

## IDENTIFICAÇÃO DE CONDIÇÕES FUNCIONAIS EM PAVIMENTOS URBANOS AUXILIADA POR *MACHINE LEARNING*

Lucas Moreira Magalhães  
Francisco Heber Lacerda de Oliveira

Universidade Federal do Ceará  
Programa de Pós-Graduação em Engenharia de Transportes

### RESUMO

O uso intensivo do modo rodoviário no Brasil impõe aos gestores a responsabilidade da manutenção e reabilitação da estrutura implantada. Entretanto, diversos municípios não dispõem de recursos para levantar dados e avaliar a situação de suas vias. Devido às dificuldades em diversas localidades para com a manutenção das vias, este trabalho propõe um modelo de identificação das condições funcionais de pavimentos urbanos para auxílio nas tomadas de decisões de gestores. O modelo envolve um algoritmo de *Machine Learning* que, junto a sensores de *smartphones*, geram imagens georreferenciadas e indicam a condição do pavimento. Dados de acelerações linear, angular e localização do veículo foram levantados na cidade de Fortaleza e processados com os parâmetros estatísticos obtidos em função dos valores das acelerações. Percebeu-se que o modelo tem potencial para tornar-se uma ferramenta útil a gestores como uma alternativa viável e complementar aos métodos mais onerosos e demorados.

### ABSTRACT

The intensive use of road in Brazil imposes on managers the responsibility of maintaining and rehabilitating the implanted structure. However, several municipalities do not have the resources to collect data and assess the status of their roads. Due to the difficulties in several locations for the maintenance of roads, this paper proposes a model for the identification of the functional conditions of urban pavements to assist decision taking by managers. The model involves a Machine Learning algorithm that, together with smartphone sensors, generate georeferenced images and indicate the condition of the pavement. Data from linear, angular acceleration and vehicle location were collected in the city of Fortaleza and processed together with the statistical parameters obtained as a function of acceleration values. It was realized that the model has the potential to become a useful tool for managers as a viable and complementary alternative to more expensive and time-consuming methods.

### 1. INTRODUÇÃO

Entender a condição global das rodovias é necessário ao gestor para a tomada de decisão acurada para a sua manutenção. Desconhecer essas condições pode acarretar problemas de conforto e segurança e gerar custos adicionais aos usuários. Um banco de dados desenvolvido a partir de levantamentos de campo permite ao gestor conhecer as zonas críticas da rede pavimentada, alertando-o da necessidade de intervenções para manutenção e reabilitação dos pavimentos.

A utilização de dispositivos eletrônicos e *softwares* para fins de avaliação de pavimentos são implementações favoráveis de dados e pesquisas *in situ*, e a produtividade da coleta de dados. Outra aplicação dessa tecnologia promissora é a utilização dos sensores de *smartphones*, para identificação de condições de pavimentos. Almeida *et al.* (2018) desenvolveu um aplicativo que computa o Índice de Irregularidade Internacional (*International Roughness Index – IRI*), denominado SmartIRI, e qualifica o conforto ao rolamento das rodovias.

No contexto do desenvolvimento e aplicação de novas tecnologias para avaliação de pavimentos rodoviários, tem-se a utilização de *Machine Learning*, um tipo de ciência de dados, com resultados favoráveis nas Engenharias. Na Engenharia de Transportes, mais especificamente na infraestrutura urbana, constata-se suas aplicações por Eriksson *et al.* (2008), que desenvolveram modelos para identificação de buracos, bueiros, entre outros defeitos presentes em pavimentos rodoviários, utilizando as respostas de sensores de velocidade,

posição e aceleração embarcados em táxis.

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

Diante do exposto, o presente trabalho tem como objetivo identificar condições funcionais de pavimentos urbanos, de modo a complementar ou substituir os levantamentos de dados tradicionais em campo, interpretando leituras de parâmetros dos sensores de *smartphones*, embarcados em veículos, com auxílio do *Machine Learning*.

