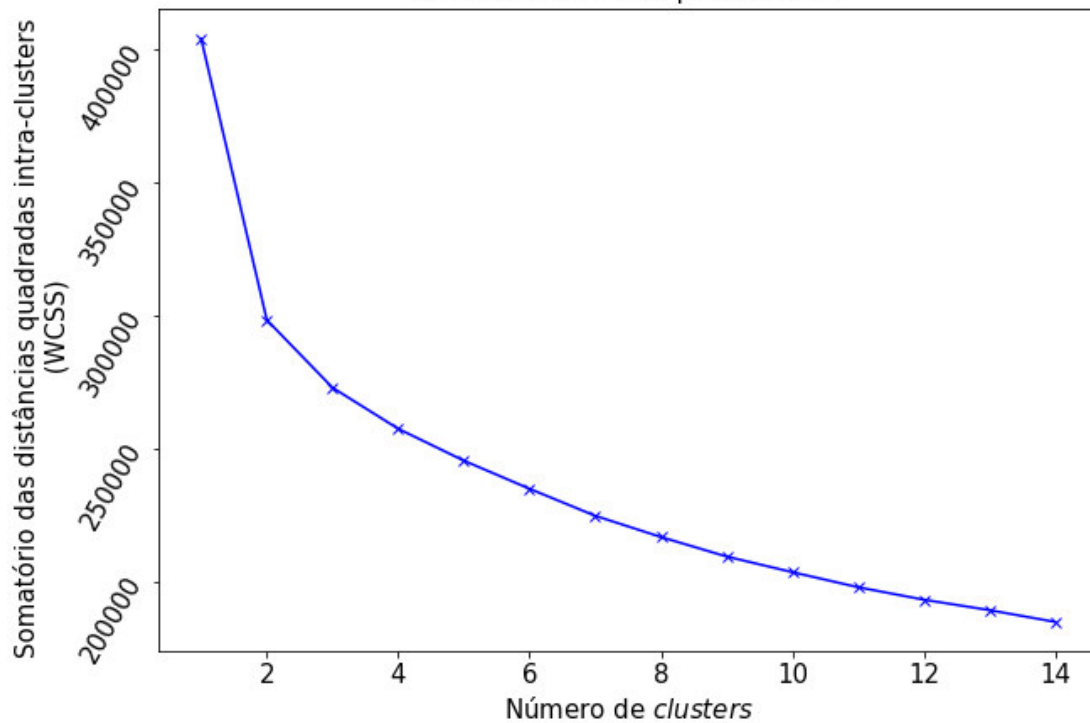


Fonte: o autor

### 4.3 Formação do modelo e aplicação

Após atribuir ao algoritmo todos os dados coletados e tratados, 16.165 pontos com informações das características pertinentes ao agrupamento foram incorporados ao sistema. Após isso, o sistema foi submetido a um teste de cotovelo para a escolha de um número de *clusters* adequado para o conjunto de dados estudados. A Figura 31 apresenta o resultado desse processo.

Figura 31 – Teste do cotovelo para o modelo gerado  
Método do cotovelo para n ótimo

