



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TRANSPORTES**

**PEDRO HENRIQUE FONTENELE COSTA CARVALHO**

**COLETA DE DADOS DE INVENTÁRIO E LEVANTAMENTO DE DEFEITOS COM  
SMARTPHONES E TRATAMENTO POR MEIO DE APRENDIZADO DE MÁQUINA  
PARA USO EM SISTEMAS DE GERÊNCIA DE PAVIMENTOS**

**FORTALEZA**

**2020**

PEDRO HENRIQUE FONTENELE COSTA CARVALHO

COLETA DE DADOS DE INVENTÁRIO E LEVANTAMENTO DE DEFEITOS COM  
SMARTPHONES E TRATAMENTO POR MEIO DE APRENDIZADO DE MÁQUINA PARA  
USO EM SISTEMAS DE GERÊNCIA DE PAVIMENTOS

Dissertação apresentada ao Curso de Mestrado em Engenharia de Transportes do Programa de Pós-Graduação em Engenharia de Transportes do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Transportes. Área de Concentração: Engenharia Civil

Orientador: Prof. Dr. Francisco Heber Lacerda de Oliveira

Coorientador: Prof. Dr. Saulo Davi Soares e Reis

FORTALEZA

2020

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)

---

C327c Carvalho, Pedro Henrique Fontenele Costa.

Coleta de dados de inventário e levantamento de defeitos com smartphones e tratamento por meio de aprendizado de máquina para uso em sistemas de gerência de pavimentos / Pedro Henrique Fontenele Costa Carvalho. – 2020.

71 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Fortaleza, 2020.

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

Coorientação: Prof. Dr. Saulo Davi Soares e Reis.

1. Sistema de Gerência de Pavimentos Urbanos (SGPU). 2. Smartphone. 3. Redes Neurais Artificiais (RNA). 4. Defeitos. I. Título.

---

CDD 388

PEDRO HENRIQUE FONTENELE COSTA CARVALHO

COLETA DE DADOS DE INVENTÁRIO E LEVANTAMENTO DE DEFEITOS COM  
SMARTPHONES E TRATAMENTO POR MEIO DE APRENDIZADO DE MÁQUINA PARA  
USO EM SISTEMAS DE GERÊNCIA DE PAVIMENTOS

Dissertação apresentada ao Curso de Mestrado em Engenharia de Transportes do Programa de Pós-Graduação em Engenharia de Transportes do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia de Transportes. Área de Concentração: Engenharia Civil

Aprovada em: 22 de Dezembro de 2020

BANCA EXAMINADORA

---

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

---

Prof. Dr. Saulo Davi Soares e Reis (Coorientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Mário Ângelo Nunes de Azevedo Filho  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. José Leomar Fernandes Júnior  
Escola de Engenharia de São Carlos (USP)

---

Prof. Dr. Danilo Rinaldi Bisconsini  
Universidade Tecnológica Federal do Paraná (UTFPR)

Aos meus pais, Sivana Fontenele e Almir Sérgio.

## **AGRADECIMENTOS**

Ao amigo e exemplo de professor Dr. Francisco Heber Lacerda de Oliveira por me orientar nesta Dissertação.

Ao amigo, irmão do peito e professor Dr. Saulo Davi Soares e Reis por me coorientar nesta Dissertação.

Aos meus amigos de pós-graduação Breno Quariquasi e Matheus Gomes, pelo companheirismo nesses anos.

Ao amigo Paulo Júnior por sacrificar alguns dos seus finais de semana na elaboração do aplicativo utilizado nesta dissertação.

Aos amigos no Discord, por ajudarem a manter a sanidade nos tempos de pandemia, em especial ao Aderson Passos.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

“Experience is simply the name we give our mistakes.”

(Oscar Wilde)

## RESUMO

No contexto das cidades brasileiras, a necessidade de Manutenção e Reabilitação (M&R) constantes da infraestrutura viária torna-se uma prioridade para o seu adequado funcionamento, desenvolvimento e atendimento dos interesses dos seus usuários nos quesitos de conforto, segurança e Custo Operacional do Veículo (COV). Na maioria dessas cidades, a gerência dos pavimentos é realizada pelas prefeituras, que, muitas vezes, devido ao tamanho da malha, a falta de mão de obra especializada e ao uso de métodos convencionais de avaliação, tendem a não cumprir, ou mesmo falhar, na periodicidade e nas práticas de M&R adequadas, sobretudo a nível de rede. Por outro lado, tem-se, na última década, o desenvolvimento de novas tecnologias para o auxílio à avaliação das condições dos pavimentos. O uso de sensores presentes nos smartphones atuais vem se mostrando uma opção viável para coleta de dados que compõem os Sistemas de Gerência de Pavimentos (SGP), devido a seu baixo custo e alta produtividade. A exploração de ferramentas disponíveis nesses aparelhos, tais como receptores GNSS (*Global Navigation Satellite System*), acelerômetros e giroscópios, da forma realizada nesta pesquisa, objetiva a coleta, classificação, tratamento e análise de dados com uso de Redes Neurais Artificiais (RNA) para a identificação de irregularidades no pavimento, com o intuito de compor uma plataforma de Sistema de Gerência de Pavimentos Urbanos (SGPU). A coleta de dados ocorreu no *Campus* do Pici da Universidade Federal do Ceará, com um veículo de passeio e um smartphone com sistema operacional *Android*. Os modelos propostos puderam identificar irregularidades no pavimento, como buracos, lombadas e tachões, com acurácia média de 84%, assim como tipos distintos de revestimento, com acurácia média de 98%. Os resultados obtidos, portanto, atestam a favor da técnica como sendo uma alternativa moderna ou complemento aos métodos tradicionais de avaliação das condições dos pavimentos, no que tange as características citadas. Deste modo, pretende-se contribuir para Sistema de Gerência de Pavimentos Urbanos (SGPU), orientando o gestor na indicação e priorização de trechos críticos ou com algum tipo de defeito específico que demande uma intervenção ou avaliação complementar, auxiliando na tomada de decisão mais adequada quanto às estratégias de M&R a serem realizadas.

**Palavras-chave:** Sistema de Gerência de Pavimentos Urbanos (SGPU). Smartphone. Redes Neurais Artificiais (RNA). Defeitos

## ABSTRACT

In the context of Brazilian cities, the need for constant Maintenance and Rehabilitation (M&R) of the road infrastructure becomes a priority for its proper functioning, development, and meeting the interests of its users in terms of comfort and safety, and Operating Cost of the Vehicle (VOC). In most of these cities, the management of the pavements is carried out by city halls, which often, due to the size of the network, the lack of specialized labor, and the use of conventional assessment methods, tend to not comply - or even fail - appropriate periodicity and M&R practices, especially at the network level. On the other hand, there has been, in the last decade, the development of new technologies to aid in the assessment of pavement conditions. The use of sensors in current smartphones has proven to be a viable option for the collection of data used in Pavement Management Systems (SGP), due to its low cost and high productivity. The exploration of tools available in these devices, such as GNSS (*Global Navigation Satellite System*) receivers, accelerometers, and gyroscopes, as performed in this research, aims to collect, classify, treat and analyze data using Artificial Neural Networks (RNA) for the identification of irregularities in the pavement, to compose an Urban Pavement Management System (UPMS) platform. Data collection took place at the Pici *Campus* of the Federal University of Ceará, with a passenger vehicle and a smartphone with the *Android* operating system. The proposed models were able to identify irregularities in the pavement, such as potholes, with an average accuracy of 84%, as well as different types of pavement, with an average accuracy of 98%. The results obtained, therefore, attest in favor of the technique as being a modern alternative or complement to the traditional methods of assessing pavement conditions regarding the aforementioned characteristics. Therefore, this work intends to contribute to , guiding the manager in the assignment and prioritization of critical or defective segments that require intervention or complimentary assessment, assisting in the most appropriate decision making regarding the strategies of M&R to be carried out.

**Keywords:** Smartphone. Artificial Neural Network (ANN). Urban Pavement Management Systems (UPMS), defects

## LISTA DE FIGURAS

Figura 1 – Resultados do processamento digital de imagens para identificação de buracos em pavimento asfáltico. . . . .	21
Figura 2 – Perfilômetro a <i>laser</i> acoplado ao veículo. . . . .	22
Figura 3 – Ilustração da aceleração vertical que o veículo é submetido após passar sobre um buraco. . . . .	22
Figura 4 – Exemplo dos eixos dos sensores em um smartphone. . . . .	24
Figura 5 – Esquema do uso de aprendizado de máquina para melhor compreensão do problema. . . . .	25
Figura 6 – Neurônio artificial e analogia ao neurônio biológico. . . . .	27
Figura 7 – Exemplo de arquitetura de MLP com duas camadas de 10 neurônios e principais elementos em destaque. . . . .	29
Figura 8 – Exemplo de transferência entra camadas de uma Redes Neuras Artificiais (RNA) . . . . .	30
Figura 9 – (a) neurônio recorrente (b) neurônio recorrente na dimensão do tempo . . . . .	32
Figura 10 – Célula LSTM . . . . .	33
Figura 11 – Célula GRU . . . . .	35
Figura 12 – Esquema da utilização de aumento de dados para nos modelos de classificação. . . . .	36
Figura 13 – Exemplos do efeito das técnicas de aumento de dados nos dados do acelerômetro . . . . .	36
Figura 14 – Exemplo de Matriz de confusão para classificação binária. . . . .	37
Figura 15 – Esquema processo de identificação de irregularidades de superfície no pavimento por meio de sensores de smartphones. . . . .	40
Figura 16 – Esquema processo de classificação dos sinais obtidos. . . . .	41
Figura 17 – Aplicativo e trecho escolhido. . . . .	42
Figura 18 – Coleta de informações sobre o trecho e gravação de vídeo. . . . .	42
Figura 19 – Coleta sendo realizada, suporte e eixos do dispositivo. . . . .	43
Figura 20 – Histograma das velocidades coletadas. . . . .	44
Figura 21 – Exemplo de interpolação de pontos aplicada. . . . .	44
Figura 22 – Exemplo dos polígonos das interferências - Rotulação. . . . .	45
Figura 23 – Revestimentos encontrados no trecho. . . . .	46
Figura 24 – Exemplos das irregularidades e pavimento classificados. . . . .	46
Figura 25 – Contagem dos dados por classificação adotada. . . . .	47

Figura 26 – Exemplo de amostragem das leituras com janela de observação igual a 4 e passo igual a 2, para as redes neurais recorrentes. . . . .	49
Figura 27 – Evolução dos modelos no conjunto de teste. . . . .	54
Figura 28 – Matrizes de confusão para as melhores iterações de cada modelo apresentado	54
Figura 29 – Evolução dos novos modelos no conjunto de teste. . . . .	56
Figura 30 – Matrizes de confusão para as melhores iterações dos novos modelos C*, D*, E* e F* . . . . .	56
Figura 31 – Evolução dos modelos quanto à presença de eventos. . . . .	58
Figura 32 – Matrizes de confusão para as melhores iterações dos modelos quanto à identificação de eventos e Não Eventos(Nda) . . . . .	58
Figura 33 – Evolução dos modelos quanto ao tipo de pavimento. . . . .	59
Figura 34 – Matrizes de confusão para as melhores iterações dos modelos quanto ao tipo do pavimento . . . . .	60
Figura 35 – Matrizes de confusão para as melhores iterações dos modelos com adição de dados para os tipos de eventos . . . . .	62
Figura 36 – Matriz de confusão e métricas analisadas do modelo final para identificação de eventos com utilização de aumento de dados. . . . .	63

## LISTA DE TABELAS

Tabela 1 – Exemplos de sensores embarcados na maioria dos smartphones atuais . . .	23
Tabela 2 – Funções de ativação . . . . .	28
Tabela 3 – Trabalhos Relacionados com uso de ML para identificação de irregularidades de superfície . . . . .	39
Tabela 4 – Características utilizadas. . . . .	48
Tabela 5 – Divisão dos conjuntos de treino e teste para cada tipo de abordagem. . . . .	50
Tabela 6 – Divisão dos conjuntos de treino e teste para as redes neurais recorrentes . .	50
Tabela 7 – Aumento de dados utilizado para os dados brutos . . . . .	51
Tabela 8 – Arquitetura dos modelos utilizados . . . . .	51
Tabela 9 – Melhores ajustes de quantidade de neurônios e tamanho do lote para cada arquitetura . . . . .	53
Tabela 10 – Métricas dos modelos apresentados quanto aos tipos de eventos encontrados	55
Tabela 11 – Melhores ajustes de quantidade de neurônios e tamanho do lote para a arquitetura com mais camadas e diferentes tipos de neurônios . . . . .	55
Tabela 12 – Melhores ajustes de quantidade de camadas e neurônios com neurônios GRU e simples para identificação de eventos. . . . .	57
Tabela 13 – Métricas dos modelos utilizados na rotulação de Evento e Não Evento . . .	59
Tabela 14 – Melhores ajustes de quantidade de camadas e neurônios com neurônios GRU e simples para identificação do tipo de pavimento. . . . .	59
Tabela 15 – Métricas dos modelos utilizados na rotulação sobre o tipo de pavimento . .	60
Tabela 16 – Melhores modelos treinados com aumento de dados para os tipos de eventos	61
Tabela 17 – Métricas dos modelos utilizados na rotulação sobre os tipos de eventos com o uso de Aumento de dados . . . . .	62

## LISTA DE ABREVIATURAS E SIGLAS

DTW	<i>Dynamic Time Warping</i>
GDS	Gradiente Descendente Estocástico
GNSS	Sistema de Navegação Global por Satélite - do inglês <i>Global Navigation Satellite System-</i>
GRU	<i>Gated Recurrent Unit</i>
IA	Inteligência Artificial
IRI	<i>International Roughness Index</i>
KNN	k-vizinhos mais próximos - do inglês <i>k-nearest neighbors</i>
LSTM	<i>Long Short-Term Memory</i>
M&R	Manutenção e Reabilitação
MC	Matriz de Confusão
ML	aprendizado de máquina - do inglês <i>Machine Learning</i>
MLP	<i>Perceptron</i> multicamadas - do inglês <i>Multilayer Perceptron</i>
ReLU	<i>Rectified Linear Unit</i>
RNA	Redes Neuras Artificiais
RNR	Redes Neuras Recorrentes
SeLU	<i>Scaled Exponential Linear Unit</i>
SGP	Sistemas de Gerência de Pavimentos
SGPU	Sistema de Gerência de Pavimentos Urbanos
SIG	Sistema de Informação Geográfica
SVM	Máquina de Vetor de Suporte - do inglês <i>Support Vector Machine</i>
TanH	Tangente Hiperbólica
VSA	Valor de Serventia Atual

## LISTA DE SÍMBOLOS

$B$	Largura de faixa em que o ruído é medido em Hertz
$\mu T$	Micro Tesla
$rad$	Radianos
lx	Lux - densidade de intensidade luminosa ou iluminância
$\sigma$	Função sigmóide
$Hz$	Hertz

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
<b>1.1</b>	<b>Contextualização</b>	<b>14</b>
<b>1.2</b>	<b>Justificativa</b>	<b>16</b>
<b>1.3</b>	<b>Objetivos</b>	<b>17</b>
<b>1.4</b>	<b>Estrutura do trabalho</b>	<b>17</b>
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>19</b>
<b>2.1</b>	<b>Avaliação funcional de pavimentos</b>	<b>19</b>
<b>2.2</b>	<b>Coleta de dados</b>	<b>22</b>
<b>2.3</b>	<b>Processamento de dados</b>	<b>23</b>
<b>2.3.1</b>	<b><i>Redes Neurais Artificiais</i></b>	<b>27</b>
<b>2.3.1.1</b>	<b><i>Neurônio Artificial</i></b>	<b>27</b>
<b>2.3.1.2</b>	<b><i>Redes Neurais Artificiais Multicamadas e Aprendizado Profundo</i></b>	<b>28</b>
<b>2.3.1.3</b>	<b><i>Redes Neurais Recorrentes</i></b>	<b>32</b>
<b>2.3.1.4</b>	<b><i>LSTM e GRU</i></b>	<b>33</b>
<b>2.4</b>	<b>Aumento de dados</b>	<b>35</b>
<b>2.5</b>	<b>Métricas de desempenho</b>	<b>37</b>
<b>2.6</b>	<b>Trabalhos relacionados</b>	<b>38</b>
<b>3</b>	<b>MÉTODO DE PESQUISA</b>	<b>40</b>
<b>3.1</b>	<b>Coleta de dados</b>	<b>41</b>
<b>3.2</b>	<b>Rotulação dos dados</b>	<b>43</b>
<b>3.3</b>	<b>Pré-processamento de dados</b>	<b>48</b>
<b>3.4</b>	<b>Processamento de dados</b>	<b>51</b>
<b>4</b>	<b>ANÁLISE E DISCUSSÃO DOS RESULTADOS</b>	<b>53</b>
<b>4.1</b>	<b>Quanto aos tipos de eventos encontrados</b>	<b>53</b>
<b>4.2</b>	<b>Quanto à presença de eventos</b>	<b>57</b>
<b>4.3</b>	<b>Quanto ao tipo do pavimento</b>	<b>57</b>
<b>4.4</b>	<b>Com aumento de dados</b>	<b>59</b>
<b>4.5</b>	<b>Aplicabilidades ao SGPU</b>	<b>61</b>
<b>5</b>	<b>CONCLUSÕES E RECOMENDAÇÕES</b>	<b>64</b>
	<b>REFERÊNCIAS</b>	<b>66</b>

# 1 INTRODUÇÃO

Este capítulo discorre sobre a estrutura desta Dissertação e apresenta a importância da coleta de dados sobre pavimentos, principalmente no que tange ao conforto ao rolamento de veículos e o seu uso nos Sistemas de Gerência de Pavimentos (SGP). São apresentados a contextualização, justificativa, objetivos, problema de pesquisa e, por fim, a estrutura do trabalho.

## 1.1 Contextualização

É evidente que todas as estruturas estão sujeitas à ação do tempo, submetidas à deterioração. Essa degradação pode ser observada, principalmente, nas estruturas mais frágeis ou de maior frequência de utilização, como os pavimentos, devido à sua forma de solicitação em relação às demais estruturas.