## 2. REVISÃO BIBLIOGRÁFICA

A condição funcional de pavimentos relaciona-se a sua capacidade de atender a sua função de implantação, e de proporcionar serventia adequada quanto à qualidade de rolamento durante todo seu período de serviço (DNIT, 2006). Serventia é uma medida subjetiva que define um nível de estado de conforto ao rolamento e segurança e sua relação com a experiência do usuário na sua utilização, o Valor de Serventia Atual. Esse procedimento de avaliação subjetiva é estabelecido por DNIT (2003).

Outro parâmetro para avaliar a condição funcional do pavimento é a irregularidade longitudinal, sendo definida por Paterson (1987) como a irregularidade da superfície do pavimento em relação a uma seção de referência, que pode interferir no conforto ao rolamento, drenagem e distribuição do carregamento dinâmico dos veículos. Esta irregularidade é medida paralelamente ao pavimento, variando a amplitude de medida, dependendo do equipamento (BERNUCCI *et al.*, 2006). Um índice de irregularidade longitudinal utilizado para mensuração é o Índice de Irregularidade Internacional (*International Roughness Index – IRI*).

O IRI, por ser um índice padronizado e utilizado em vários países, é escolhido com frequência como parâmetro de controle de obras rodoviárias. O IRI pode ser definido como um índice estatístico que quantifica em m/km ou mm/m o desvio da superfície do pavimento implantado em relação ao projetado (BERNUCCI *et al.*, 2006). Segundo Almeida *et al.* (2018), valores de medição de IRI são afetados, de forma crescente, por fatores como ação do clima, carga dinâmica de tráfego e outros fatores de deterioração da superfície.

Levantamentos de condições funcionais estão em constante evolução, agregando tecnologias para a melhoria da velocidade de execução e custos agregados. Dentre várias tecnologias testadas, o uso do *Machine Learning* se mostra promissor para grande quantidade de dados e curto tempo de resposta.

### 2.1. *Machine Learning*

O *Machine Learning* é um conjunto de fórmulas matemáticas, ou algoritmos, de leitura e interpretação de dados de entrada, que buscam prever saídas de dados a partir dos dados inseridos (GRUS, 2015). Para Burkov (2019), esses algoritmos utilizam dados de entradas para serem treinados, e dessa forma, produzir uma saída de dados desejada. Portanto a criação de um modelo vai ter como objetivo produzir uma saída pertinente para dados diferente do conjunto de dados de treino na condição desses dados de entrada seguirem uma distribuição

estatística similar ao conjunto de treino.

Segundo Grus (2015) e Géron (2019) há, essencialmente, quatro tipos de aprendizagem de modelos de *Machine Learning*: aprendizados supervisionado, não-supervisionado, semi-supervisionado e por reforço. Os tipos supervisionados se diferem entre si pela classificação, ou etiquetagem, de dados de entrada de um grupo de treino para produção de um modelo. Já aprendizado por reforço denota atingir um objetivo estabelecido em um processo de tentativa e recompensa a cada passo que se aproxima do objetivo, ou penalidades caso a opção escolhida se afaste do objetivo.

Um modelo de aprendizado de máquina carrega consigo um algoritmo de inferência, que são ajustados para as necessidades de uma aplicação particular. Um exemplo de algoritmo associado a modelos preditivos é o k-médias (ou *k-means*). Esse algoritmo é classificado com de agrupamento, ou *clustering*, e é usado de forma extensiva pela possibilidade de trabalhar com grande quantidade de dados e sua relativa simplicidade (BRUCE; BRUCE, 2019). O *k-means* identifica *clusters* com dados de entrada similares e valores representativos para cada *cluster* gerado (GRUS, 2015).