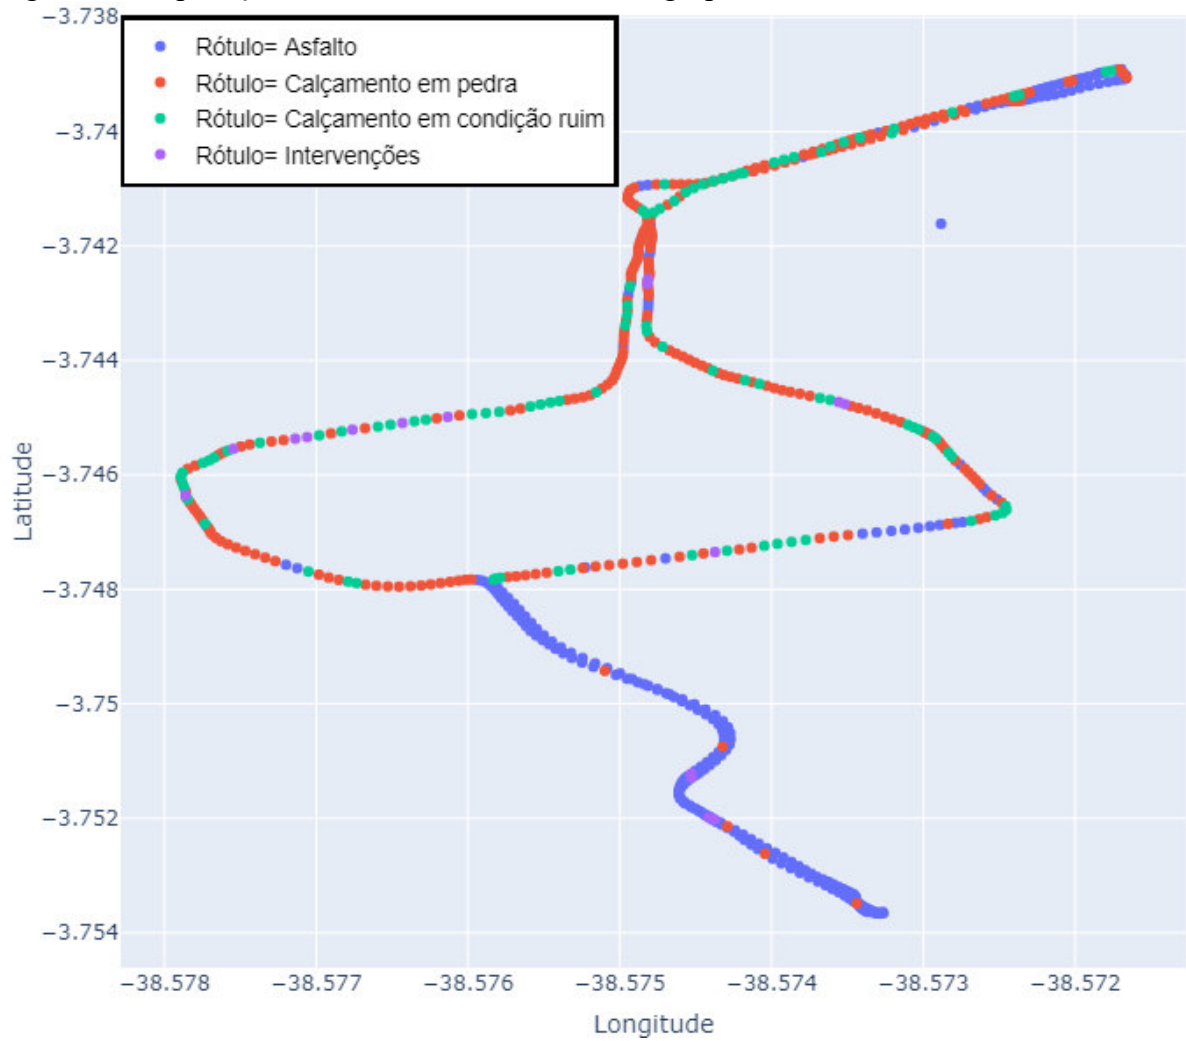


Fonte: o autor

O número de *clusters* escolhidos para o modelo foi de 4, por ser um valor com variação de curvatura em relação ao próximo valor pequeno, o que indica pequena redução do WCSS. Os *clusters* serão interpretados como a presença de alguma interferência na via, como lombadas e buracos, pavimento em calçamento, pavimento em calçamento em condição ruim e asfalto. Após o algoritmo não-supervisionado *k-means* encontrar os centroides na aplicação do modelo, foi utilizado o grupo de teste para a aplicação do modelo e observar o comportamento em relação a identificação das reais características da via.


A aplicação do modelo foi feita em cada elemento do grupo de teste separadamente, com o intuito de analisar de forma menos agregada a influência do equipamento sobre os resultados obtidos. A Figura 32 a Figura 34 mostram as classificações dadas aos pontos levantados.