Tendo em vista o desgaste comum dos pavimentos, é indispensável o seu acompanhamento desde a construção a fim de manter os parâmetros necessários para sua utilização, sobretudo, segurança e conforto, pois são os principais percebidos pelos usuários. Quando o desgaste ultrapassa determinado ponto crítico e o pavimento começa a apresentar elevado nível de deterioração, os custos para sua recuperação tendem a se elevar rapidamente, muitas vezes necessitando a sua reconstrução. O acompanhamento das condições da infraestrutura por meio de um SGP, pode determinar com mais eficácia o processo de Manutenção e Reabilitação (M&R) com um planejamento constante dos aspectos de segurança e conforto, características fundamentais da condição funcional dos pavimentos.

As agências rodoviárias utilizam os SGP como parte vital da sua estratégia de gestão de ativos, auxiliando no cumprimento das suas responsabilidades para com a sociedade. O valor financeiro do pavimento deve ser compatível com sua vida útil - de que a integração do projeto, construção, M&R seja atendida-, a fim de fornecer o desempenho necessário por algumas décadas (HAAS *et al.*, 2015)

A avaliação desses ativos, também, deve ser analisada sobre a função social que o pavimento desempenhará. Isso significa que não se pode pensar apenas nos gastos iniciais envolvidos na sua construção, mas na sua conservação ao longo do tempo. Se não houver o devido acompanhamento e tomada de ações adequadas de M&R, a não trafegabilidade promovida por um pavimento implica em diversos fatores socioeconômicos negativos para o usuário, como o desgaste mais rápido de veículos, maiores tempos de deslocamento, aumento dos custos

operacionais, inacessibilidade de áreas etc. No Brasil, verifica-se uma predominância de uso de processos e técnicas de baixa produtividade e dispendiosas, com uma intensa dependência humana, imputando subjetividade na avaliação de pavimentos.

Com a difusão do uso de smartphones, seu poder de processamento e ferramentas embutidas, o mesmo vem sendo explorado como alternativa para resolver tarefas mais complexas de forma eficiente e econômica (LI; GOLDBERG, 2018). Aplicativos de navegação, que utilizam o Sistema de Navegação Global por Satélite - do inglês *Global Navigation Satellite System* (GNSS)-, tornaram-se ferramentas úteis, principalmente para quem trafega em grandes centros urbanos. Alguns estudos foram desenvolvidos para utilização desse ferramental disponível nos smartphones, tais como acelerômetros e giroscópios para avaliação funcional de pavimentos, na determinação da irregularidade longitudinal, destacando o seu baixo custo e alta produtividade (BISCONSINI, 2016). Diante disso, a utilização de smartphones para coleta de dados se apresenta como uma alternativa prática para obtenção de parâmetros que sirvam de referência para os SGP, auxiliando na tomada de decisão de forma mais técnica e racional.

Essa possibilidade de avaliação pode reduzir custos operacionais e tempo de execução se comparadas às avaliações tradicionais, uma vez que é possível realizá-la somente com um smartphone acoplado ao para-brisa de um veículo, por exemplo. Além disso, a avaliação funcional por meio de smartphones não é sujeita a subjetividades associadas ao avaliador, como ocorre com outros métodos (ALMEIDA, 2018).

Souza *et al.* (2018) relatam um aumento de diversos trabalhos propostos na última década com o uso de smartphones para a avaliação da qualidade do pavimento, ressaltando uma grande redução nos custos envolvidos quando comparados aos métodos tradicionais de avaliação. A maioria desses trabalhos utilizam-se de técnicas de aprendizado de máquina - do inglês *Machine Learning* (ML)-, para analisar os dados obtidos e inferir características para a infraestrutura.

Desse modo, com a quantidade expressiva de dados que podem ser extraídos com uso dos smartphones, o uso de técnicas de ML, suas abordagens e adaptações podem encontrar uma solução para problemas complexos no contexto da Engenharia de Transportes (GÉRON, 2019). Esses problemas envolvem a identificação de defeitos em revestimentos de pavimentos de modo confiável, reduzindo a subjetividade da avaliação e reduzindo custos.

## 1.2 Justificativa

Conforto ao rolamento é uma das principais características experimentadas pelos usuários nos grandes centros urbanos. O monitoramento dessa característica e suas variações ao longo do tempo por meio de um Sistema de Gestão de Pavimentos Urbanos (SGPU) é uma tarefa difícil e sem legislação específica no Brasil, tornando raro a elaboração de planejamento das atividades de M&R e dificultando decisões técnicas dos gestores, especialmente os públicos, na alocação de recursos.

Na maioria das cidades, a gerência dos pavimentos é realizada pelas prefeituras, que, muitas vezes, devido ao tamanho da malha, à falta de mão de obra especializada e ao uso de métodos convencionais de avaliação, tendem a descumprir práticas de M&R adequadas para essas vias, sobretudo a nível de rede. É comum, apenas, restaurações pontuais em áreas afetadas, quando a velocidade atinge níveis intoleráveis ou, até mesmo, quando não há mais possibilidade de tráfego ou elevam-se os acidentes. A análise periódica das condições de uma rede pavimentada requer investimentos financeiros, tempo e mão de obra, sendo uma medida essencial na sua conservação.

A avaliação da condição funcional dos pavimentos tem o objetivo de indicar as melhores soluções de M&R, garantindo maior segurança e conforto aos usuários e economia na operação das rodovias (LEMLIN *et al.*, 1998). Nas grandes cidades, devido ao tráfego constante, o monitoramento das vias torna-se uma tarefa difícil de ser realizada em horário comercial, principalmente com o uso das técnicas convencionais. A possibilidade do uso de sensores presentes nos smartphones, bastante utilizados no dia a dia dos condutores, podem ajudar na coleta de dados tais como aceleração e orientação do dispositivo que podem ser associadas à condição funcional dos pavimentos ou a defeitos específicos em sua superfície e na identificação de áreas mais desgastadas da malha viária, concentrando esforços nas mesmas e, assim, economizando tempo e mão de obra.

É necessário, para um adequado funcionamento de um SGPU, a maior quantidade de informações possível sobre os pavimentos, não somente do âmbito estrutural, como também do funcional, e o monitoramento de suas características mais importantes ao longo do tempo, dando suporte para um planejamento sólido de ações de M&R. O uso de técnicas com abordagens computacionais para a resolução de problemas de múltiplas variáveis é amplamente utilizado atualmente e o uso de técnicas de ML para desenvolvimento de modelos de predição ou classificação mostra-se eficiente na análise dessas informações.

Considerando o exposto, esta dissertação se justifica pela necessidade do desenvolvimento de um processo de coleta e classificação de dados da condição de pavimentos urbanos, no que tange ao conforto ao rolamento de veículos, que supere os problemas identificados nas soluções de SGPU que compõem o repertório ferramental tradicional e implementado atualmente de forma mais predominante. Levando-se em consideração, portanto, o potencial dos sensores embarcados em smartphones em coletar dados de forma massiva, prática e com um baixo custo, também se justifica a abordagem da pesquisa em incorporar estes dispositivos como parte do método. Há também a necessidade de, por meio de técnicas de ML, extrair informações adequadas para plataforma de gerenciamento de dados de pavimentos. Entre essas informações, estão o tipo do revestimento e a localização de irregularidades para suporte na tomada de decisão para atividades de M&R.

### 1.3 Objetivos

O objetivo geral deste trabalho é desenvolver um processo de coleta de dados da condição funcional de pavimentos urbanos, a partir de sensores de smartphones e processá-los de forma a obter informações para plataformas de gerenciamento de dados de pavimentos.

Como objetivos específicos, podem ser destacados:

- a) identificar características dos sensores embarcados nos smartphones;
- b) propor modelos de avaliação baseado nos *outputs* disponíveis por meio de técnicas de aprendizado de máquina diagnosticando possíveis limitações;
- c) mapear trechos conhecidos para facilitar o processo de rotulação dos dados;
- d) avaliar os modelos desenvolvidos;
- e) analisar o potencial de inclusão do método adotado na avaliação do conforto ao rolamento de veículos para suporte as ações de M&R de pavimento urbanos.

### 1.4 Estrutura do trabalho

Além deste capítulo introdutório, este trabalho é composto de mais quatro capítulos. O Capítulo 2 contém a revisão bibliográfica abrangendo livros, artigos, dissertações, teses e documentos de agências reguladoras sobre avaliação e gerenciamento de pavimentos e conceitos para utilização de técnicas de ML na elaboração de modelos. O Capítulo 3 descreve os materiais e métodos, equipamentos utilizados, engenharia de dados e algoritmos de ML utilizados. O

Capítulo 4 discorre os resultados obtidos por meio das técnicas utilizadas as análises bem como acurácia e erros das classificações. O Capítulo 5 apresenta a conclusão, discorrendo os avanços e as limitações do trabalho, assim como as proposições para trabalhos futuros.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, serão apresentados trabalhos relacionados à avaliação de pavimentos através de sensores de smartphones com suas diversas abordagens.

### 2.1 Avaliação funcional de pavimentos

Em geral, um dos fatores mais associados à qualidade dos pavimentos é a irregularidade longitudinal, representada pelo Índice Internacional de Irregularidade do inglês *International Roughness Index* (IRI), sendo esta, um desvio relativo a um plano de referência. Esse tipo de irregularidade tem influência direta na qualidade de rolamento, uma vez que afeta a dinâmica dos veículos e, também, influi nas cargas a qual a via é submetida (DNER, 1994; SAYERS; KARAMIHAS, 1998; DNIT, 2006).

Sendo o IRI um dos parâmetros mais representativos da qualidade de rolamento dos veículos, muitas técnicas para a medida desse índice são utilizadas. Bernucci *et al.* (2008) descrevem que essas irregularidades podem ser medidas por meio de: 1) equipamentos medidores de perfil longitudinal que podem ou não ter contato com a superfície do pavimento; 2) levantamentos topográficos; e 3) por equipamentos do tipo resposta, que medem o as irregularidades indiretamente pelo efeito que elas causam no veículo. Sayers e Karamihas (1998) simplificam a classificação desses equipamentos conforme o tipo de avaliação que eles fornecem: direta ou indireta. Na primeira classificação, estão os equipamentos que medem as irregularidades por meio de grandezas relacionadas diretamente ao perfil da superfície do pavimento, por exemplo nível e mira e equipamentos com sensores a *laser*. Na segunda classificação, as grandezas medidas têm relação indireta com o perfil da superfície, obtido por meio da interpretação das respostas do equipamento às irregularidades do pavimento.

A obtenção dos parâmetros qualitativos do IRI tem custo relativamente elevado, dado a aquisição, operação e manutenção de perfilômetros. DNIT (2003) propõe o uso do Valor de Serventia Atual (VSA), uma medida baseada na opinião de avaliadores, por meio de notas adotadas em função da capacidade do pavimento atender as exigências do tráfego, de conforto e suavidade. Este procedimento necessita de um grupo composto por cinco avaliadores e envolve mais membros para uma melhor aferição da sensibilidade de avaliação quando possível. Ele é completamente subjetivo às noções de conforto dos avaliadores.

Em se tratando de vias urbanas, essas avaliações tradicionais costumam ser repensa-

das, principalmente do ponto de vista prático: alguns dos equipamentos necessitam de bloqueio parcial ou total do tráfego de veículos durante a coleta. Bisconsini (2020) relata o uso de alguns desses equipamentos como pouco práticos para coleta em grandes extensões, importante na gerências de pavimentos a nível de rede e que os equipamentos como os perfilômetros inerciais a *laser* e sistemas do tipo *scanner* também podem ser usados para levantamentos de defeitos de superfície, porém com alto custo de compra, operação e tratamento de dados. Zanchetta (2017) comenta que as atividades de um SGP, conceitualmente desenvolvidas para pavimentos rodoviários ainda são válidas para pavimentos urbanos dado alguns ajustes, contribuindo para o desenvolvimento de um SGPU.

Muitas autoridades responsáveis pela infraestrutura de transportes em todo mundo, estão buscando tecnologias de baixo custo para avaliação de pavimentos, em especial para vias de baixo volume de tráfego, melhorando seu SGPU (YAN; YUAN, 2017). Bisconsini (2020) relata estudos envolvendo acelerômetros comerciais e smartphones para o monitoramento de pavimentos destacando o avanço tecnológico, incentivado por um mercado mundial competitivo na área das tecnologias móveis, contribuindo no aperfeiçoamento dos sensores e capacidade de processamento desses aparelhos. Ao longo da última década, estudos se intensificaram a fim de desenvolver alternativas de monitoramento da condição de pavimentos, principalmente na detecção de anomalias, tais como buracos e trincas, e obstáculos, como lombadas e tachões, que afetam diretamente o conforto ao rolamento e, normalmente, são os mais sentidos pelos usuários.


Monitorar e avaliar a condição dos pavimentos é de fundamental importância para o melhor planejamento de intervenções e manutenção com maior eficiência. Eriksson *et al.* (2008) comentam que os orçamentos das cidades costumam ser bem reduzidos e a definição das áreas que necessitam de manutenção é de grande importância. Salih *et al.* (2016) reiteram que o planejamento é particularmente importante em países em desenvolvimento onde o orçamento para a gestão desses ativos é bem reduzido.

Os smartphones se destacaram como alternativas de baixo custo para esse monitoramento, mesmo que em caráter preliminar, uma vez que é possível realizá-la somente com o dispositivo acoplado ao para-brisa de um veículo (ALMEIDA, 2018). Buza *et al.* (2014) afirmam que, em geral, há três principais maneiras de supervisionar as superfícies dos pavimentos em busca de irregularidades: através de imagens, de reconstrução 3D e de vibrações.

A supervisão do pavimento através de imagens dá-se pelo processamento digital de imagens capturadas geralmente por câmeras apontadas para o pavimento em um veículo em

movimento que possuem padrões treinados por diversos métodos para identificar defeitos (Figura 1) e assimilá-los à geolocalização correspondente, como apontam Koch (2013), Huidrom *et al.* (2013) e Buza *et al.* (2014). Felix Enigo *et al.* (2016) propõem um sistema de processamento de imagens onde usuários podem enviar fotografias de defeitos no pavimento e alertar as autoridades responsáveis sem redundâncias.

Figura 1 – Resultados do processamento digital de imagens para identificação de buracos em pavimento asfáltico.



Fonte: adaptado de Buza *et al.* (2014)

As reconstruções 3D baseiam-se na digitalização da superfície do pavimento por meio de *lasers* ou ultrassom que refletem na superfície criando um modelo 3D digital do mesmo, destacando as anomalias do restante do pavimento. Sattar *et al.* (2018) apontam que essa abordagem já foi bastante estudada por diversos pesquisadores nos Estados Unidos, Índia, China e Nova Zelândia por exemplo, requer equipamentos de alto custo como Perfilômetros a *Laser* (Figura 2) e pode ser uma alternativa economicamente inviável quando se trata do monitoramento de uma grande quantidade de vias, principalmente a nível de rede.

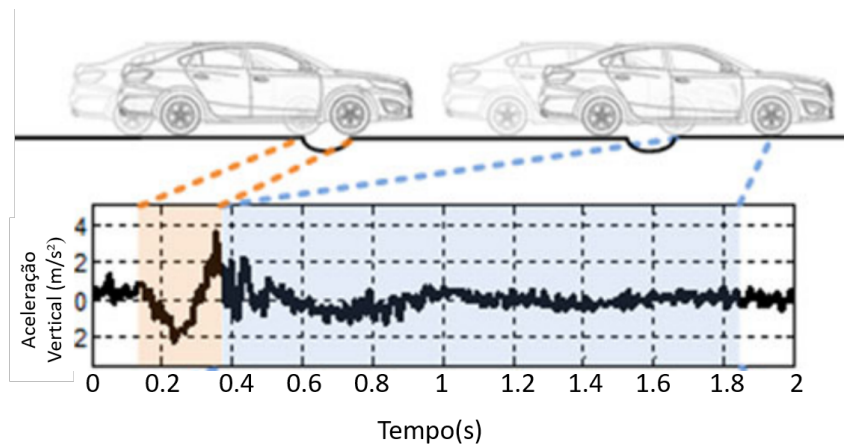
Figura 2 – Perfilômetro a *laser* acoplado ao veículo.



Fonte: adaptado de Albuquerque e Oliveira (2017)

A abordagem por meio de vibrações permite detectar anomalias e interferências no pavimento por meio das vibrações as quais o veículo é submetido quando passa sobre elas (Figura 3) capturadas através de sensores como acelerômetros e giroscópios. Em teoria um veículo tende a vibrar mais quando passa por anomalias como buracos, tachões, lombadas e tampas de bueiros que quando trafega sobre um pavimento mais regular (SATTAR *et al.*, 2018).

Figura 3 – Ilustração da aceleração vertical que o veículo é submetido após passar sobre um buraco.



Fonte: adaptado de Xue *et al.* (2017)

## 2.2 Coleta de dados

A maioria dos smartphones atuais possui uma grande quantidade de sensores embutidos capazes de mensurar movimentos, orientação/posição e várias condições ambientais ao seu redor. Os sensores de condições ambientais medem parâmetros como a temperatura, pressão, iluminação através de termômetros, barômetros e fotômetros respectivamente. Nos sensores de

movimentos, estão incluídos os acelerômetros, sensores de gravidade e giroscópios por exemplo, enquanto os sensores de posição referem-se à orientação do dispositivo e magnetômetros (GOOGLE, 2019).

Os sensores também podem ser divididos em duas classes: baseados em *hardware* e baseados em *software*. Os sensores baseados em *hardware*, são os que possuem os sensores físicos com funções específicas instalados na placa do dispositivo tais como acelerômetros e giroscópios; os sensores baseados em *software*, também conhecidos com sensores virtuais, utilizam-se dos dados dos sensores físicos para simular outras características, por exemplo o sensor de gravidade (SATTAR *et al.*, 2018). A Tabela 1 descreve alguns dos sensores mais comuns encontrados nos smartphones atuais.

Tabela 1 – Exemplos de sensores embarcados na maioria dos smartphones atuais

Sensor	Tipo	Medidas	Unidade
Acelerômetro	Físico	Medir a força da aceleração	$m/s^2$
Giroscópio	Físico	& Medir velocidade angular	$rad/s$
Magnetômetro	Físico	Medir a densidade do fluxo magnético	$\mu T$
Gravidade	Virtual	Medir a força da gravidade	$m/s^2$
Proximidade	Físico	Medir a proximidade de objetos à frente	cm
Orientação	Virtual	Medir a orientação do dispositivo	Graus
Iluminação	Físico	Mede a intensidade de iluminação	$lx$
Receptor GNSS	Físico	Posição, velocidade planar	Graus, $m/s$

Fonte: o autor

Sattar *et al.* (2018) comentam que o uso desses sensores pode atender a inúmeros aplicativos com as mais diversas finalidades. Entretanto, a maioria dos estudos para identificação de anomalias no pavimento, por meio de smartphones, utiliza apenas o acelerômetro, embora haja estudos que façam uso de mais sensores como giroscópios e até mesmo o microfone, como é o caso de Mohan *et al.* (2008). O acelerômetro mede a aceleração na qual o dispositivo é submetido em  $m/s^2$  ao longo de três eixos (Figura 4), bem como o giroscópio que mede a taxa de rotação dos dispositivo em torno dos mesmos eixos físicos.