Nesse algoritmo, a posição dos *clusters* são definidos previamente, de modo que resultem em uma mínima soma dos quadrados dentro de *clusters* (*Within Cluster Sum of Squares – WCSS*), um valor ótimo, em relação ao seu centroide. A escolha dos *clusters* é interativo, buscando um valor de WCSS para o número *k* de *clusters*. Os centroides dos *clusters* são deslocados para o menor valor encontrado, porém, esse valor pode ser um ponto ótimo local, e não global, assim, o método de interação *k-means++* é recomendado. Essa forma tem como princípio a escolha inicial dos centroides dos *clusters* baseados nas distâncias já escolhidas, ao invés de uma escolha ao acaso (ARTHUR; VASSILVITSKII, 2007), sendo a forma de interação padrão em diversas bibliotecas de programação.

## 2.2. Sensores de *Smartphones* e o seu Uso na Identificação de Condições de Pavimentos

Sensores embarcados em *smartphones* estão sendo utilizados em pesquisas pelo seu fácil manuseio, a precisão melhorando junto a qualidade e miniaturização dos componentes e baixo custo em relação a sensores dedicados. Componentes como acelerômetros e giroscópios são os mecânicos mais utilizados.

Acelerômetros podem ser descritos como um sistema mecânico de pequenos capacitores cujo objetivo é detectar acelerações pelo afastamento das placas desses capacitores (VIEIRA, 2013). A posição de placas e capacitores determinam a aceleração nos eixos ortogonais. Os resultados obtidos das medidas de um acelerômetro são acelerações relativas a gravidade local. O sensor em repouso indica a mensuração do valor da aceleração da gravidade, enquanto qualquer movimentação indica alterações nos seus eixos correspondentes.

Giroscópios são sensores que se diferenciam de acelerômetros por sua capacidade de detectar a rotação dos eixos coordenados. O giroscópio detecta a conservação do movimento angular, enquanto acelerômetros detectam vibração para definir acelerações lineares. Dessa forma, giroscópios ópticos calculam velocidades angulares através da integração de dados de entrada, com resolução satisfatória e imunes a acelerações (SANTOS, 2003). Erros em medições de velocidades angulares em giroscópios estão relacionados a sensibilidade e a acurácia de seus componentes, que envolvem a detecção de sinais sem ruídos. Esses parâmetros são

inversamente proporcionais, e uma melhoria simultânea requer uma solução mais refinada e mais cara.

O levantamento de condições funcionais de pavimentos a partir do uso de sensores de *smartphones* já é uma linha de pesquisa promissora, com diversas abordagens para o seu uso. Bisconsini *et al.* (2019) evidencia o uso de *smartphones* em avaliação funcional de pavimentos devido a adequada produtividade, baixo custo e não requerer mão de obra especializada. Sattar *et al.* (2018) reuniu trabalhos relacionados a monitoramento de vias utilizando sensores de *smartphones*, descrevendo os passos dos diversos autores, como escolhas em pré-processamento e seleção de sensores para diferentes de levantamentos de dados, assim como semelhanças nos métodos de pesquisa.

Bhoraskar *et al.* (2012) desenvolveram o *Wolverine*, utilizando sensores de *smartphones* para monitoramento de estados de tráfego, obtendo dados de acelerômetros para, após criar um modelo com algoritmos de *Machine Learning* e máquina de vetores de suporte, caracterizam uma via em irregular, onde há presença de lombadas e outros problemas para o conforto ao rolamento, ou em suave, e detectar frenagens. Zonas com alta detecção de frenagem foram associadas a congestionamento de via pelo *Wolverine*.

Outros sistemas propõem a detecção de defeitos específicos no pavimento, como panelas, com a utilização de *smartphones* para coleta de dados. Mohan *et al.* (2008) criaram o sistema *Nericell*, que utilizam sensores para a detecção de buracos e frenagens sofridos por veículos nos quais está embarcado o smartphone, com uma abordagem de limites de sinais recebidos. Pesquisas conduzidas no Brasil, como Almeida *et al.* (2018) e Bisconsini *et al.* (2019), propuseram a utilização de *smartphones* como opção a métodos específicos e mais caros, como *Falling Weight Deflectometer* e perfilômetros a laser, para a avaliação da irregularidade longitudinal de rodovias.