Figura 32 – Aplicação do modelo ao elemento 1 do grupo de teste




Fonte: o autor

Figura 33 – Aplicação do modelo ao elemento 2 do grupo de teste



Fonte: o autor

Figura 34 – Aplicação do modelo ao elemento 3 do grupo de teste




Fonte: o autor

O modelo aplicado ao grupo de teste diferenciou diversos pontos de interesse, inclusive no elemento 3, mesmo sem haver dados previamente processados no modelo com as condições de coleta utilizadas. Porém, alguns dos pontos de interesse foram diferenciados da parte majoritária dos dados (calçamento em pedra e asfalto) de formas diferentes, tendo as características dos pontos sido interpretados pelo modelo como *clusters* diferentes dos de campo. Essas diferenças podem ser observadas na Figura 35.



Figura 35 – Diferenças entre a identificação de características da via




Fonte: o autor

O canto superior direito e central da Figura 35 são, respectivamente, o item 1 e 2 do grupo de treino, que indicam a intervenção para redução de velocidade em tachão classificado corretamente com o rótulo de intervenção, porém no canto inferior esquerdo da Figura 35, representando o item 3 do grupo de treino, interpretou de forma mais branda, classificando como calçamento em pedra, porém ainda diferenciando do entorno em pavimentação asfáltica.

A transição entre padrões de pavimentação, situação já analisada em relação aos sinais interpretados pelos sensores, foram separados de forma correta entre o rótulo de asfalto e calçamento em pedra para os três elementos do grupo de teste. A Figura 36 mostra o local da mudança de padrão e classificação dada por cada elemento de grupo de teste.

Figura 36 – Identificação de mudança de padrão de pavimentação de via



Fonte: o autor

Como visto a Figura 36, a transição de padrões de via é bem diferenciado por todos os elementos do grupo de treino, tendo assim o modelo o potencial para diferenciar outras alterações de padrão de revestimento de via e a sua falta, indicando aos gestores responsáveis trechos com remoção parcial ou total do revestimento utilizado na via, e servindo como um mapa de gravidade da condição de vias para auxílio da priorização para intervenções futuras.

## 5. CONCLUSÕES E RECOMENDAÇÕES

Este capítulo apresenta as principais conclusões obtidas em todo o percurso dessa pesquisa, assim como as sugestões para trabalhos futuros, que resultaram na formação de um modelo que visava a identificação das condições funcionais em pavimentos urbanos.

### 5.1 Conclusões

Essa pesquisa tratou do desenvolvimento de um modelo de identificação de características funcionais de pavimentos urbanos. A utilização do *smartphone* como um instrumento de coleta teve como objetivo reduzir o custo do processo de levantamento de dados para tomada de decisões relacionadas a manutenção e reabilitação de pavimentos.

Os dados levantados para a elaboração do modelo foram aplicados a um código computacional de um algoritmo de *machine learning*, o *k-means*, que recebendo arquivos de dados higienizados em relação a presença de valores nulos e padronizando-os, alcançou-se um modelo que pode diferenciar padrões de pavimentação, identificar a qualidade de um calçamento em pedra e reconhecer interferências ocorridas no pavimento analisado, sendo eles defeitos funcionais, como panelas, e intervenções para controle de velocidade, como lombada em tachão.

A frequência de captura utilizado pelo aplicativo de coleta foi de 20 hz, porém, baseado na bibliografia estudada, seria indicado a aumento dessa taxa de captura para algo próximo de 40 Hz. O aumento da taxa eleva a acurácia do modelo final, pois o aumento do número de sinais por segundo obtidos permite a descrição mais próxima da condição interpretada pelos sensores em relação às características reais do pavimento. Porém, deve-se atentar que esse aumento da taxa de aquisição de dados requer um *smartphone* que suporte essa frequência aumentada, assim como a manutenção nessa condição de maior aquisição provoca um maior gasto de bateria do aparelho, e esses fatores podem ser impeditivos para um levantamento de menor custo.

Uma das limitações observadas durante o decorrer dessa pesquisa foi a dificuldade de manter a velocidade constante durante os levantamentos, sendo a velocidade um fator de notória influência nas respostas obtidas pelos sensores. A manutenção da velocidade constante foi comprometida pela escolha da faixa prioritária de tráfego escolhida para o levantamento ter sido à esquerda, faixa essa que permitia a parada de veículos para carga e descarga, necessitando de reduções de velocidade recorrente durante os levantamentos.