### 2.3 Processamento de dados

O processamento dos dados obtidos pelos sensores dos smartphones constitui provavelmente a etapa mais importante na identificação de irregularidades no pavimento e é nesta etapa que os estudos mais se diferem. Há basicamente três métodos utilizados na identificação

Figura 4 – Exemplo dos eixos dos sensores em um smartphone.



Fonte: O autor

de sinais que podem representar essas irregularidades como aponta Sattar *et al.* (2018):

- a) Baseado em Limites: a identificação de intercorrências nos sinais dá-se por um limite calibrado e predefinido em experimentos, que podem depender de valores diretos ou indiretos (parâmetros estatísticos de uma série, por exemplo o desvio padrão) obtidos por acelerômetros;
- b) *Dynamic Time Warping* (DTW): os sinais são comparados com modelos já identificados medindo a similaridade entre eles. Diferentemente do método baseado em limites, o DTW verifica a correspondência da forma do sinal, não somente seus valores, ampliando a capacidade de associação dos modelos e flexibilizando as intensidades capturadas. Dada essa característica, esta técnica é bastante utilizada em aplicações de reconhecimento de fala, por exemplo;
- c) Aprendizado de máquina - do inglês *Machine Learning* (ML): usa de métodos computacionais para interpretar os sinais e identificar irregularidades no pavimento. Existem vários algoritmos de ML já empregados na identificação de irregularidades.

Nguyen *et al.* (2019) descrevem o método com uso do DTW de forma mais abrangente, contemplando os métodos com utilização de processamento de sinais nessa categoria - o que é mais apropriado - pois há outras técnicas implementadas nessa categoria com uso de filtros, por exemplo.

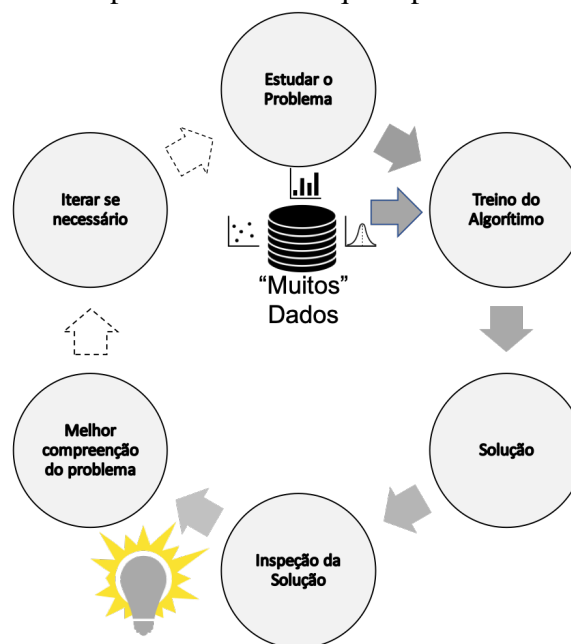
Com a emergente acessibilidade aos dispositivos móveis e disponibilidade de dados, Nguyen *et al.* (2019) relatam um crescente número de estudos envolvendo dados coletados por meio de smartphones embarcados no veículo para identificação de buracos e estimativa de índices de irregularidade. Dentre os estudos analisados, é destacado uma maior quantidade com

uso de técnicas de ML nas as abordagens para identificação de buracos ressaltando um alto desempenho.

Nesta pesquisa, será explorada a abordagem por meio de vibrações com o uso de smartphones para coleta dos dados e algoritmos de ML para a interpretação dos mesmos. O desenvolvimento de técnicas de ML é relativamente antigo, datado do final da década de 50, embora as aplicações só tenham se tornado mais utilizadas a partir da década de 90, como o desenvolvimento de filtros de *spam* (*e-mails* recebidos não solicitados pelo usuário). Em geral, ML é a ciência de programar máquinas para que elas aprendam com os dados a realizarem uma tarefa sem serem explicitamente programadas para tal tarefa (GÉRON, 2019). Neste campo de estudos da Inteligência Artificial (IA), é possível a utilização de algoritmos que possam desempenhar uma determinada função com base em dados, e estes algoritmos se dividem em dois principais ramos: os algoritmos de aprendizado supervisionados e não supervisionados (PATEL, 2019).

Géron (2019) comenta que esses algoritmos de aprendizado podem ajudar os seres humanos a compreenderem melhor determinados fenômenos e com base nas soluções que os algoritmos desenvolvem, como ilustrado na Figura 5, fornecer melhor compreensão sobre o problema.

Figura 5 – Esquema do uso de aprendizado de máquina para melhor compreensão do problema.



Fonte: Adaptado de Géron (2019)

Para os algoritmos de aprendizagem supervisionada, faz-se necessário um conjunto

de composto da amostra e dos rótulos de cada observação. O objetivo desse algoritmo é utilizar essa amostra junta aos rótulos já conhecidos para construir um modelo capaz de inferir um rótulo para uma nova observação. (BURKOV, 2019).

O aprendizado não supervisionado é o ramo do ML responsável por achar padrões “escondidos” em amostras não rotuladas, o que pode ser um problema mais difícil para o algoritmo, porém, se bem trabalhado, possui soluções mais poderosas e muitos especialistas acreditam que o aprendizado não supervisionado é a próxima fronteira das inteligências artificiais. É possível a utilização desses algoritmos para a rotulação de dados não rotulados, facilitando o processo que geralmente poder ser difícil e computacionalmente caro (PATEL, 2019).

Cada problema deve ser estudado para que se possa escolher o algoritmo mais adequado para os dados disponíveis e em ambos os tipos de abordagem, havendo necessidade de uma quantidade expressiva de dados. Os algoritmos de ML conseguem produzir melhores resultados com códigos simplificados que exigiriam longas listas de regras para algoritmos convencionais e adaptando-se a novos dados (GÉRON, 2019).

Um dos pontos mais importantes no processamento de dados é a engenharia de características, que, segundo Patel (2019), pode ser considerada parte da solução, pois ajuda os algoritmos de ML a extrair informações mais robustas do dados. A engenharia de características envolve: a seleção das características na qual são escolhidas as características mais significantes para o modelo; a extração de características na qual combinam-se características para gerar mais características úteis ao problema; e a criação de novas características por meio da coleta de novos dados (GÉRON, 2019).

Dentre os métodos com a utilização de ML para identificação de irregularidades no pavimento, as Redes Neurais Artificiais RNA se destacam ao lado de algoritmos de classificação como Máquina de Vetor de Suporte - do inglês *Support Vector Machine* (SVM) e k-vizinhos mais próximos - do inglês *k-nearest neighbors* (KNN) (SOUZA *et al.*, 2018; CABRAL *et al.*, 2018; SERAJ *et al.*, 2016; BHORASKAR *et al.*, 2012). Portanto, dada a frequência de sua utilização em problemas semelhantes ao desta pesquisa e a qualidade comumente obtida de bons resultados, coube a esta dissertação o foco nas RNA, que além de sua versatilidade, conta com um considerável número de técnicas derivadas com potencial de aplicação neste trabalho.

### 2.3.1 Redes Neurais Artificiais

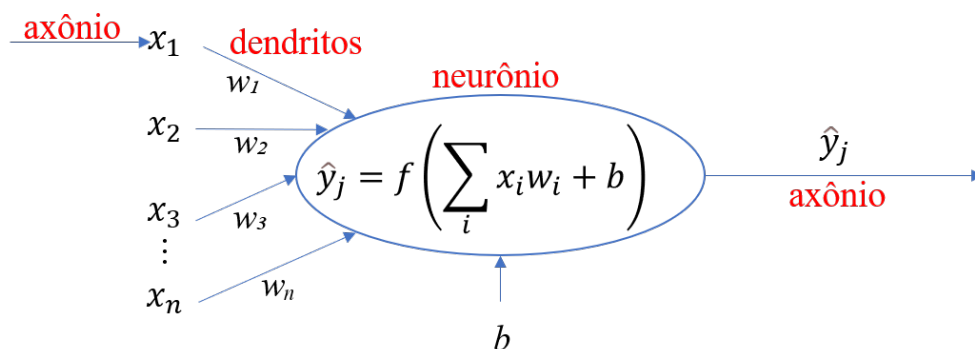
As Redes Neurais Artificiais RNA têm sua fundamentação construída na década de 40 com um modelo computacional simplificado do funcionamento do neurônio biológico, proposto pelo neurofisiologista Warren McCulloch e o matemático Walter Pitts, e como sua estrutura poderia ser utilizado por meio de lógica proposicional (GÉRON, 2019). A utilização de apenas um neurônio artificial é bem simples, porém pouco eficiente em tarefas mais complexas. A solução mais prática e direta encontrada foi o encadeamento de vários neurônios a fim de resolver essas tarefas. De forma simplificada, as redes neurais são uma série de funções encadeadas, chamadas de camadas na qual é aplicada à uma entrada de dados.

Nesta seção é apresentado as noções básicas sobre as redes neurais e algumas de suas variações.

#### 2.3.1.1 Neurônio Artificial

O neurônio artificial é descrito por Guyon (1991) como uma estrutura lógico-matemática análoga a um neurônio biológico. Sze *et al.* (2017) descrevem a estrutura onde o neurônio recebe as entradas ( $x_i$ ) via os dendritos onde é realizado um cálculo nesses sinais e cria um sinal para o axônio; esses sinais, equivalentes às sinapses neuronais, são chamados de ativações. As sinapses podem escalonar os valores das entradas por meio de uma representação numérica chamada de pesos ( $w_i$ ). No corpo celular é realizada uma soma ponderada, adicionado um viés ( $b$ ) e em seguida é aplicada uma função de ativação ( $f$ ) e o seu resultado é o valor de saída ( $\hat{y}_j$ ) desse neurônio, conforme a Figura 6.

Figura 6 – Neurônio artificial e analogia ao neurônio biológico.



Fonte: adaptado de Sze *et al.* (2017)

A função de ativação é frequentemente uma função não-linear. Existem diversas

funções de ativação utilizadas na literatura sendo apenas algumas abordadas neste trabalho como a sigmóide, Tangente Hiperbólica (TanH), a *Rectified Linear Unit* (ReLU), e a *Scaled Exponential Linear Unit* (SeLU) (Tabela 2).

Tabela 2 – Funções de ativação

Funções de ativação
$sigmoide = \sigma(x) = \frac{1}{1 + e^{-x}}$
$TanH(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
$ReLU(x) = \max(0, x)$
$SeLU(x) = \lambda \begin{cases} x & \text{if } x > 0 \\ \alpha e^x - \alpha & \text{if } x \leq 0 \end{cases}$

Na SeLU,  $\lambda$  e  $\alpha$  são dois parâmetros fixos extraídos dos próprios dados de entrada, que, quando possuem distribuição estatística de média igual a 0 e desvio padrão igual a 1, têm valores de  $\lambda \approx 1,0507$  e  $\alpha \approx 1,6732$  (COHEN, 2017).

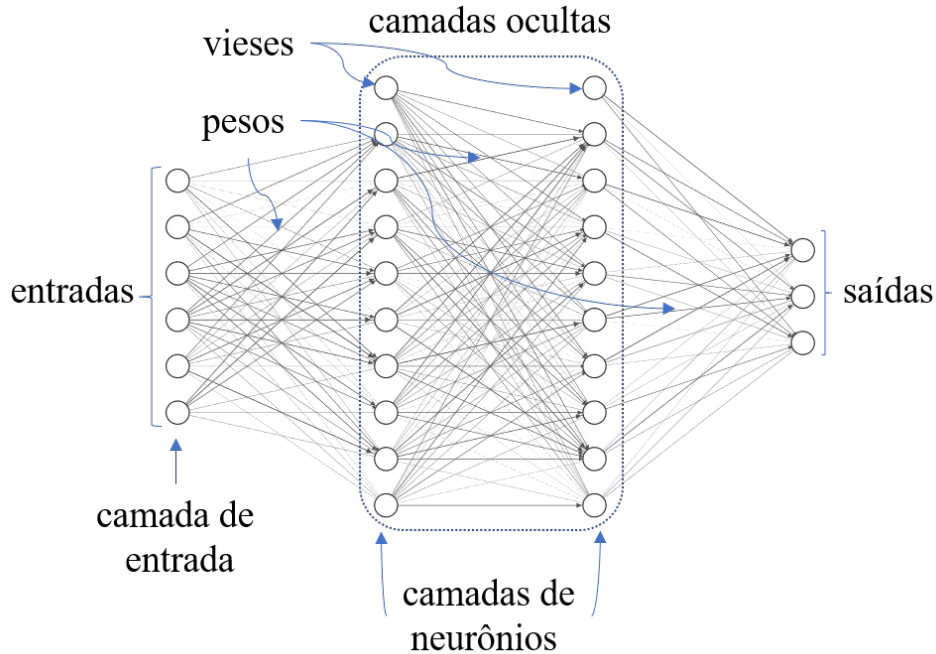
A rede neural “aprende” atualizando os pesos ( $w_i$ ) após uma conferência dos valores das saídas ( $\hat{y}_j$ ) com os valores esperados ( $y_j$ ), ajustando seus valores para uma redução do erro entre os valores de saída e os valores esperados. Essa atualização dos pesos será aprofundada nas sessões seguintes.

### 2.3.1.2 Redes Neurais Artificiais Multicamadas e Aprendizado Profundo

Uma das arquiteturas mais simples de uma RNA é o *Perceptron*, composto apenas por uma camada de neurônios. Os neurônios podem ser conectados uns aos outros fazendo com que suas saídas sejam conectadas à entrada do outro, formando uma arquitetura com mais camadas (Figura 7), como é o caso da *Perceptron* multicamadas - do inglês *Multilayer Perceptron* (MLP) quando se trata de múltiplas camadas de neurônios interligados. Quando todos os neurônios de uma camada são conectados a todos os neurônios da camada anterior, essa camada é chamada de camada densa (GÉRON, 2019). Nestes casos, as camadas que ficam entre a camada de entrada e a camada de saída são chamadas de camadas ocultas.

Goodfellow *et al.* (2016) comentam que as MLP também são conhecidas como redes profundas *feedforward*. O conceito de aprendizado profundo nasce do empilhamento de funções

Figura 7 – Exemplo de arquitetura de MLP com duas camadas de 10 neurônios e principais elementos em destaque.



Fonte: o autor

encadeadas formado pelas camadas. No entanto, o termo aprendizado profundo não deve ser atribuído apenas a uma MLP com um grande número de camadas ocultas. Como será apresentado adiante, algoritmos de aprendizado profundo são caracterizados por diferentes topologias de RNA, que guardam em comum apresentarem estruturas compostas por um grande número de operações matemáticas.


Em uma RNA as entradas ( $x_i$ ) variam de 1 a  $n$  ( $1 \leq i \leq n$ ) onde  $n$  é o número de entradas e  $y_j$  variando de 1 a  $m$  ( $1 \leq j \leq m$ ), onde  $m$  é no numero de saídas. Têm-se o envio de informação de uma camada para a outra (Figura 8), sendo  $x_i^{(k)}$  o valor de entrada da camada  $k$  de índice  $i$  no neurônio  $x_j^{k+1}$ , vindo da camada  $k + 1$  e de índice  $j$  de  $m$  é dado por:

$$x_j^{(k+1)} = f(b_j + w_{j,0}x_0^{(k)} + w_{j,1}x_1^{(k)} + \cdots + w_{j,n}x_n^{(k)}). \quad (1)$$

Portanto, percebe-se que tratando-se de varias camadas, é possível calcular as saídas de uma camada de uma só vez utilizando as matrizes correspondentes de cada termo com

$$x^{(k+1)} = f \left( \begin{bmatrix} w_{0,0} & w_{0,1} & \cdots & w_{0,n} \\ w_{1,0} & w_{1,1} & \cdots & w_{1,n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{m,0} & w_{m,1} & \cdots & w_{m,n} \end{bmatrix} \begin{bmatrix} x_0^{(k)} \\ x_1^{(k)} \\ \vdots \\ x_n^{(k)} \end{bmatrix} + \begin{bmatrix} b_0 \\ b_1 \\ \vdots \\ b_n \end{bmatrix} \right) \quad (2)$$

Figura 8 – Exemplo de transferência entra camadas de uma RNA



Fonte: o autor

ou simplesmente

$$x_j^{(k+1)} = f(Wx^{(k)} + b), \quad (3)$$

onde  $W$  é a matriz dos pesos,  $x^{(k)}$  é a matriz das entradas anterior e  $b$ , a matriz dos vieses. Estas redes, onde todos os neurônios estão conectados com os neurônios da camada seguinte, denominam-se redes neurais *feedforward*. Em contraste, Redes Neuras Recorrentes (RNR) podem apresentar neurônios de uma mesma camada conectados entre si, ou conectados a neurônios de camadas anteriores (TAN *et al.*, 2013). As RNR serão abordadas na próxima sessão.

Nos problemas de classificação, como os apresentados no presente trabalho, a última camada da rede contém um número de neurônios igual à quantidade de classes ( $N$ ) (ou rótulos) que se pretende classificar. Neste caso, é comum a utilização de uma função de ativação classificatória, como a *softmax*:

$$softmax(x)_i = \frac{exp(x_i)}{\sum_{j=1}^N exp(x_j)}, \quad (4)$$

onde seu resultado é probabilidade de valores de  $x$  pertencerem a uma classes, (GÉRON, 2019).

A rede é iniciada com os valores dos pesos completamente aleatórios, o que geralmente faz com que as saídas ( $\hat{y}_i$ ) sejam muito diferentes dos valores esperados. Para mensurar o desempenho dessa rede, com ( $w_i$ ) aleatórios, em produzir saídas mais parecidas com os valores esperados, é introduzido uma função que calcula as diferenças entre os resultados esperados e os valores produzidos pela RNA, chamada de função de custo. Uma das funções de custo

comumente utilizada em redes neurais que retornam uma probabilidade de uma determinada classe ocorrer é denominada entropia cruzada:

$$EC = L(y, \hat{y}) = - \sum_{n=1}^N y_n \log(\hat{y}_n), \quad (5)$$

onde  $y_n$  é a probabilidade da  $i$ -ésima instância pertencer a classe  $n$ . Em problemas de classificação de múltiplas classes é usualmente utilizada a função de custo “entropia cruzada categórica”, que utiliza uma ativação *softmax* como valor esperado para a distribuição de probabilidade de cada uma das classes.

Dito isso, percebe-se que uma das tarefas de uma RNA é ajustar os pesos  $w_i$  no intuito de reduzir o erro das previsões, por meio de minimização da função de custo. Nota-se que não é possível ajustar os valores dos pesos conforme a necessidade da redução do erro para múltiplas camadas utilizando a Equação 3. Esse ajuste é realizado no sentido inverso da propagação da rede por meio de um algoritmo chamado *backpropagation*. O algoritmo geralmente utilizado para minimizar a função de custo é o gradiente descendente. O gradiente descendente pode ser entendido como um vetor na direção e intensidade que os pesos e vies seguem para minimizar o “custo”. Esse cálculo é realizado por meio das derivadas parciais da função de custo em relação aos parâmetros, assim os pesos podem ser atualizados seguindo

$$w_j \leftarrow w_j - \lambda \frac{\partial L(w)}{\partial w_j}, \quad (6)$$

onde  $\lambda$  é a taxa de aprendizado. Burkov (2019) comenta que o algoritmo do gradiente descendente é sensível à escolha da melhor taxa de aprendizado e tornando-se lento para uma grande quantidade de dados, mas relata diversos algoritmos propostos como Gradiente Descendente Estocástico (GDS) (que realiza o gradiente descendente para cada amostra) e o *Adam* (que utiliza as médias móveis dos gradientes e dos quadrados dos gradientes) (KINGMA; BA, 2015) para contornar essas dificuldades.

O algoritmo *backpropagation* utiliza o método do gradiente descendente para minimizar a função custo e atualizar os pesos das RNA operando em duas fases: na primeira fase (ou fase direta), os valores dos pesos da iteração anterior são usados para calcular a saída de cada neurônio que é transmitido para a camada seguinte; e na segunda fase (ou fase de retorno), a fórmula é aplicada no sentido contrário. Deste modo, é possível utilizar o erro da camada  $k + 1$  para estimar o erro da camada  $k$  (TAN *et al.*, 2013).

Outro conceito importante é o tamanho do lote utilizado pela rede para atualização dos pesos. O tamanho do lote define a quantidade de amostras que serão propagadas pela rede


para atualização dos pesos. Géron (2019) comenta que o tamanho do lote pode melhorar bastante o desempenho da rede, principalmente no tempo de treino.

### 2.3.1.3 Redes Neurais Recorrentes

As RNRs são um tipo de arquitetura de redes neurais parecida com as vistas na seção anterior com um adicional de manterem conexões recorrentes entre as camadas, diferentemente das redes *feedforward*. Essa característica concede às RNRs robustez para problemas com dados sequenciais ou que possuam relação temporal. As RNRs usam suas conexões com as camadas anteriores e para armazenar representações dos eventos de entrada em forma de ativações (HOCHREITER; SCHMIDHUBER, 1997).

Burkov (2019) relata que essas redes são usadas para classificar, rotular ou gerar sequências e que são frequentemente usadas em processamento de texto por conta da própria anatomia dos textos ser sequencial. Os neurônios recorrentes recebem entradas ( $x_t$ ) e saídas de iterações passadas ( $y_{t-1}$ ) ( Figura 9a). Como na primeira iteração não há saídas anteriores, esse valor é comumente 0 (GÉRON, 2019). A representação gráfica de um neurônio recorrente na dimensão temporal pode ser vista na Figura 9b.

Figura 9 – (a) neurônio recorrente (b) neurônio recorrente na dimensão do tempo



Fonte: adaptado de Géron (2019).

Para o treinamento das RNRs é usado um algoritmo adaptado do *backpropagation* que ajusta os pesos da rede na dimensão do tempo ao longo de todo período somando os gradientes da função custo para cada instante de tempo ( $t$ ), chamado de *backpropagation through time* (WERBOS, 1990). Em recorrências muito longas, esses algoritmos podem sofrer do que se

chama de explosão de gradiente e desvanecimento de gradiente, que é quando o gradiente perde a relevância seja por valores muito altos ou valores muito baixos tornando a convergência da rede mais difícil (GÉRON, 2019; GOODFELLOW *et al.*, 2016; PASCANU *et al.*, 2013).


Na literatura, existem diferentes maneiras de se trabalhar com a perda de relevância do gradiente, seja pelo uso de regularização na matriz de pesos, funções de ativação, como a *ReLU*, no lugar de funções mais comuns como a sigmóide e a tangente hiperbólica, ou pelo uso de arquiteturas como a *Long Short-Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU).

#### 2.3.1.4 LSTM e GRU

Os modelos de RNRs mais utilizados na prática são as RNR com portas, como por exemplo as LSTM e as baseadas nas GRU (BURKOV, 2019). A arquitetura de RNR denominada LSTM foi inicialmente proposta por Hochreiter e Schmidhuber (1997) e atualmente é frequentemente utilizada em processamento de linguagem natural, enquanto a GRU são versões simplificadas da LSTM. (DATASCIENCEACADEMY, 2020).

A estrutura de uma LSTM é definida com a presença de células conectadas entre si de forma recorrente, eliminando o uso de unidades ocultas das RNRs (GOODFELLOW *et al.*, 2016). A arquitetura de uma célula LSTM pode ser vista na Figura 10. A grande característica das redes LSTM é o armazenamento de informações na célula por meio de portas que emulam características cognitivas como memória e esquecimento.

Figura 10 – Célula LSTM



Fonte: adaptada de Géron (2019)

A ideia principal dessa estrutura é que ela aprende a identificar padrões que devem ser guardados e padrões que devem ser descartados para fornecer ao estado seguinte apenas as

informações relevantes. Deste modo, a característica de memória da LSTM está presente em dois vetores, nomeadamente, o vetor  $h_{(t)}$  para estados de curto prazo e o vetor  $c_{(t)}$  para estados de longo prazo. As Equações 7 resumem como a célula calcula os estados das memórias nesta etapa. Há, portanto, três portas: a porta do esquecimento  $f_{(t)}$  a qual controla que parte do estado de longo prazo deve ser apagada, a porta de entrada  $i_{(t)}$  a qual controla que parte de  $g_{(t)}$  deve ser adicionada ao estado de longo prazo e a porta de saída  $o_{(t)}$  a qual decide que parte do estado de longo prazo deve ser interpretada para produzir a memória de curto prazo. Além destas três portas, temos ainda a saída  $y_{(t)}$  da célula. Deste modo, as operações de uma célula em uma LSTM podem ser sintetizadas pelo seguinte conjunto de equações:

$$\begin{aligned}
i_{(t)} &= \sigma(W_{xi}^\top x_t + W_{hi}^\top h_{(t-1)} + b_i) \\
f_{(t)} &= \sigma(W_{xf}^\top x_t + W_{hf}^\top h_{(t-1)} + b_f) \\
o_{(t)} &= \sigma(W_{xo}^\top x_t + W_{ho}^\top h_{(t-1)} + b_o) \\
g_{(t)} &= \tanh(W_{xg}^\top x_t + W_{hg}^\top h_{(t-1)} + b_g) \\
c_{(t)} &= f_{(t)} \otimes c_{(t-1)} + i_{(t)} \otimes g_{(t)} \\
y_{(t)} = h_{(t)} &= o_{(t)} \otimes \tanh(c_{(t)})
\end{aligned} \tag{7}$$

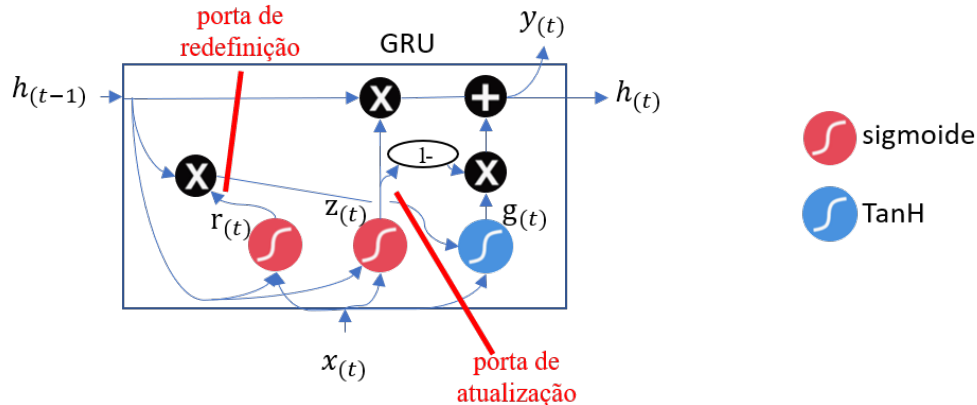
onde  $W_{xi}, W_{xf}, W_{xo}, W_{xg}$  são as matrizes de pesos de cada uma das quatro camadas conectadas ao vetor de entrada,  $W_{hi}, W_{hf}, W_{ho}, W_{hg}$  são as matrizes de pesos de cada uma das quatro camadas conectadas ao vetor de estado de curto prazo anterior  $h_{(t-1)}$ , e  $b_i, b_f, b_o, b_g$  são os vieses de cada camada (GÉRON, 2019). Sendo  $\otimes$  a multiplicação por elemento, onde cada entrada é multiplicado por seu parâmetro de escala de saída correspondente.

A célula de GRU é uma versão simplificada de uma LSTM, proposta em 2014 por Cho *et al.* (2014), onde os vetores de estados são fundidos em um único vetor de estado  $h_{(t)}$  e uma única porta controla a porta de esquecimento e a porta de saída. A Figura 11 apresenta a arquitetura de uma célula GRU.

Como não há a porta de saída, o vetor de estado é produzido em cada passo, embora a porta de redefinição  $r_{(t)}$  controle o que deve ser passado para a camada principal  $g_{(t)}$ . O cálculo do funcionamento de uma célula GRU pode ser resumido por meio das equações

$$\begin{aligned}
z_{(t)} &= \sigma(W_{xz}^\top x_t + W_{hz}^\top h_{(t-1)} + b_z) \\
r_{(t)} &= \sigma(W_{xr}^\top x_t + W_{hr}^\top h_{(t-1)} + b_r) \\
g_{(t)} &= \tanh(W_{xg}^\top x_t + W_{hg}^\top (r_{(t)} \otimes h_{(t-1)}) + b_g) \\
h_{(t)} &= z_{(t)} \otimes h_{(t-1)} + (1 - z_{(t)}) \otimes g_{(t)}
\end{aligned} \tag{8}$$

Figura 11 – Célula GRU



Fonte: adaptada de Géron (2019)

onde assim como na célula LSTM,  $W_{xz}$ ,  $W_{xr}$ ,  $W_{xg}$  são as matrizes de pesos para cada uma das camadas conectadas ao vetor de entrada e  $W_{hz}$ ,  $W_{hr}$ ,  $W_{hg}$  são as matrizes de pesos das camadas conectadas ao vetor de estado  $h_{(t)}$ .

## 2.4 Aumento de dados

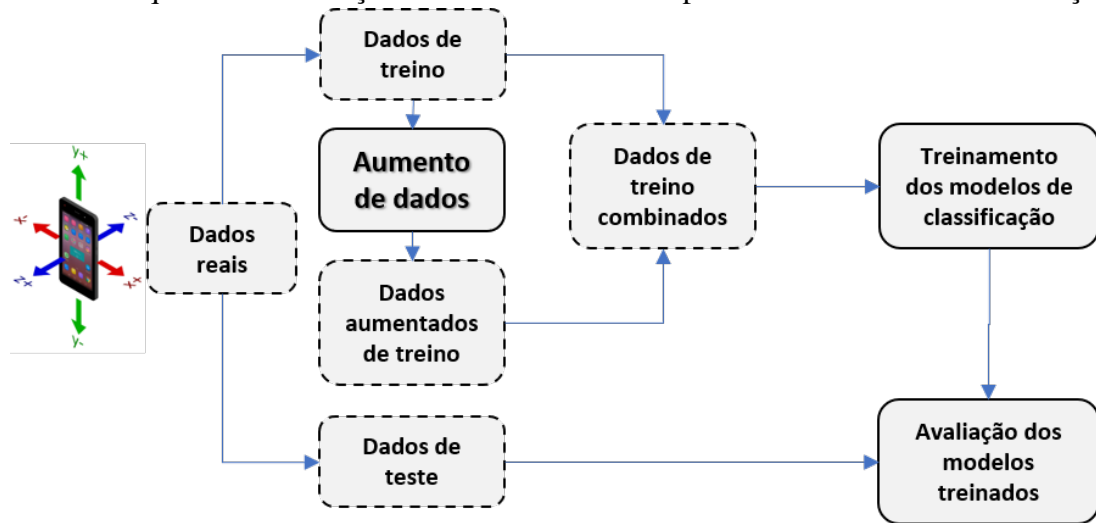
O aumento de dados é uma técnica que permite o incremento dos dados utilizados no treino de maneira artificial, por meio da criação de variações realistas dos dados de cada rótulo adotado, colaborando para a redução do sobreajuste, resultado indesejado caracterizado por um modelo que obtém um bom desempenho para os dados de treino mas não generaliza bem para outros conjuntos de dados (GÉRON, 2019). Rashid e Louis (2019a) comentam que essa é uma técnica bastante utilizada principalmente na visão computacional, onde os algoritmos são treinados a identificar elementos de uma imagem ou vídeo mas pouco explorada em classificação de sinais como series temporais, por exemplo.

Na visão computacional é comum se fazer uso da rotação de imagens assim como inclinações, redimensionamento e espelhamento, resultando em novas imagens de um mesmo objeto, por exemplo, porém com pequenas diferenças. Géron (2019) lembra que o novo conjunto de dados gerado, deva ser impossível distinguir dos dados reais por um ser humano, aumentando consideravelmente o conjunto de treino utilizado. Os dados aumentados para os modelos de classificação seguem o esquema apresentado na Figura 12.

No aumento de dados para dados de sensores, Um *et al.* (2017) descrevem algumas técnicas como:

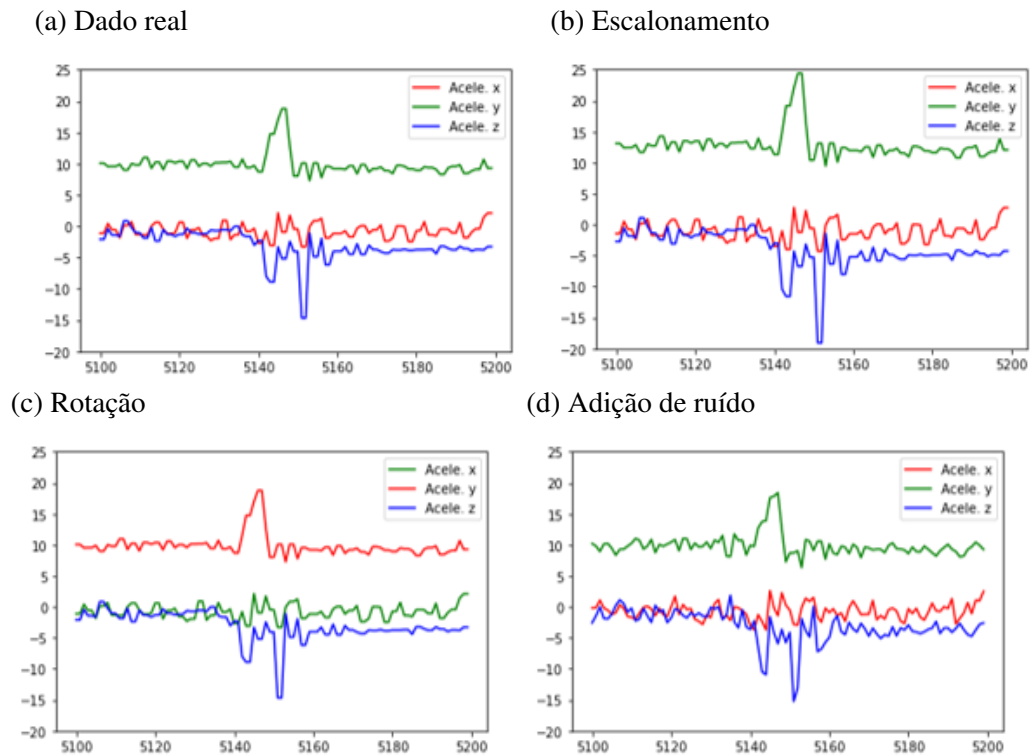
- a) Adição de ruído: são adicionados valores aleatórios aos dados originais com

Figura 12 – Esquema da utilização de aumento de dados para nos modelos de classificação.



Fonte: adaptado de Rashid e Louis (2019b)

Figura 13 – Exemplos do efeito das técnicas de aumento de dados nos dados do acelerômetro



Fonte: o autor.

- a) finalidade de simular ruídos na coleta. Geralmente esses ruídos obedecem alguma regra baseada na distribuição dos dados de cada rótulo (Figura 13d);
- b) Escalonamento: quando os dados possuem sua magnitude dilatada pela multiplicação por um fator escalar (Figura 13b);
- c) Rotação: quando os dados dos eixos são rotacionados arbitrariamente para maior variação, simulando diferentes posições dos aparelhos (Figura 13c).

## 2.5 Métricas de desempenho

Um dos desafios mais comuns encontrados nos problemas de classificação é o desbalanceamento dos dados utilizado nos conjuntos de treino e de teste. Em modelos que tratam problemas de classificação que possuem duas ou mais classes é muito comum que a quantidade de dados disponíveis para cada classe não sejam iguais, fazendo com que métricas como acurácia, que é basicamente a proporção de predições corretas, não retratem bem o resultado dos modelos (BRUCE; BRUCE, 2017). Métricas alternativas podem ajudar a avaliar os modelos, principalmente em classificações como mais de 2 rótulos.

A Matriz de Confusão (MC) é um formato de apresentação das predições dos modelos de classificação em formato de tabela onde é apresentado o número de predições corretas e incorretas do modelo categorizado pelo tipo do rótulo adotado. Geralmente os valores das colunas são as predições do modelo, enquanto as linhas representam o valor real (BRUCE; BRUCE, 2017). Por exemplo, em um problema binário onde há apenas dois casos (A e B, neste caso), é possível observar os valores corretos das predições do modelo na diagonal principal, e abaixo e acima da diagonal principal os falsos positivos e falsos negativos respectivamente (Figura 14).