Outra limitação observada foi a atribuição de uma maior especificidade às interferências encontradas no pavimento estudado, sendo o modelo ainda deficiente, com as características atribuídas a cada ponto georeferenciado para o treino do modelo, em diferenciar uma panela de uma interferência de redução de velocidade em tachão, caso as respostas obtidas pelo sensor seja semelhante a ponto de compartilharem o mesmo *cluster*. Ainda, um sistema de atribuição de nota de risco para as interferências observadas seria útil a esse tipo modelo gerado a pesquisa, servindo como uma ferramenta ainda mais benéfica a um gestor responsável pela manutenção e reabilitação de pavimentos.

Por fim, conclui-se que o *smartphone* é um equipamento que pode ser usado como um instrumento eficaz no levantamento de dados para processamento por meio de um modelo, com o intuito de identificar condições superficiais de um pavimento urbano. Seu custo reduzido ajuda a difundir seu uso com maior facilidade em instituições responsáveis pela gestão dos pavimentos, utilizando assim tecnologias desenvolvidas para apresentarem baixo custo, operação simples e alta produtividade.

## 5.2 Sugestões para trabalhos futuros

Durante o processo de pesquisa, algumas questões foram levantadas e podem ser respondidas através de trabalhos futuros, servindo como propostas para essas pesquisas. As sugestões para trabalhos futuros são:

- a) Levantar dados de outros tipos de pavimentos, como pavimento rígido, e estudar sua influência quando inserido no banco de dados com a finalidade de identificar condições funcionais de pavimentos;
- b) utilizar outros veículos para levantamentos e analisar a influência da suspensão do veículo utilizado sobre o sinal interpretado pelos smartphones;
- c) rotular, parcial ou totalmente, os dados levantados e comparar o grupo de teste utilizado com o pavimento real observado, quantificando a taxa de acerto do modelo;
- d) utilizar um aplicativo com maior frequência de captura, para a obtenção de maior número de dados com a mesma distância percorrida;
- e) verificar a influência do posicionamento do suporte para *smartphone* sobre os sinais interpretados pelos aparelhos;

- f) utilização de novos algoritmos de *machine learning* não-supervisionados de agrupamento, para verificar a taxa de acerto e analisar a eficiência de cada modo de agrupamento de dados.

## REFERÊNCIAS

- ALMEIDA, Lucas Cavalcante de. **Aplicativo para Smartphone Destinado à Medição da Irregularidade Longitudinal em rodovias**. Dissertação (Mestrado) - Curso de Engenharia Civil, Departamento de Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, 2018. 95 f. Disponível em: <<http://www.repositorio.ufc.br/handle/riufc/35669>>. Acesso em: 07 abr. 2019.
- ARTHUR, David; VASSILVITSKII, Sergei. **k-means++: The Advantages of Careful Seeding**. 18th Annual ACM-SIAM Symposium on Discrete Algorithms Nova Orleães, Louisiana, EUA, 2007.
- BANKO, Michele; BRILL, Eric. **Scaling to very very large corpora for natural language disambiguation**. Proceedings of the 39th Annual Meeting on Association for Computational Linguistics. Association for Computational Linguistics, Stroudsburg, PA, EUA, 2001, p. 26-33.
- BARELLA, Rodrigo Maluf. **Contribuição Para a Avaliação Da Irregularidade longitudinal de pavimentos com perfilômetros inerciais**. Tese (Doutorado) - Curso de Engenharia Civil, Escola Politécnica da Universidade de São Paulo, 2007.
- BEEBY, Stephen; ENSELL, Graham; KRAFT, Michael; WHITE, Neil. **MEMS: Mechanical Sensors** (Microelectromechanical systems series). Southampton, Reino Unido, Artech House, Inc, 2004.
- BENEVIDES, Sérgio Armando de Sá e. **Modelos de Desempenho de Pavimentos Asfálticos para um Sistema de Gestão de Rodovias Estaduais do Ceará**. 2006. Tese (Doutorado) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.
- BERNARDI, José Vicente Elias; LANDIM, Paulo Milton Barbosa. **Aplicação do Sistema de Posicionamento Global (GPS) na coleta de dados**. DGA, IGCE, UNESP/Rio Claro, Laboratório de Geomatématica, Texto Didático 10, 31 p. 2002. Disponível em <<http://www.rc.unesp.br/igce/aplicada/textodi.html>>. Acesso em 28 de Agosto de 2019 às 01:14.
- BERNUCCI, Liedí Bariani; SOARES, Jorge Barbosa; MOTTA, Laura Maria Goretti de; CERATTI, Jorge Augusto Pereira. **Pavimentação Asfáltica: Formação Básica para Engenheiros**. 3. ed. rev. Rio de Janeiro: Petrobrás: ABEDA, 2006.
- BISCONSINI, Danilo Rinaldi. **Avaliação da irregularidade longitudinal dos pavimentos com dados coletados por smartphones**. Tese (Doutorado). Universidade de São Paulo, 2016.
- BISHOP, Christopher M. **Model-based Machine Learning**. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences., Cambridge Microsoft Research, Cambridge, UK, 2013.
- BHORASKAR, Ravi; VANKADHARA, Nagamanoj; RAMAN, Bhaskaran; KULKARNI, Purushottam. **Wolverine: Traffic and Road Condition Estimation using Smartphone**