Figura 14 – Exemplo de Matriz de confusão para classificação binária.

		predição do modelo	
		A	B
valor real	A	verdadeiro positivo	falso negativo
	B	falso positivo	verdadeiro negativo

Fonte: adaptado de Bruce e Bruce (2017)

Outras métricas apresentadas neste trabalho são o *f1-score*, *recall* e a precisão. O *f1-score* é uma métrica de equilíbrio entre o *recall* e a precisão. O *recall* é a razão entre os verdadeiros positivos sobre os falsos negativos e a precisão é a razão entre os verdadeiros positivos sobre os falsos positivos:

$$recall = \frac{\sum VerdadeiroPositivo}{\sum VerdadeiroPositivo + \sum FalsoPositivo} \quad (9)$$

$$precisão = \frac{\sum VerdadeiroPositivo}{\sum VerdadeiroPositivo + \sum FalsoNegativo}. \quad (10)$$

O *recall* mede a força do modelo em prever um resultado positivo corretamente enquanto a precisão mostra a proporção de instâncias de uma classe identificada corretamente. O *f1-score* é um balanço entre essas duas métricas conforme (WITTEN *et al.*, 2017):

$$f1-score = \frac{2 * recall * precisão}{recall + precisão}. \quad (11)$$

## 2.6 Trabalhos relacionados

Na última década, diversos trabalhos foram publicados com a utilização de técnicas de aprendizado de máquina com dados de smartphones para identificação de irregularidades no pavimento (Tabela 3) e índices de irregularidade (como o IRI) (NGUYEN *et al.*, 2019). Dentre esses trabalhos, há diversas abordagens de algoritmos de aprendizado de máquinas seja para o processamento dos sinais obtidos através de sensores embutidos nos aparelhos ou o processamento digital de imagens capturadas com a câmera dos mesmos.

Os dados dos sensores dos smartphones são coletados à uma frequência captura predefinida que variam de 38 *Hz* até 100*Hz*. Assim como a frequência de captura, os estudos costumam adotar uma janela de observação, compostas por um número fixo de leituras coletadas ou um intervalo de tempo, para geração das amostras trabalhadas. É observado uma diversidade de abordagens quanto à frequência de captura e janela de observação que geralmente variam dependendo da abordagem adotada. Trabalhos de referência como Eriksson *et al.* (2008) e Mohan *et al.* (2008) na identificação de buracos utilizam sensores móveis capazes de coletar dados a frequências mais altas (380*Hz*).

Tabela 3 – Trabalhos Relacionados com uso de ML para identificação de irregularidades de superfície

Autor(es)	Abordagem	Janela de Análise	Sensores Utilizados	Freq. de capturas de amostras (Hz)	Veículo	Modelo de Smartphone	Distância do Experimento
Perttunen <i>et al.</i> (2011)	SVM	0,5s a 2s	Acelerômetro	38	n/a	Nokia N95 8GB	25km
Bhoraskar <i>et al.</i> (2012)	K-means, SVM	n/a	Acelerômetro	50	Suzuki access 125, Auto rickshaw	Google Nexus S, HTC Wildfire S	n/a
Douangphachanh e Oneyama2013	Regressão Linear	n/a	Acelerômetro	100	Toyota Vigo 4WD, Camionete; Toyota Camry, Vigo 2WD, Yaris	Samsung Galaxy Note 3, Galaxy S3, LG 4X HD	n/a
Mohamed <i>et al.</i> (2015)	SVM	n/a	Acelerômetro e Giroscópio	n/a	Volkswagen Jetta, Chevrolet Aveo	Lumia 820	n/a
Jain e Singh JIIT (2012)	SVM	n/a	Acelerômetro	n/a	Onibus, Auto-riquexá, Ciclo-riquixá, 4 modelos diferentes Motocileta e Carro (sem modelos especificados)	co OS Android (sem especificações)	678km
Seraj <i>et al.</i> (2016)	SVM	128 e 256	Acelerômetro e Giroscópio	93	Toyota Corolla e Yaris, Peugeot 306, Skoda Fabia e BMW X3	Galaxy S2	100 km
Silva <i>et al.</i> (2017)	Comparação de vários algoritmos	125	Acelerômetro	50	Três modelos diferentes	2 modelos diferentes (sem especificações)	n/a
Cabral <i>et al.</i> (2018)	Comparação de vários algoritmos	2s	Acelerômetro	100	Toyota Hi-Lux Triton, Mitsubishi Pajero e Toyota Land Cruiser Prado	Samsung Galaxy S-8 e Galaxy A-5; e Asus ZenFone4	200km
Souza <i>et al.</i> (2018)	SVM	5s e 10s	Acelerômetro	100	Hyundai i30	Samsung Galaxy S7 e Galaxy S8	161 e 1221 km

Fonte: o autor

### 3 MÉTODO DE PESQUISA

Neste capítulo, será apresentado os métodos utilizados para coleta e rotulação dos dados por meio de smartphones, assim como o processamento dos dados adotado.

O processo inicia-se pela coleta dos sinais dos sensores do smartphone acoplado ao para-brisa do veículo, tais como localização geográfica e acelerações, seguido do processamento dos dados que inclui a engenharia de características e a rotulação, para a análise dos modelos de classificação desenvolvidos. A Figura 15 ilustra o processo de identificação de irregularidades na superfície dos revestimentos por meio de sensores embutidos em smartphones da maioria dos trabalhos relacionados.

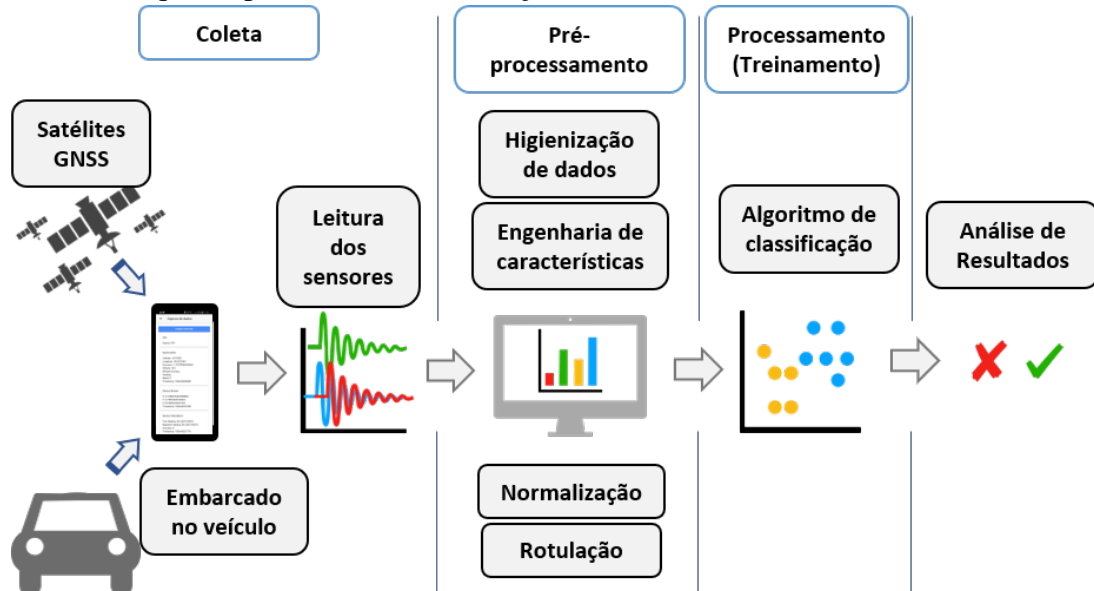
Figura 15 – Esquema processo de identificação de irregularidades de superfície no pavimento por meio de sensores de smartphones.



Fonte: O autor

De forma mais específica, para este trabalho têm-se a Figura 16 ilustrando o processo de aquisição de dados, rotulação e classificação dos trechos por meio de algoritmos que serão detalhados nas sessões seguintes.

Figura 16 – Esquema processo de classificação dos sinais obtidos.



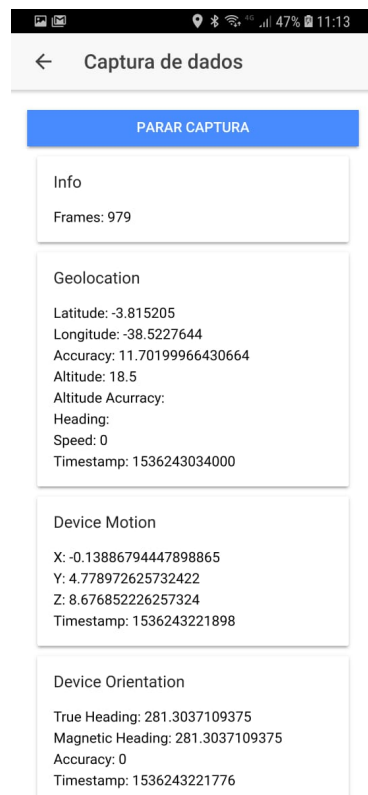
Fonte: o autor

### 3.1 Coleta de dados

Inicialmente, foi desenvolvido um aplicativo (Figura 17a), capaz de coletar os dados dos sensores do smartphones referentes a valores de aceleração, velocidade e orientação do dispositivo em todos os eixos, assim como a localização correspondente. O veículo utilizado na coleta foi um *Toyota Etios hatch* modelo 2014 e os smartphones *Redmi Note 7 (Rn7)* e *Mi9* da marca *Xiaomi*, ambos com sistema operacional *Android*. A rota escolhida está localizada no *Campus* do Pici da Universidade Federal do Ceará (UFC), em Fortaleza (Figura 17b). O trecho possui, aproximadamente, 4,7km, e foi escolhido visando contemplar uma diversidade de elementos, tais como tachões, lombadas, buracos, revestimento asfáltico e em pedra, que tiveram suas localizações mapeadas para o processo de rotulação por meio do *software* de Sistema de Informação Geográfica (SIG): QGIS, abordado na sessão seguinte.

Figura 17 – Aplicativo e trecho escolhido.

(a) Tela do aplicativo em coleta. (b) Trecho usado na coleta de dados na Universidade Federal do Ceará, *Campus do Pici*, Fortaleza, CE



Fonte: o autor.

Uma gravação em vídeo simultânea, feita por um *tablet*, foi adotada no auxílio do mapeamento e rotulação dos sinais obtidos. A Figura 18 mostra o procedimento realizado nessa coleta de dados durante a rota.

Figura 18 – Coleta de informações sobre o trecho e gravação de vídeo.



Fonte: o autor

O smartphone foi fixado na região central do para-brisa do veículo (Figura 19a) com um suporte rígido, tri-articulado de ventosa (Figura 19b), sendo preservada uma posição vertical do aparelho com a tela para o interior do veículo visando facilitar a utilização do aplicativo; dessa forma, não foi preciso nenhuma análise posterior dos sensores para determinar a orientação do dispositivo. Isso posto, a orientação dos eixos dos sensores do smartphone ficou conforme disposto na Figura 19c.


Figura 19 – Coleta sendo realizada, suporte e eixos do dispositivo.



(a) Coleta com ambos os smartphones.



(b) Suporte utilizado.



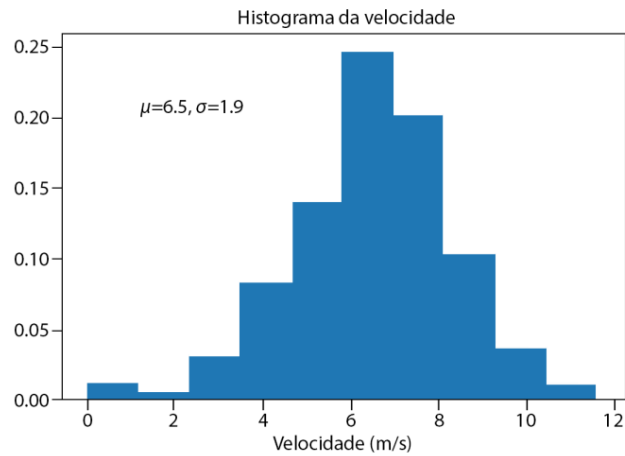
(c) Eixos do dispositivo acoplados ao veículo.

Fonte: o autor.

### 3.2 Rotulação dos dados

O receptor GNSS, diferente dos demais sensores utilizados, possui uma frequência de captura fixada em  $1Hz$ . Portanto, a localização só é atualizada a cada segundo e, para cada ponto georreferenciado de coleta, tem-se 20 leituras associadas aos demais sensores que operam à uma frequência de captura de  $20Hz$ . Nessas condições, é presumível que o veículo esteja alguns metros à frente da localização apontada pelo sensor, dependendo da velocidade desenvolvida. Os dados utilizados nos modelos referentes à velocidade desenvolvida estão dispostos na Figura 20.


Figura 20 – Histograma das velocidades coletadas.



Fonte: o autor

A fim de reduzir os possíveis erros de localização descritos pela baixa frequência de captura do receptor GNSS, as leituras obtidas dos demais sensores foram atribuídos a 19 novos pontos, distribuídos entre as localizações de leituras do receptor GNSS consecutivas, por meio de uma interpolação linear como ilustra a Figura 21. Dessa forma, a distância física entre as leituras foram reduzidas, melhorando-se o processo de rotulação .

Figura 21 – Exemplo de interpolação de pontos aplicada.



Fonte: o autor

A rotulação adotada se iniciou pelo mapeamento das interferências encontradas no trajeto por meio da criação de polígonos contemplando suas localizações no *software* QGIS. Foram mapeadas diversas interferências nos pavimentos, tais como lombadas, tachões, buracos, passagens elevadas, assim como o tipo do pavimento encontrado e as leituras foram rotuladas como se tivessem sua localização contida nesses polígonos (Figura 22) usando o ferramental contido no *software*.

Figura 22 – Exemplo dos polígonos das interferências - Rotulação.



Fonte: o autor

Neste trabalho foram exploradas três abordagens quanto às rotulações:

- a) aos tipos de revestimentos;
- b) à ocorrência de eventos, ou seja, interferências na via;
- c) aos tipos de eventos encontrados.

Apenas dois tipos de revestimentos foram contemplados no trajeto escolhido: asfáltico e em pedra conforme as Figuras 23a e 23b respectivamente. Nos tipos de evento, as passagens elevadas (Figura 24c) e lombadas (Figura 24a) foram classificadas como “lombada”, totalizando três tipos de interferências: buraco, lombada e tachão.

Figura 23 – Revestimentos encontrados no trecho.



(a) Revestimento asfáltico.

(b) Revestimento em pedra.

Fonte: o autor.

Figura 24 – Exemplos das irregularidades e pavimento classificados.

(a) Lombada (asfalto)

(b) Lombada (pedra)



(c) Passagem elevada

(d) Buraco



(e) Tachão (pedra)


(f) Tachão (asfalto)



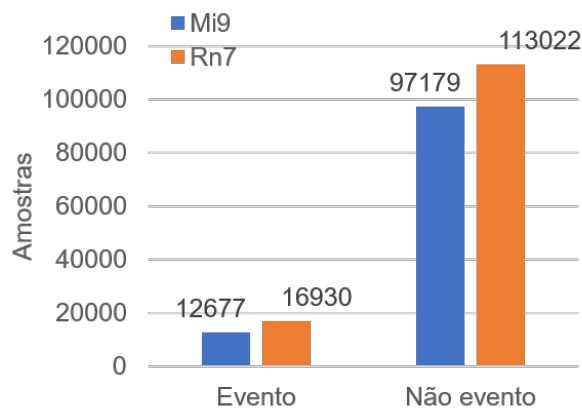
Fonte: o autor.

Ao total, foram coletados mais de duzentos e trinta mil leituras de cada sensor, de ambos os smartphones que, após o processo de rotulação, foram classificados conforme a abordagem adotada: quanto aos tipos de pavimentos (Figura 25a), quanto à ocorrência de eventos (Figura 25b) e quanto aos tipos de eventos encontrados (Figura 25c). Além disso, os dados também foram rotulados de acordo com os aparelhos utilizados na coleta (Mi9 e Rn7).


Figura 25 – Contagem dos dados por classificação adotada.



(a) Contagem dados por tipo de pavimento.



(b) Contagem dados sobre ocorrência de eventos.



(c) Contagem dados por tipo de evento.

### 3.3 Pré-processamento de dados

Para a utilização de RNR, foi adotada uma janela de observação de 20 leituras consecutivas dos sensores. A engenharia de características deu-se pela utilização e extração de características baseadas nos dados coletados, gerando mais informações sobre os sinais, como por exemplo: parâmetros estatísticos (médias, desvios padrões e variâncias), informações sequenciais e relações entre características. No total, mais de 50 características foram extraídas e testadas a fim de selecionar as que obtivessem melhor desempenho nos modelos. As características selecionadas e utilizadas neste trabalho são apresentadas na Tabela 4 .

Tabela 4 – Características utilizadas.

Origem		Características
Acelerômetro	Desvio Padrão	$y, z, Ac\_Resul, Ac\_Lin, Ac\_Lin^2$
	Média	$x, y, z, Ac\_Resul, Ac\_Lin, Ac\_Lin^2$
	Média móvel	$x, y, z, Ac\_Resul, Ac\_Lin, Ac\_Lin^2$
	Variância	$y, Ac\_Resul, Ac\_Resul$ $x, y, z, Ac\_Resul, Ac\_Lin$
GNSS	Velocidade	$V$
Giroscópio	Desvio Padrão	$y, z$
	Média	$y, z$
	Variância	$y, z$
Relação		$V/Ac\_Lin,$ $V^2/Ac\_Lin,$ $ac\_y/V,$ $ac\_y/V^2$

$x, y, z$ : são os eixos coletados;

$Ac\_Resul$ : é o módulo da aceleração dos três eixos;

$Ac\_Lin$ : é a aceleração linear;

$V$ : é a velocidade planar.


A aceleração resultante ( $Ac\_Resul$ ), ou o módulo das acelerações, pode ser definida pela Equação 12, que utiliza as acelerações em todos os eixos ( $Ac_x$ ,  $Ac_y$  e  $Ac_z$ ) que são coletadas do acelerômetro em cada instante de leitura. A aceleração linear ( $Ac\_Lin$ ) é a diferença entre o módulo das acelerações e a aceleração da gravidade, que foi coletada com o smartphone completamente parado, em orientação conhecida no valor de  $9,8 m/s^2$ .

$$Ac\_Resul = \sqrt{Ac_x^2 + Ac_y^2 + Ac_z^2}. \quad (12)$$

Devido às baixas velocidades assumidas em vias urbanas, os sinais dos sensores

ficam sujeitos às mudanças bruscas referentes às frenagens e arranques do veículo. Isso ocasiona leituras poluídas com movimentos que não são característicos do rolamento, dificultando a rotulação dos sinais. Portanto, as leituras que continham valores de velocidade menores que  $10 \text{ km/h}$  foram desprezadas. Outra prática adotada durante a higienização dos dados foi a sequencialidade dos dados no uso das redes neurais recorrentes. Foi decidido adotar janelas de observação com 20 leituras, deste modo apenas dados sequenciais com no mínimo este tamanho foram mantidos, desprezando quaisquer sequências incompletas, seja devido à baixas velocidades ou eventuais erros nos sensores. Ainda no tratamento dos dados para essas redes neurais, além da janela de observação foi adotado um passo de 10 leituras, interligando amostras sequenciais e contribuindo para a diversidade dos dados conforme ilustra a Figura 26.