**Sensors.** Fourth International Conference on Communication Systems and Networks (COMSNETS 2012), 2012.

BRUCE, Peter; BRUCE, Andrew. **Estatística Prática para Cientista de Dados: 50 Conceitos Essenciais.** O'Reilly Media, p. 392, 2019.

BURKOV, Andriy. **The Hundred-page Machine Learning.** [s.i]: 2019. 159 p.

CÂMARA, Gilberto; ORTIZ, Manoel Jimenez. **Sistema de informação geográfica para aplicações ambientais e cadastrais: uma visão geral.** Instituto Nacional de Pesquisas Espaciais – INPE, 2006. Disponível em <<http://www.dpi.inpe.br/spring>>. Acesso em 04/10/2019.

CARVALHO, Pedro Henrique Fontenele Costa; OLIVEIRA, Francisco Heber Lacerda de Oliveira; REIS, Saulo Davi Soares e. **Identificação de Irregularidades de Superfície por Meio de Machine Learning para Sistemas de Gerência de Pavimentos.** Relatório de Dissertação (Mestrado) - XXXIII Congresso da Associação Nacional de Pesquisa e Ensino em Transportes – ANPET. Balneário Camboriú, Santa Catarina, 2019.

CHOI, Richard. **Advanced Gyroscopy Technology.** SPAWAR Systems Center. San Diego, EUA, 2008.

CONFEDERAÇÃO NACIONAL DO TRANSPORTE - CNT. **Pesquisa Rodoviária – Relatório Gerencial.** Brasília: Confederação Nacional do Transporte, 2018. Disponível em: [www.cnt.gov.br](http://www.cnt.gov.br). Acesso em: 07 abr. 2019

DEPARTAMENTO DE ESTRADAS DE RODAGEM DO PARANÁ - DER/PR. **Avaliação Funcional e Estrutural de Pavimentos.** 2006.

DIGGELEN, Frank Stephen Tromp Van. **A-GPS: Assisted GPS, GNSS, and SBAS.** Boston: Artech House, 2009.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTES – DNIT. **Manual de pavimentação.** Rio de Janeiro, 2006.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTES – DNIT. **Manual de Gerência de Pavimentos.** Diretoria Executiva. Instituto de Pesquisas Rodoviárias. Rio de Janeiro. 2011.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTES – DNIT. **DNIT 009-PRO: Avaliação Subjetiva da Superfície de Pavimentos Flexíveis e Semirígidos: Procedimento.** Rio de Janeiro, 2003a.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTES – DNIT. **DNIT 008-PRO: Levantamento visual contínuo para avaliação da superfície de pavimentos flexíveis e semi-rígidos - Procedimento.** Rio de Janeiro, 2003b.

ERIKSSON, Jakob; GIROD, Lewis; HULL, Bret; NEWTON, Ryan; MADDEN, Samuel; BALAKRISHNAN, Hari. **The Pothole Patrol: Using a Mobile Sensor Network for Road Surface Monitoring**. MobiSys, Breckenridge, Colorado, USA, 17 jun. 2008

FICCDC – TECHNOLOGY WORKING GROUP. **A Process for evaluating Geographic Information Systems**. Clark University, USA, 1988.

FEDERAL HIGHWAY ADMINISTRATION - FHWA. **Highway Statistics Table HM-12: Functional System National Summary**. Federal Highway Administration, U.S Department of Transportation, 2015. Disponível em: <<https://www.fhwa.dot.gov/policyinformation/statistics/2015/hm12.cfm>>. Acesso em 07 abr. 2019.

FORSLÖF, Lars; JONES, Hans. **Roadroid: continuous road condition monitoring with smart phones**. IRF 17th World Meeting and Exhibition, Riyadh, Saudi Arabia, 2013.

GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. O'Reilly Media, 2017, 576p.

GRUS, Joel. **Data Science from Scratch: First Principles with Python**. Sebastopol, Ca: O'reilly, 2015. 336 p.

HOFMANN-WELLENHOF, Bernhard.; LICHTENEGGER, Herbert & COLLINS, James. **Global positioning system: theory and practice**. Technische Universität Graz, Graz, Austria, Springer-Verlag, 2001.

HUANG, Yang H. **Pavement Analysis and Design**. Prentice Hall-Englewood Cliffs, New Jersey, 2004.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Resolução da Presidência 01/2005**. [S. l.], 24 fev. 2015.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS**. [S. l.], 27 Set. 2017. Disponível em <<https://www.ibge.gov.br/geociencias/informacoes-sobre-posicionamento-geodesico/servicos-para-posicionamento-geodesico/16332-rbmc-ip-rede-brasileira-de-monitoramento-continuo-dos-sistemas-gnss-em-tempo-real.html?edicao=16333&t=acesso-ao-produto>> Acesso em 30 de Agosto de 2019 às 19:05.

LAVETI, Ganesh; Rao, Gottapu; Rani, K.Jhansi; Nalinee, A & Babu, A.Mahesh. (2015). **GPS receiver SPS accuracy assessment using LS and LQ estimators for precise navigation**. Annual IEEE India Conference – INDICON. Pune, India, 2014.

MEDVEDEV, Dmitry. **On the development of road infrastructure**. [S. l.], 29 abr. 2016. Disponível em: <http://government.ru/info/22865/>. Acesso em: 31 maio 2019.

MOHAN, Prashanth; PADMANABHAN, Venkata N.; RAMJEE, Ramachandran. **Nericell: Rich Monitoring of Road and Traffic Conditions using Mobile Smartphones**. Embedded network sensor systems, n. 8, p. 323–336, 2008.

PAIXÃO, Monique Paixão; CORDEIRO, Cristovão César Carneiro; CORREIA, Maria de Conceição Nogueira. **Pavimentos Semirrígidos: Prevenção e Tratamento da Reflexão de Trincas**. In: Seminário Estudantil de Produção Acadêmica, 2017. Disponível em: <https://revistas.unifacs.br/index.php/sepa/article/viewFile/4949/3298>. Acesso em: 25 maio 2019.

PASSARO, Vittorio M. N; CUCCOVILLO, Antonello; VAIANI, Lorenzo; DE CARLO, Martino; CAMPANELLA, Carlo Edoardo. **Gyroscope Technology and Applications: A Review in the Industrial Perspective**. Dipartimento di Ingegneria Elettrica e dell'Informazione, Politecnico di Bari. Bari, Italy, 2017.

PATERSON, William D.O. **Road Deterioration and Maintenance Effects Models for Planning and Management**. The World Bank, Baltimore, The Johns Hopkins University Press, 1987.

SANTOS, Winderson Eugênio dos. **Sistema para Identificação da Curvatura na Junta Prismática de um Robô via Quartenions**. 2003. 172 f. Tese (Doutorado) - Curso de Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis, 2003. Cap. 4.

SATTAR, Shahram; LI, Songnian; CHAPMAN, Michael. **Road surface monitoring using smartphone sensors: A review**. Sensors (Switzerland), v. 18, n. 11, p. 21, 2018.

SAYERS, Michael W.; GILLESPIE, Thomas. D.; QUEIROZ, César. A. V. **The international road roughness experiment: a basis for establishing a standard scale for road roughness measurements**. Transportation Research Record, v. 1084, 1995.

SILVA, Ardemirio de Barros. **Sistemas de informações geo-referenciadas: conceitos e fundamentos**. Universidade Estadual de Campinas, Campinas, 2003.