Figura 26 – Exemplo de amostragem das leituras com janela de observação igual a 4 e passo igual a 2, para as redes neurais recorrentes.



No pré-processamento dos dados, é necessário um escalonamento das características, pois a maioria dos algoritmos de aprendizado de máquina não funcionam bem quando possuem suas características em diferentes ordens de grandeza. Além de ajudarem os algoritmos a terem seu desempenho melhor, o escalonamento das características por meio de uma padronização, mantém os valores menos afetados por *outliers* (GÉRON, 2019). Isso posto, cada uma das características tiveram seus valores ( $x_{std}$ ) escalonados por meio de uma padronização (Equação 13).

$$x_{std} = \frac{x - \mu}{std}. \quad (13)$$

Após a engenharia de características e a higienização, os dados foram organizados de modo a compor modelos de acordo com o apresentado na Tabela 6 para as RNR. Tradicionalmente em trabalhos com uso de redes neurais é adotado conjuntos de treino e teste que variam entre 70% a 80% para os dados de treino e 30% a 20% para os dados de teste, porém esses percentuais

podem depender da quantidade de dados (GÉRON, 2019). Devido à pouca quantidade de dados rotulados como “buraco” em relação aos demais rótulos, a divisão dos conjuntos ficou de acordo com a Tabela 5, permitindo que o modelo pudesse ser testado em mais amostras para esse tipo de classificação.

Tabela 5 – Divisão dos conjuntos de treino e teste para cada tipo de abordagem.

	Tipo de pavimento	Evento e não evento	Tipo de evento
Treino	47%	47%	45%
Teste	53%	53%	55%

Após a separação dos conjuntos foi utilizado técnicas de aumento de dados apenas no conjunto treino. Assim, o conjunto de teste de todos os modelos utilizados neste trabalho é composto apenas de dados reais. O balanceamento dos dados nos conjuntos foi feito com base no rótulo de menor recorrência, para evitar um treinamento excessivo das categorias com maior quantidade de dados. Desse modo, em alguns modelos, parte das amostras não são utilizadas, como apresentado na Tabela 6.

Em seguida, foram utilizadas três técnicas de aumento de dados: escalonamento, rotação e adição de ruído. Todos os dados aumentados foram retirados do conjunto de treino e aplicadas as técnicas em seis níveis diferentes. Para o escalonamento foram adotadas as escalas de 0,93; 0,95; 0,97; 1,03; 1,05; 1,10 e para a adição de ruído, foi utilizado seis variações aleatórias de ruído baseadas no desvio padrão característico de cada rótulo, variando de  $-0,25$

Tabela 6 – Divisão dos conjuntos de treino e teste para as redes neurais recorrentes

	Todas as amostras	Treino	Teste	Treino Balanceado	Teste Balanceado
Tipo de pavimento					
Pav. Asfáltico	10.448	5.419	5.029	4.221	5.029
Pav. Pedra	10.271	4.221	6.050	4.221	5.029
TOTAL	20.719	9.640	11.079	8.442	10.058
Evento e Não evento					
Evento	3.033	1.495	1.538	1.495	1.538
Não Evento	20.873	9.679	11.194	1.495	1.538
TOTAL	23.906	11.174	12.732	2.990	3.076
Tipos de evento					
Buraco	227	113	114	113	114
Lombada	632	259	373	113	114
Tachão	665	321	344	113	114
TOTAL	1.524	2.693	831	339	342



Cada arquitetura foi testada para diferentes quantidades de neurônios (16, 32 e 64), e para diferentes tamanhos de lotes (16, 32 e 64) utilizados em cada iteração. Para ambos os tipos de rede, foi realizado o refinamento dos hiperparâmetros como as funções de ativação utilizadas (ReLU, SeLU e TanH) e o método de otimização (*Adam* e GDS) para o melhor valor de acurácia nos testes. A função de perda usada foi a *categorical cross-entropy* (ou entropia cruzada categórica) para os dois tipos de rede.

## 4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Neste capítulo, serão apresentadas as análises e resultados dos modelos treinados quanto aos tipos de eventos, quanto à presença de eventos e quanto ao tipo do pavimento encontrado. Também será apresentado resultados para modelos onde a utilização de técnicas de aumento de dados foram empregadas. Finalmente será discutido suas aplicabilidades a Sistemas de Gerência de Pavimentos Urbanos (SGPU)

### 4.1 Quanto aos tipos de eventos encontrados

A princípio foram testadas e analisadas 306 arquiteturas de modelos diferentes, incluindo redes simples e profundas com neurônios recorrentes e simples. Todos os modelos testados foram executados pelo menos cinco vezes e tiveram seus resultados registrados, sendo expostas as médias obtidas a fim de reduzir um pouco o caráter aleatório da inicialização dos modelos em cada treino. Foi utilizada a abordagem da rotulação entre os tipos de eventos para o refinamento dos modelos, uma vez que essa categoria possui uma menor quantidade de dados. Para a maioria dos modelos testados o melhor otimizador encontrado foi o *Adam* e a função de ativação que obteve os melhores resultados foi a *ReLU*.

Para os dados reais sem aumento de dados, os modelos de cada arquitetura testada que apresentaram melhor desempenho para a rotulação entre os tipos de eventos obtiveram acurácias próximas de 80%, como mostra a Tabela 9.

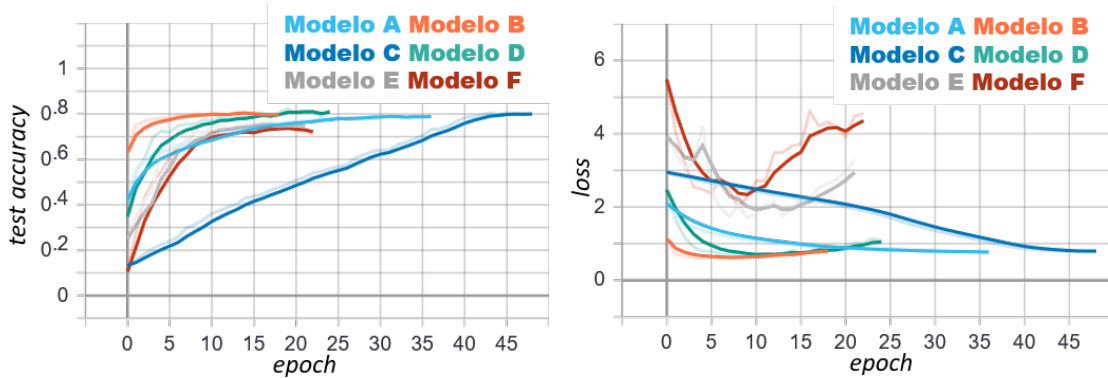
Tabela 9 – Melhores ajustes de quantidade de neurônios e tamanho do lote para cada arquitetura

Modelo	Arquitetura do modelo*	Quantidade de Neurônios na camada	Tamanho do Lote	Acurácia	Desvio Padrão (Acurácia)
A	1xDense	16	32	79,27%	0,11%
B	2xDense	32 e 16	16	79,95%	0,52%
C	1xGRU	16	64	81,11%	0,40%
D	2xGRU	32 e 32	16	82,40%	0,69%
E	1xLSTM	64	16	76,78%	0,55%
F	2xLSTM	32 e 32	16	74,91%	0,39%

\*Quantidade de camadas ocultas x Tipo de camada

Vale ressaltar que a arquitetura dos modelos utilizando duas camadas ocultas com neurônios simples (Modelo B) e neurônios recorrentes GRU (Modelo D), ambos usando tamanho de lote igual a 16, convergiram mais rápido e apresentaram baixos valores de erro (Figura

Figura 27 – Evolução dos modelos no conjunto de teste.



(a) Evolução da acurácia no teste.

(b) Evolução do erro no teste.

27). A utilização de tamanhos de lotes menores testados se mostrou, de fato, mais eficiente no desempenho desses modelos, proporcionando uma convergência mais rápida e estável no conjunto de teste, como Masters e Luschi (2018) comentam acerca da utilização de lotes menores que 32 unidades no treinamento de redes neurais profundas.

Na Figura 28 é possível observar as matrizes de confusão de alguns treinos dos modelos apresentados para os tipos de eventos rotulados. A Tabela 10 apresenta outras métricas analisadas para os mesmos modelos.

Figura 28 – Matrizes de confusão para as melhores iterações de cada modelo apresentado

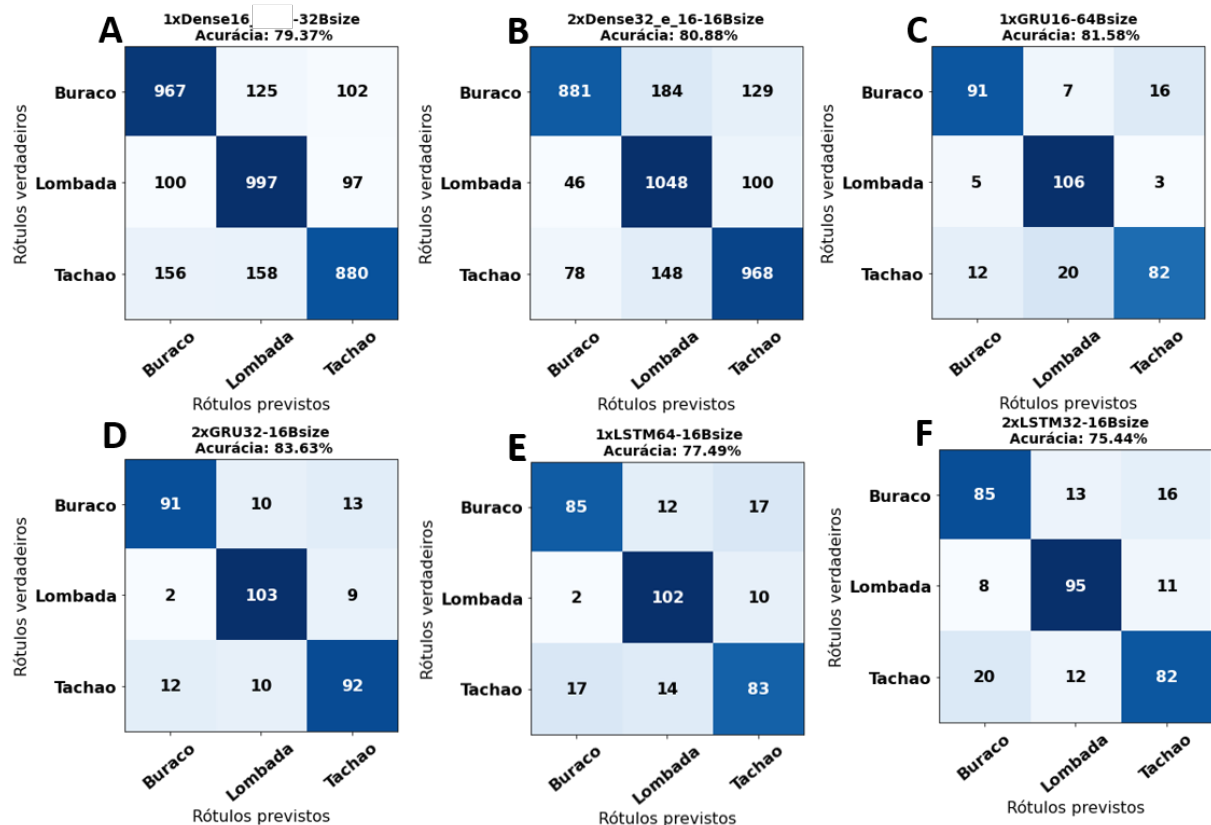


Tabela 10 – Métricas dos modelos apresentados quanto aos tipos de eventos encontrados

Modelos	A	B	C	D	E	F
Rótulos	Precisão					
Buraco	0,7936	0,8664	0,8413	0,8605	0,8206	0,7558
Lombada	0,7773	0,7423	0,7888	0,8373	0,7949	0,7698
Tachão	0,8117	0,8129	0,8151	0,7810	0,7274	0,7540
Total Geral	0,7942	0,8072	0,8151	0,8263	0,7810	0,7598
Rótulos	Recall					
Buraco	0,8005	0,7141	0,8000	0,7895	0,7526	0,7070
Lombada	0,8374	0,8834	0,9298	0,8825	0,8632	0,8491
Tachão	0,7404	0,8010	0,7035	0,8000	0,6877	0,6912
Total Geral	0,7927	0,7995	0,8111	0,8240	0,7678	0,7491
Rótulos	f1-score					
Buraco	0,7970	0,7828	0,8201	0,8233	0,7850	0,7297
Lombada	0,8061	0,8066	0,8535	0,8590	0,8274	0,8074
Tachão	0,7744	0,8069	0,7552	0,7903	0,7070	0,7205
Total Geral	0,7925	0,7988	0,8096	0,8242	0,7731	0,7525

Vale destacar que os modelos C e D, sendo os únicos modelos destas arquiteturas a obterem resultados de *f1-score* acima de 80%. O *recall* para o rótulo de lombada, de todos os modelos, tiveram valores melhores, mostrando-se eficiente nas confirmações deste rótulo.

Após este primeiro momento, foi realizada uma triagem nos modelos que obtiveram melhores resultados e a fim de aprofundá-los nas demais abordagens de rotulação. Além disso, algumas variações de arquitetura utilizadas como a mesclagem dos tipos de neurônios e quantidade de camadas de cada tipo utilizados como descrito Tabela 11. Os ajustes para esses modelos também seguiu a mesma metodologia dos demais, sendo testados para 16, 32 e 64 neurônios em cada camada. Adicionalmente, os tamanhos de lotes utilizados foram também testados, sendo aqui apresentados apenas as arquiteturas com os melhores desempenhos.


Tabela 11 – Melhores ajustes de quantidade de neurônios e tamanho do lote para a arquiteturas com mais camadas e diferentes tipos de neurônios

Modelo	Arquitetura do modelo*	Tamanho do Lote	Acurácia	Desvio Padrão (Acurácia)
C*	1xGRU(64) + 2xDense(16)	16	82,34%	0,30%
D*	2xGRU(64) + 2xDense(32)	16	82,40%	0,71%
E*	1xLSTM(64)+ 2xDense(16)	64	81,05%	0,48%
F*	2xLSTM(64) + 2xDense(16)	16	81,05%	1,10%

\*Quantidade de camadas x Tipo da camada (neurônios na camada)

Na Figura 30 é possível observar as matrizes de confusão de alguns treinos dos modelos C\*, D\*, E\* e F\*. Observou-se uma melhora evidente na acurácia dos modelos com neurônios LSTM quando aliados à camadas densas, apesar da volatilidade na curva do erro (Figura 29). Os modelos com neurônios GRU e camadas densas não apresentaram grande melhoria quanto à acurácia, mantendo-a acima de 82%. Contudo, estes apresentaram menor tempo de convergência e menores valores de erro, o que os tornam mais eficientes.

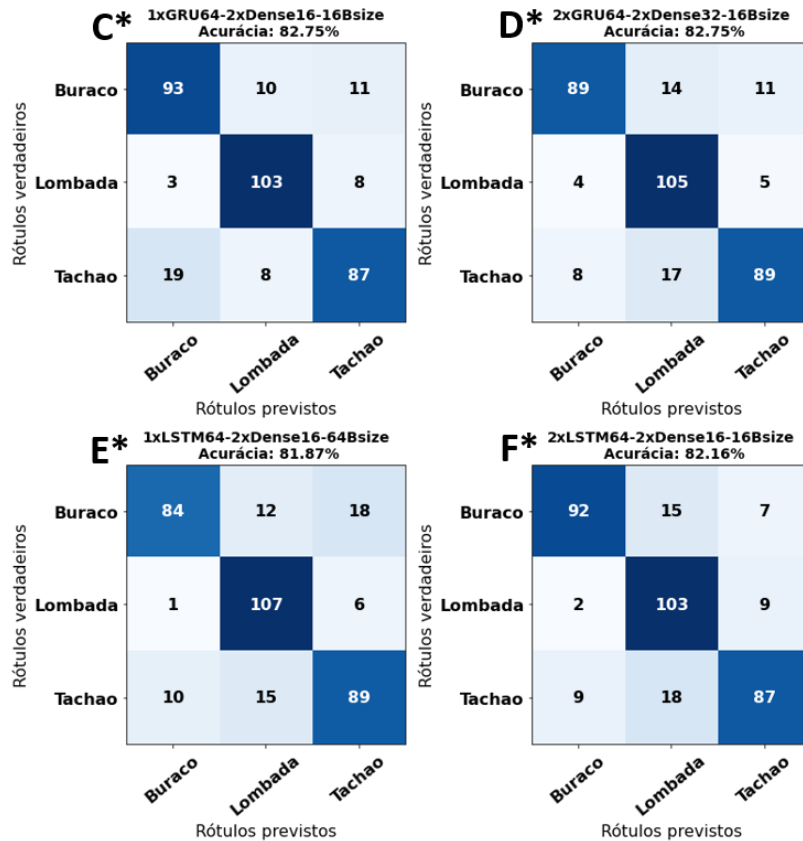
Figura 29 – Evolução dos novos modelos no conjunto de teste.



(a) Evolução da acurácia no teste.

(b) Evolução do erro no teste.

Figura 30 – Matrizes de confusão para as melhores iterações dos novos modelos C\*, D\*, E\* e F\*



## 4.2 Quanto à presença de eventos

Devido os resultados com as arquiteturas envolvendo mais camadas ocultas, neurônios recorrentes GRU, camadas densas e tamanho de lotes menores para os modelos quanto ao tipo de evento, resolveu-se utilizar essas arquiteturas para os demais tipos de rotulações adotadas. Para as rotulações quanto à presença de eventos foram testadas 54 arquiteturas de modelos diferentes utilizando 1 ou 2 camadas de neurônios recorrentes GRU seguidas ou não de até duas camadas densas com 16, 32 ou 64 neurônios por camada. As melhores combinações de arquitetura para cada tipo testadas para essa rotulação estão dispostas na Tabela 12.