SILVA, Rafael Cerqueira *et al.* **Procedimento para Levantamento Visual Contínuo Informatizado (LVCI) pelo Método da Varredura**. Revista ANTT, Juiz de Fora, MG, 2015. Disponível em: [http://www.antt.gov.br/backend/galeria/arquivos/VI\\_\\_ArtigoRevistaANTT\\_LVCI\\_MET\\_\\_V ARREDURA.pdf](http://www.antt.gov.br/backend/galeria/arquivos/VI__ArtigoRevistaANTT_LVCI_MET__V ARREDURA.pdf). Acesso em: 4 jun. 2019.

VERBOSKI, José Luiz. **Acionamento de uma Articulação Robótica 3D por Servomotores**. 2007. 77 f. TCC (Graduação) - Curso de Engenharia Industrial Elétrica, Departamento Acadêmico de Eletrotécnica, Universidade Tecnológica Federal do Paraná, Curitiba, Cap. 2, p. 18, 2007.

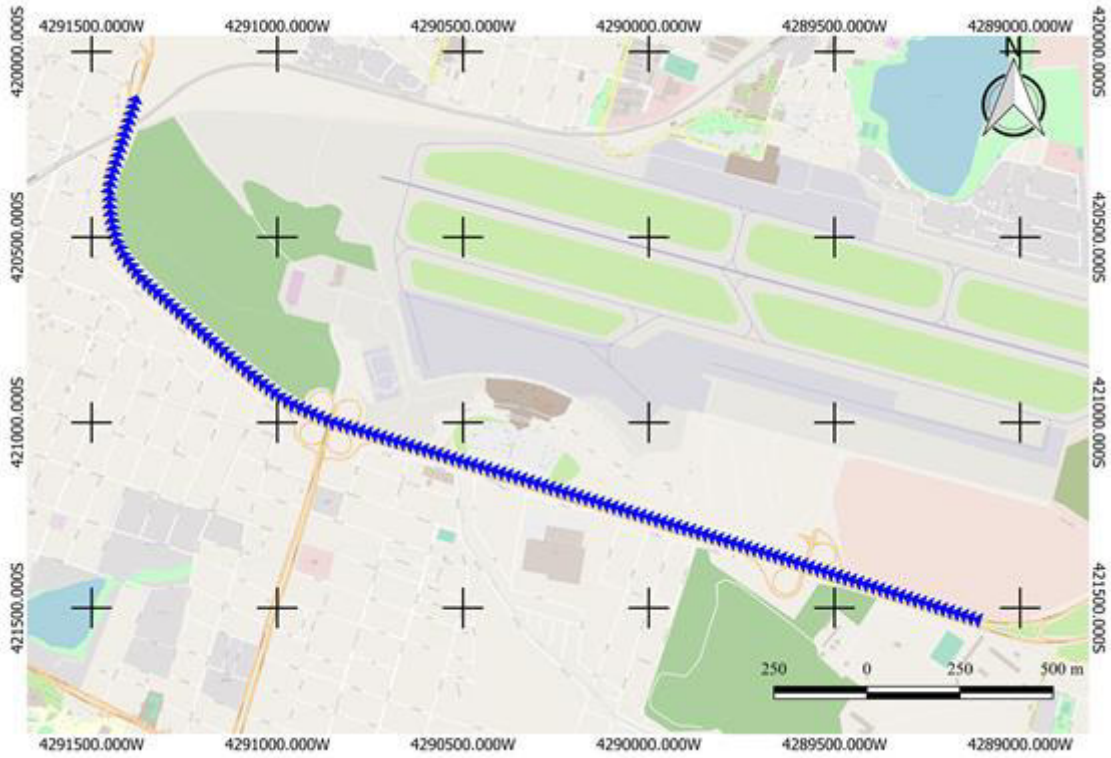
VIEIRA, Leonardo Pereira. **Experimentos de Física com Tablets e Smartphones**. 2013. 107 f. Dissertação (Mestrado) - Curso de Física, Instituto de Física, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2013. Cap. 3.

World Economic Forum. 2018. **The Global Competitiveness Report 2018**. Geneva: World Economic Forum.









Avenida Carlos Jereissati – Rota 1