Tabela 12 – Melhores ajustes de quantidade de camadas e neurônios com neurônios GRU e simples para identificação de eventos.

Modelo	Arquitetura*	Tamanho do Lote	Acurácia	Desvio Padrão (acurácia)
A(e)	1xGRU(64) +2xDense(16)	16	83,10%	0,23%
B(e)	2xGRU(32) + 2xDense(32)	16	82,91%	0,25%
C(e)	1xGRU(16)	16	82,31%	0,06%
D(e)	2xGRU(16)	16	83,02%	0,29%


\*Quantidade de camadas x Tipo da camada (neurônios na camada)

Como apresentado na Tabela 12, os modelos A(e) e D(e) apresentaram os melhores valores de acurácia dentre os modelos testados. A diferença, no entanto, não é significativa, apesar do modelo D(e) apresentar uma maior estabilidade na curva do erro (Figura 31). Na Figura 32 é possível observar as matrizes de confusão de alguns treinos dos modelos apresentados para a identificação de evento. A Tabela 13 apresenta as outras métricas analisadas dos mesmos modelos.

## 4.3 Quanto ao tipo do pavimento

Para a rotulação quanto ao tipo do pavimento, foram testados 54 modelos, utilizando a mesma lógica de teste de modelos quanto à presença de eventos. Aqui, será apresentado apenas os melhores ajustes dos modelos quanto à quantidade neurônios de cada camada (Tabela 14). Todos os modelos testados obtiveram acurácias acima de 98%, com destaque para os modelos utilizando camadas recorrentes e densas, as quais apresentam menores valores de erro como apresentado na Figura 33.

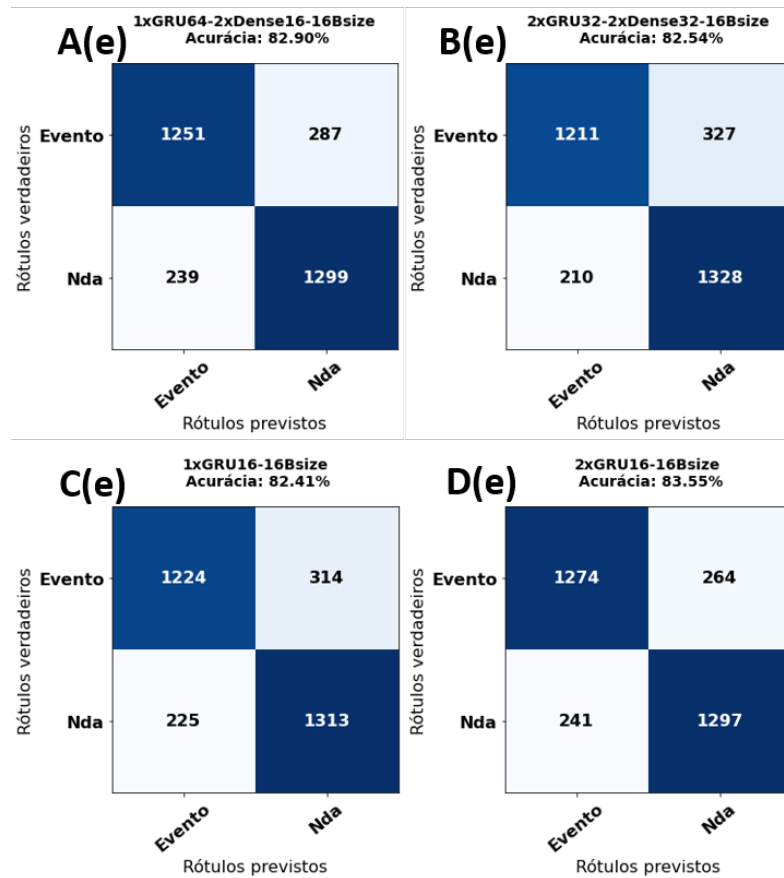
Figura 31 – Evolução dos modelos quanto à presença de eventos.



(a) Evolução da acurácia no teste.

(b) Evolução do erro no teste.

Figura 32 – Matrizes de confusão para as melhores iterações dos modelos quanto à identificação de eventos e Não Eventos(Nda)



Na Figura 34 é possível observar as matrizes de confusão de alguns treinos dos modelos apresentados para o tipo de pavimento encontrado. A Tabela 15 apresenta as outras métricas analisadas dos mesmos modelos.

Tabela 13 – Métricas dos modelos utilizados na rotulação de Evento e Não Evento


Modelos	A(e)	B(e)	C(e)	D(e)
Rótulos	Precisão			
Evento	0,8300	0,8307	0,8350	0,8330
Não Evento (Nda)	0,8331	0,8294	0,8151	0,8290
Total Geral	0,8316	0,8300	0,8251	0,8310
Rótulos	Recall			
Evento	0,8334	0,8280	0,8069	0,8273
Não Evento (Nda)	0,8286	0,8302	0,8393	0,8330
Total Geral	0,8310	0,8291	0,8231	0,8302
Rótulos	f1-score			
Evento	0,8314	0,8287	0,8206	0,8298
Não Evento (Nda)	0,8305	0,8292	0,8269	0,8307
Total Geral	0,8309	0,8289	0,8238	0,8303

Tabela 14 – Melhores ajustes de quantidade de camadas e neurônios com neurônios GRU e simples para identificação do tipo de pavimento.

Modelo	Arquitetura*	Tamanho do Lote	Acurácia	Desvio Padrão (acurácia)
A(p)	1xGRU(64) + 2xDense(32)	16	98,36%	0,03%
B(p)	2xGRU(64) + 1xDense(16)	16	98,20%	0,06%
C(p)	1xGRU(16)	32	98,13%	0,07%
D(p)	2xGRU(32)	64	98,10%	0,05%

\*Quantidade de camadas x Tipo da camada (neurônios na camada)

Figura 33 – Evolução dos modelos quanto ao tipo de pavimento.



(a) Evolução da acurácia no teste.

(b) Evolução do erro no teste.

#### 4.4 Com aumento de dados

O aumento de dados foi utilizado na rotulação sobre os tipos de eventos encontrados, devido a pouca quantidade de dados dessa classificação. Foi analisado o impacto de cada tipo de aumento de dados nos modelos selecionados a partir da triagem realizada nos modelos testados

Figura 34 – Matrizes de confusão para as melhores iterações dos modelos quanto ao tipo do pavimento

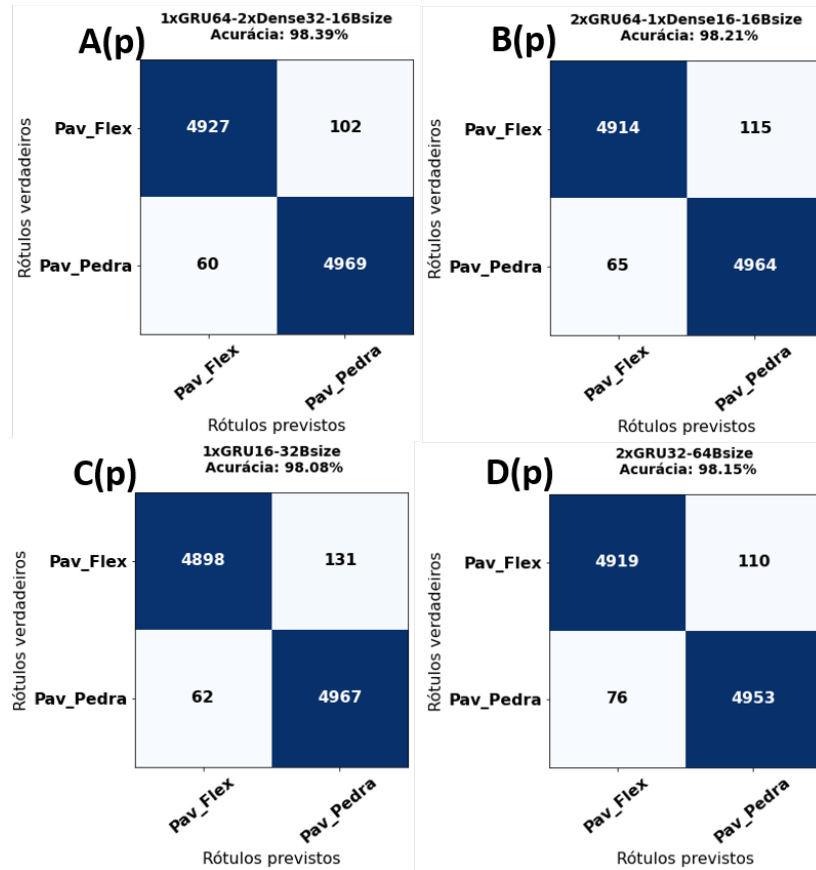


Tabela 15 – Métricas dos modelos utilizados na rotulação sobre o tipo de pavimento

Modelos	A(p)	B(p)	C(p)	D(p)
Rótulos	Precisão			
Pav_Flex (Asfalto)	0,9853	0,9852	0,9850	0,9843
Pav_Pedra	0,9818	0,9787	0,9776	0,9779
Total Geral	0,9836	0,9820	0,9813	0,9811
Rótulos	Recall			
Pav_Flex (Asfalto)	0,9818	0,9786	0,9774	0,9776
Pav_Pedra	0,9854	0,9853	0,9851	0,9844
Total Geral	0,9836	0,9820	0,9813	0,9810
Rótulos	f1-score			
Pav_Flex (Asfalto)	0,9835	0,9819	0,9812	0,9809
Pav_Pedra	0,9836	0,9820	0,9813	0,9811
Total Geral	0,9836	0,9820	0,9813	0,9810

com os dados originais, com 1 ou 2 camadas com neurônios recorrentes *GRU* com 64 neurônios seguidos de 2 camadas com 16, 32 e 64 neurônios simples, sendo aqui expostos apenas os melhores valores para cada tipo de adição de dados. Os modelos treinados utilizam tamanhos de lote igual 16.

Foram adicionadas as técnicas de escalonamento, rotação e adição de ruído e algumas combinações destas ao conjunto de treino. A Tabela 16 apresenta as melhores arquiteturas treinadas com as adições de dados bem como acurácia dos modelos. A Figura 35 mostra as matrizes de confusão para os melhores resultados dos modelos. Apenas os modelos E(a.d.) e F(a.d.) obtiveram uma melhora na acurácia, sendo o último modelo próximo a 85% de acurácia e *f1-score*, sendo a melhor para esse tipo de classificação. A Tabela 17 apresenta as métricas encontradas nesses modelos testados.

Tabela 16 – Melhores modelos treinados com aumento de dados para os tipos de eventos

Modelo	Arquitetura	Técnica de aumento de dados	Acurácia	Desvio Padrão (acurácia)
A(a.d)	1xGRU(64) + 2xDense(32)	Rotação e adição de ruído	80,58%	0,55%
B(a.d)	2xGRU(64) + 2xDense(32)	Rotação	80,88%	1,31%
C(a.d)	2xGRU(64) + 2xDense(16)	Todas a três	82,40%	0,83%
D(a.d)	2xGRU(64) + 2xDense(16)	Escalonamento	82,87%	1,35%
E(a.d)	2xGRU(64) + 2xDense(16)	Adição de ruídos	83,51%	0,81%
F(a.d)	2xGRU(64) + 2xDense(16)	Escalonamento e Adição de ruídos	84,80%	0,73%

\*Quantidade de camadas x Tipo da camada (neurônios na camada)

Adicionalmente, foi-se treinada a arquitetura do melhor modelo quanto à identificação de eventos (A(e)) com o aumento de dados via escalonamento e adição de ruído: combinação de dados que obtiveram melhor resultado no modelo F(a.d) quanto aos tipos de eventos. A média da acurácia do modelo aumentou próximo de 1%, ficando em 84,07% e desvio padrão de 0,77% . A matriz de confusão e outras métricas analisadas podem ser vistas na Figura 36a e na Tabela 36b.

#### 4.5 Aplicabilidades ao SGP

A maioria das estratégias mais eficientes de Manutenção e Reabilitação (M&R) desenvolvidas por meio de um SGP são caracterizadas pelo uso de avaliações de pavimento mais

Figura 35 – Matrizes de confusão para as melhores iterações dos modelos com adição de dados para os tipos de eventos

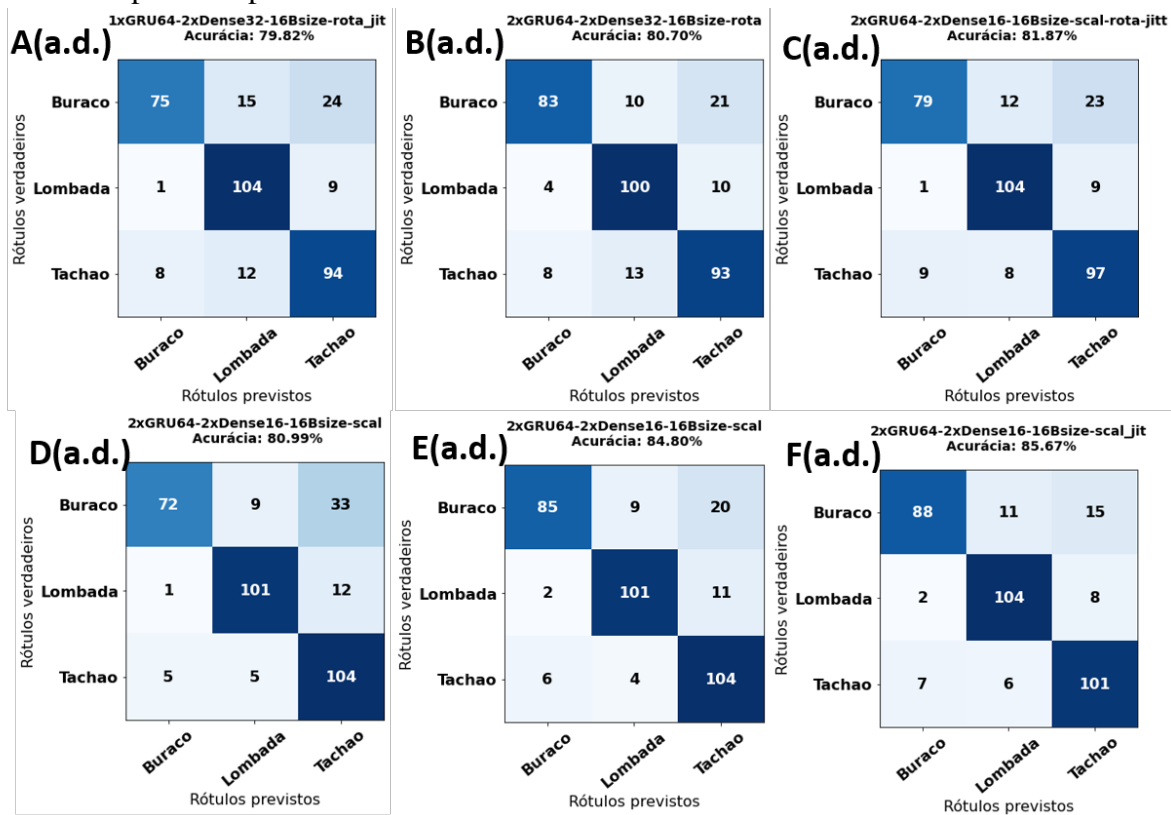
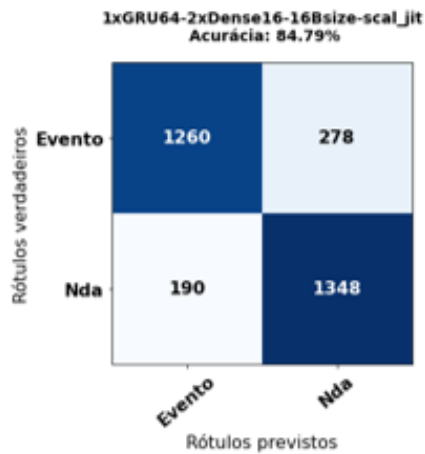


Tabela 17 – Métricas dos modelos utilizados na rotulação sobre os tipos de eventos com o uso de Aumento de dados

Modelos	A(a.d.)	B(a.d.)	C(a.d.)	D(a.d.)	E(a.d.)	F(a.d.)
Rótulos	Precisão					
Buraco	0,8605	0,8669	0,8821	0,9201	0,9137	0,9059
Lombada	0,8028	0,8525	0,8446	0,8715	0,8305	0,8589
Tachão	0,7692	0,7309	0,7625	0,7398	0,7878	0,7938
Total Geral	0,8108	0,8168	0,8297	0,8438	0,8440	0,8529
Rótulos	Recall					
Buraco	0,7105	0,7123	0,7158	0,6842	0,7351	0,7596
Lombada	0,9053	0,8702	0,9140	0,8982	0,9246	0,9070
Tachão	0,8018	0,8439	0,8421	0,9035	0,8456	0,8772
Total Geral	0,8058	0,8088	0,8240	0,8287	0,8351	0,8480
Rótulos	f1-score					
Buraco	0,7769	0,7805	0,7895	0,7840	0,8130	0,8263
Lombada	0,8507	0,8611	0,8779	0,8843	0,8748	0,8822
Tachão	0,7846	0,7829	0,8001	0,8127	0,8136	0,8334
Total Geral	0,8041	0,8082	0,8225	0,8270	0,8338	0,8473

Figura 36 – Matriz de confusão e métricas analisadas do modelo final para identificação de eventos com utilização de aumento de dados.

(a) Matriz de confusão.



(b) Métricas.

Rótulos	Precisão	Recall	f1-score
Evento	0,8614	0,8122	0,8360
Não Evento(Nda)	0,8225	0,8692	0,8451
Total Geral	0,8419	0,8407	0,8406

precisas, as quais fornecem aos gestores maior confiança nas tomadas de decisões (HUANG, 2004). As informações coletadas por meio de smartphones, como o tipo do revestimento, a presença de interferências e os tipos de interferências - principalmente buracos - abordadas neste capítulo, podem ser usadas para compor índices de desempenho do pavimento, como Zanchetta (2017) lista:

- a) índices de defeitos itemizado (um índice para cada defeito);
- b) índice de combinado defeitos do pavimento;
- c) índice geral do pavimento.

As informações também podem ser utilizadas para auxílio na elaboração de mapas para SGPU, principalmente, de pequenas prefeituras que não possuem informações sobre o revestimento do pavimento em todas as vias. Neste cenário, seriam utilizados em veículos da frota pública enquanto movimentam-se pela cidade em atividades administrativas. Portanto, o Modelo A(p) é recomendado para o processamento dos dados coletados por meio de smartphones para a distinção entre os tipos de revestimentos (asfáltico e em pedra) e o Modelo F(a.d) para identificação de irregularidades no pavimento, como buracos, lombadas e tachões.

## 5 CONCLUSÕES E RECOMENDAÇÕES

Os resultados indicam que a ferramenta utilizada com base em técnicas de aprendizado de máquina - do inglês *Machine Learning* (ML) tem potencial na coleta de dados para um Sistema de Gestão de Pavimentos Urbanos (SGPU) e na identificação de irregularidades em revestimentos asfálticos e em pedra, tornando-se uma técnica moderna em complemento ou substituição aos métodos tradicionais.

A utilização de sistemas de coleta de dados em smartphones mostrou-se uma alternativa de baixo custo para realização de estudos preliminares na identificação de irregularidades na superfície de pavimentos urbanos, assim como o tipo de revestimento encontrado. Apesar de tratar-se de uma utilização alternativa dos sensores dos smartphones, os modelos desenvolvidos foram capazes de identificar a presença de lombadas, tachões e buracos - com uma acurácia por volta de 84%, e o tipo do pavimento com acurácia superior a 98%. Essas informações podem ser usadas para o planejamento de intervenções de manutenção e reabilitação dos pavimentos, bem como para a escolha de melhores trajetos baseado na qualidade do rolamento.

Todos os trabalhos relacionados encontrados operam a frequências de captura mais altas (de 38Hz a 100Hz), sendo e a baixa frequência de captura (20Hz) utilizada nesta pesquisa um dos fatores positivos dessa abordagem. A frequência de captura está diretamente ligada ao consumo energético do aparelho. Assim, uma menor frequência não afetaria a autonomia do aparelho.

As redes recorrentes com utilização de camadas *Gated Recurrent Unit* (GRU) mostraram-se mais eficientes que as com camadas *Long Short-Term Memory* (LSTM) para estes tipos de problemas. É possível supor que isso se dá por não se fazer necessário um porta de longo prazo específico como nas LSTM, uma vez que os sinais de uma interferência não perduram por muito tempo.

A técnica de rotulação das amostras adotada pode ter influenciado negativamente nos resultados encontrados, uma vez que ela visa rapidez na rotulação, em detrimento da precisão obtida por meio de uma rotulação minuciosa e mais coerente, possivelmente, com o auxílio de algoritmos de aprendizado não supervisionado. O aumento de dados adotado mostrou-se eficaz no refinamento de alguns modelos, aumentando a acurácia em até 3% em alguns casos, com ressalvas para a a técnica de rotação, que devido a alguma(as) característica(s) do modelos, influenciaram negativamente no desempenho do treino.

Para trabalhos futuros, entende-se que:

- a) uma análise de sensibilidade dos sensores dos smartphones de modelos diferentes venha a contribuir para o melhoramento do modelo;
- b) uma análise do impacto de diferentes tipos de suporte e veículos utilizados possam ajudar uma maior generalização dos modelos, contribuindo para a composição de um banco de dados;
- c) aumentar a profundidade da rede, adicionando outros tipos de camadas, convolucionais por exemplo, e/ou alterando a quantidade de camadas dos tipos já testadas pode contribuir na melhoria do desempenho dos modelos;
- d) aplicação de novos algoritmos de aprendizado supervisionado ou semi-supervisionado, podem fazer uso das classificações desenvolvidas por meio desses modelos para o aumento da produtividade das rotulações.

## REFERÊNCIAS

- ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVDO, E.; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M.; GHEMAWAT, S.; GOODFELLOW, I.; HARP, A.; IRVING, G.; ISARD, M.; JIA, Y.; JOZEFOWICZ, R.; KAISER, L.; KUDLUR, M.; LEVENBERG, J.; MANE, D.; MONGA, R.; MOORE, S.; MURRAY, D.; OLAH, C.; SCHUSTER, M.; SHLENS, J.; STEINER, B.; SUTSKEVER, I.; TALWAR, K.; TUCKER, P.; VANHOUCHE, V.; VASUDEVAN, V.; VIEGAS, F.; VINYALS, O.; WARDEN, P.; WATTENBERG, M.; WICKE, M.; YU, Y.; ZHENG, X. TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems. 2016. Disponível em: <<http://arxiv.org/abs/1603.04467>>.
- ALBUQUERQUE, F. S.; OLIVEIRA, R. F. S. de. Avaliação de perfil longitudinal de pavimento de concreto de cimento Portland com perfilômetro inercial a laser. **Transportes**, v. 25, n. 1, p. 82, 2017. ISSN 2237-1346.
- ALMEIDA, L. C. **Aplicativo para smartphone destinado à medição da irregularidade longitudinal em rodovias**. 2018. 95 f. Dissertação (Mestrado em Engenharia Civil) — Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, 2018.
- BERNUCCI, L. B.; MOTTA, L. M. G. d. M.; CERATTI, J. A. P. C.; SOARES, J. B. S. **Pavimentação asfáltica : formação básica para engenheiros**. Rio de Janeiro: [s.n.], 2008. 504 p.
- BHORASKAR, R.; Nagamanoj Vankadhara; RAMAN, B.; KULKARNI, P. Wolverine : Traffic and road condition estimation using smartphone sensors. In: . [S.l.]: Fourth International Conference on Communication Systems and Networks (COMSNETS 2012), 2012. ISBN 9781467302982.
- BISCONSINI, D. R. **Avaliação da Irregularidade Longitudinal dos Pavimentos com Dados Coletados por Smartphones**. Dissertação (Mestrado) — Universidade De São Paulo - Escola De Engenharia De São Carlos, 2016.
- BISCONSINI, D. R. **Monitoramento da Condição Funcional de Pavimentos com Dados de Smartphones**. Tese (Doutorado), 2020.
- BRUCE, P.; BRUCE, A. **Practical Statistics for Data Scientists**. [s.n.], 2017. 409 p. ISBN 978-1-491-95296-2. Disponível em: <<https://www.oreilly.com/library/view/practical-statistics-for/9781491952955/>>.
- BURKOV, A. **The Hundred-Page Machine Learning Book** . [s.n.], 2019. v. 5. 132–150 p. ISSN 0266-4720. ISBN 978-3-662-12407-9. Disponível em: <<http://doi.wiley.com/10.1111/j.1468-0394.1988.tb00341.x>>.
- BUZA, E.; OMANOVIC, S.; HUSEINOVIC, A. Pothole Detection with Image Processing and Spectral Clustering. **Recent Advances in Computer Science and Networking**, p. 2–7, 2014. ISSN 00218561. Disponível em: <<http://www.wseas.us/e-library/conferences/2013/Antalya/ITCN/ITCN-05.pdf>>.
- CABRAL, F. S.; PINTO, M.; MOUZINHO, F. A.; FUKAI, H.; TAMURA, S. An Automatic Survey System for Paved and Unpaved Road Classification and Road Anomaly Detection using

Smartphone Sensor. **Proceedings of the 2018 IEEE International Conference on Service Operations and Logistics, and Informatics, SOLI 2018**, n. August 2018, p. 65–70, 2018.

CHO, K.; Van Merriënboer, B.; GULCEHRE, C.; BAHDANAU, D.; BOUGARES, F.; SCHWENK, H.; BENGIO, Y. Learning phrase representations using rnn encoder-decoder for statistical machine translation. **EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference**, p. 1724–1734, 2014.

COHEN, E. **SELU — Make FNNs Great Again (SNN)**. 2017. Matéria publicada no Towards data science. Disponível em: <<https://towardsdatascience.com/selu-make-fnns-great-again-snn-8d61526802a9>>. Acesso em: 24 nov. 2020.

DATASCIENCEACADEMY. **Deep Learning Book**. 2020. -. Disponível em: <<https://deeplearningbook.com.br/a-matematica-da-dissipacao-do-gradiente-e-aplicacoes-das-rnns/>>. Acesso em: 25 nov. 2020.

DNER. Departamento nacional de estradas de rodagem - pro 164/94: Calibração e controle de sistemas medidores de irregularidade de superfície de pavimento. ministério dos transportes, rio de janeiro. In: . [S.l.: s.n.], 1994.

DNIT. Departamento nacional de infraestrutura de transportes - pro 009/2003: Avaliação subjetiva da superfície de pavimentos flexíveis e semirrígidos - diretoria executiva. instituto de pesquisas rodoviárias. rio de janeiro. In: . [S.l.: s.n.], 2003.

DNIT. Departamento nacional de infraestrutura de transportes - manual de restauração de pavimentos asfálticos. diretoria executiva. instituto de pesquisas rodoviárias. rio de janeiro. In: . [S.l.: s.n.], 2006.

DOUANGPHACHANH, V.; ONEYAMA, H. Estimation of road roughness condition from smartphones under realistic settings. In: **2013 13th International Conference on ITS Telecommunications (ITST)**. IEEE, 2013. Disponível em: <<https://doi.org/10.1109/itst.2013.6685585>>.

ERIKSSON, J.; GIROD, L.; HULL, B.; NEWTON, R.; MADDEN, S.; BALAKRISHNAN, H. The Pothole Patrol: Using a mobile sensor network for road surface monitoring. In: **MobiSys'08 - Proceedings of the 6th International Conference on Mobile Systems, Applications, and Services**. [S.l.: s.n.], 2008. ISBN 9781605581392.

Felix Enigo, V. S.; Vinoth Kumar, T. M.; VIJAY, S.; PRABU, K. G. Crowd Sourcing Based Online Petitioning System for Pothole Detection Using Android Platform. In: **Procedia Computer Science**. Elsevier Masson SAS, 2016. v. 87, n. 2014, p. 316–321. ISSN 18770509. Disponível em: <<http://dx.doi.org/10.1016/j.procs.2016.05.167>>.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn , Keras , and TensorFlow**. [S.l.]: O'Reilly Media, 2019. ISBN 9781492032649.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>.

GOOGLE. **Android - Sensors Overview**. 2019. <[https://developer.android.com/guide/topics/sensors/sensors\\_overview](https://developer.android.com/guide/topics/sensors/sensors_overview)>. Accessed: 2019-10-10.

GUYON, I. Neural networks and applications tutorial. **Physics Reports**, v. 207, n. 3, p. 215 – 259, 1991. ISSN 0370-1573. Disponível em: <<http://www.sciencedirect.com/science/article/pii/037015739190146D>>.

HAAS, R.; HUDSON, W. R.; FALLS, L. C. **Pavement Asset Management**. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2015. ISSN 0007-1250. ISBN 9781119038849. Disponível em: <<http://doi.wiley.com/10.1002/9781119038849>>.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural Computation**, v. 9, n. 8, p. 1735–1780, 1997. ISSN 08997667.

HUANG, Y. H. **Pavement Analysis and Desig (Section edition)**. [S.l.: s.n.], 2004. 775 p. ISBN 0-13-142473- 4.

HUIDROM, L.; DAS, L. K.; SUD, S. Method for Automated Assessment of Potholes, Cracks and Patches from Road Surface Video Clips. **Procedia - Social and Behavioral Sciences**, Elsevier B.V., v. 104, p. 312–321, 2013. ISSN 18770428. Disponível em: <<http://dx.doi.org/10.1016/j.sbspro.2013.11.124>>.

JAIN, M.; SINGH JIIT, N. A. P. Speed-breaker early warning system. In: **6th USENIX/ACM Workshop on Networked Systems for Developing Regions (NSDR 12)**. Boston, MA: USENIX Association, 2012. Disponível em: <<https://www.usenix.org/conference/nsdr12/speed-breaker-early-warning-system>>.

KINGMA, D. P.; BA, J. L. Adam: A method for stochastic optimization. **3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings**, p. 1–15, 2015.

KOCH, C.; JOG, G. M.; BRILAKIS, I. Automated pothole distress assessment using asphalt pavement video data. **Journal of Computing in Civil Engineering**, v. 27, n. 4, p. 370–378, 2013.

LEMLIN, M.; CONGRESSES, P. I. A. of R.; (C15), P. C. on Performance of R. A. **Development of tools for performance measurement: final report**. AIPCR-Association mondiale de la Route = PIARC-World Road Association, 1998. ISBN 9782840600541. Disponível em: <<https://books.google.com.br/books?id=IEwpAQAAMAAJ>>.

LI, X.; GOLDBERG, D. W. Toward a mobile crowdsensing system for road surface assessment. **Computers, Environment and Urban Systems**, v. 69, p. 51 – 62, 2018. ISSN 0198-9715. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0198971517301333>>.

MASTERS, D.; LUSCHI, C. Revisiting Small Batch Training for Deep Neural Networks. p. 1–18, 2018. Disponível em: <<http://arxiv.org/abs/1804.07612>>.

MOHAMED, A.; FOUAD, M. M. M.; ELHARIRI, E.; EL-BENDARY, N.; ZAWBAA, H. M.; TAHOUN, M.; HASSANIEN, A. E. Roadmonitor: An intelligent road surface condition monitoring system. **Advances in Intelligent Systems and Computing**, v. 323, p. 377–387, 2015. ISSN 21945357.

MOHAN, P.; PADMANABHAN, V. N.; RAMJEE, R. Nericell: Rich monitoring of road and traffic conditions using mobile smartphones. **SenSys'08 - Proceedings of the 6th ACM Conference on Embedded Networked Sensor Systems**, p. 323–336, 2008.

NGUYEN, T.; LECHNER, B.; WONG, Y. D. Response-based methods to measure road surface irregularity: a state-of-the-art review. **European Transport Research Review**, European Transport Research Review, v. 11, n. 1, 2019. ISSN 18668887.

PASCANU, R.; MIKOLOV, T.; BENGIO, Y. On the difficulty of training recurrent neural networks. In: **ICML**. [S.l.: s.n.], 2013. ISBN 9783319931449.

PATEL, A. **Hands-On Unsupervised Learning Using Python: How to Build Applied Machine Learning Solutions from Unlabeled Data**. [S.l.: s.n.], 2019. 380 p.

PERTTUNEN, M.; MAZHELIS, O.; CONG, F.; RISTANIEMI, T.; RIEKKI, J. Distributed road surface condition monitoring. **Lecture Notes in Computer Science**, n. September, p. 64–78, 2011.

RASHID, K. M.; LOUIS, J. Times-series data augmentation and deep learning for construction equipment activity recognition. **Advanced Engineering Informatics**, Elsevier, v. 42, n. April, p. 100944, 2019a. ISSN 14740346. Disponível em: <<https://doi.org/10.1016/j.aei.2019.100944>>.

RASHID, K. M.; LOUIS, J. Window-warping: A time series data augmentation of IMU data for construction equipment activity identification. **Proceedings of the 36th International Symposium on Automation and Robotics in Construction, ISARC 2019**, n. June, p. 651–657, 2019b.

SALIH, J.; EDUM-FOTWE, F.; PRICE, A. Investigating the road maintenance performance in developing countries [conference]. 2016. ISSN 2010-376X.

SATTAR, S.; LI, S.; CHAPMAN, M. Road surface monitoring using smartphone sensors: A review. **Sensors (Switzerland)**, v. 18, n. 11, 2018. ISSN 14248220.

SAYERS, M.; KARAMIHAS, S. **Little Book of Profiling. Basic information about measuring and interpreting road profiles**. [S.l.]: University of Michigan, 1998.

SERAJ, F.; ZWAAG, B. J. van der; DILO, A.; LUARASI, T.; HAVINGA, P. RoADS: A Road Pavement Monitoring System for Anomaly Detection Using Smart Phones. In: **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**. [S.l.: s.n.], 2016. v. 9546, p. 128–146. ISBN 9783319290089.

SILVA, N.; SOARES, J.; SHAH, V.; SANTOS, M. Y.; RODRIGUES, H. Anomaly detection in roads with a data mining approach. **Procedia Computer Science**, Elsevier B.V., v. 121, p. 415–422, 2017. ISSN 18770509. Disponível em: <<https://doi.org/10.1016/j.procs.2017.11.056>>.

SOUZA, V. M. A.; GIUSTI, R.; BATISTA, A. J. L. Asfalt: A low-cost system to evaluate pavement conditions in real-time using smartphones and machine learning. **Pervasive and Mobile Computing**, Elsevier B.V., v. 51, p. 121–137, 2018. ISSN 15741192. Disponível em: <<https://doi.org/10.1016/j.pmcj.2018.10.008>>.

Sze, V.; Chen, Y.; Yang, T.; Emer, J. S. Efficient processing of deep neural networks: A tutorial and survey. **Proceedings of the IEEE**, v. 105, n. 12, p. 2295–2329, 2017.

TAN, P.; STEINBACH, M.; KUMAR, V. **Introduction to Data Mining (New International Edition)**. [S.l.: s.n.], 2013. 737 p. ISSN 1098-6596. ISBN 0-321-32136-7.

UM, T. T.; PFISTER, F. M.; PICHLER, D.; ENDO, S.; LANG, M.; HIRCHE, S.; FIETZEK, U.; KULIĆ, D. Data Augmentation of Wearable Sensor Data for Parkinson’s Disease Monitoring using Convolutional Neural Networks. **arXiv**, p. 216–220, 2017.

WERBOS, P. J. Backpropagation Through Time: What It Does and How to Do It. **Proceedings of the IEEE**, v. 78, n. 10, p. 1550–1560, 1990. ISSN 15582256.

WITTEN, I. H.; FRANK, E.; HALL, M. A.; PAL, C. J. **Data Mining: Practical Machine Learning Tools and Techniques**. Cambridge, MA: Morgan Kaufmann, 2017. v. 53. 1689–1699 p. ISSN 1098-6596. ISBN 9788578110796.

XUE, G.; ZHU, H.; HU, Z.; YU, J.; ZHU, Y.; LUO, Y. Pothole in the dark: Perceiving pothole profiles with participatory urban vehicles. **IEEE Transactions on Mobile Computing**, IEEE, v. 16, n. 5, p. 1408–1419, 2017. ISSN 15361233.

YAN, W. Y.; YUAN, X.-X. A low cost video-based pavement distress screening system for low volume roads. **Journal of Intelligent Transportation Systems**, 2017.

ZANCHETTA, F. **Sistema de gerência de pavimentos urbanos: avaliação de campo, modelo de desempenho e análise econômica**. 2017. 234 f. Tese (Doutorado em Engenharia Transportes) — Centro de Tecnologia, Programa de Pós-graduação em Engenharia de Transportes, Universidade de São Paulo, São Carlos, 2017.