### 3. MÉTODO DE PESQUISA

#### 3.1. Materiais

Foi utilizado um veículo modelo Yaris, marca Toyota, motor 1.5, ano 2019. Para minimizar erros aleatórios nas leituras devido as condições mecânica, houve análise no alinhamento das rodas e revisão geral da parte mecânica, além de calibração das rodas conforme indicado pelo manual veicular. As coletas de dados foram efetuadas com diferentes carregamentos, nas seguintes configurações: carga apenas do motorista, nomeado normal, e com carga de quatro ocupantes extras e o motorista, nomeado carregado. As influências da variação no peso do veículo devido ao consumo de combustível não foram analisadas. Para minimizar os possíveis erros advindos dessa variação, o volume de combustível no tanque foi mantido acima de 50% em todos os levantamentos.

As coletas de dados foram efetuadas utilizando dois modelos distintos de *smartphones*: Xiaomi Mi 9 e Motorola Moto Z2 Force, nomeados Aparelho 1 e Aparelho2 (A1 e A2) respectivamente. Ambos os aparelhos apresentaram sinal de GPS satisfatório e possuíam os sensores de movimento necessários para coletas de dados de aceleração, velocidade e orientação dos dispositivos. Um terceiro *smartphone*, de modelo Motorola Moto G7, foi utilizado nos levantamentos para gravação de vídeos, com finalidade de auxiliar na análise dos resultados, comparando-se o estado atual da via e o resultado obtido pelo modelo de identificação de

condições do pavimento pelo algoritmo desenvolvido.

Os *smartphones* utilizados foram fixados ao para-brisas do veículo por meio de suportes veiculares, que transmitem as vibrações resultante da interação do veículo com o pavimento e evitam problemas nos sinais interpretados pelo *smartphone* devido à falta de fixação do aparelho ao veículo. Os suportes veiculares utilizados foram da marca Xiaomi, nomeado Suporte 1 (S1), e dois modelos sem marca definida, um também utilizado levantamento de dados, nomeado Suporte 2 (S2), e um para filmagens dos levantamentos. O posicionamento dos suportes no veículo foi ao centro do para-brisa dianteiro, para evitar qualquer influência causada pela distância do eixo central do veículo ao suporte.

O aplicativo utilizado para a captura de sinais dos sensores dos *smartphones* foi o *Ionic Sensors*, coletando os dados interpretados pelos sensores e armazenando-os na memória dos *smartphones* de forma simultânea. O aplicativo é capaz de capturar os sinais de GPS, acelerômetro e giroscópio, com saída de dados em formato .csv (*comma separated values*) de planilhas eletrônicas. A frequência de aquisição de dados fixado pelo aplicativo foi de 20 Hz, sendo suficiente para ter entradas de dados satisfatórias e consumo reduzido de bateria pelo aplicativo, prevenindo o aquecimento excessivo dos *smartphones*, o que poderia provocar travamentos do sistema ou dos sensores utilizados.

Um outro aplicativo utilizado, antes de cada levantamento, foi o *SensorLab*. Esse aplicativo foi utilizado para analisar o funcionamento dos sensores dos aparelhos, pois uma coleta de dados com falhas nos sensores interfere na obtenção de valores potencialmente essenciais ao posterior processamento, podendo invalidar um levantamento. Os dois *smartphones* utilizados foram comparados diretamente por meio do *SensorLab* para verificar a orientação pela função Bússola, valores de aceleração dos acelerômetros e as velocidades angulares dos giroscópios e a posição geográfica através da função GPS.

### 3.2. Método

O método dessa pesquisa pode ser resumido por uma coleta de dados com *smartphones* em locais de interesse para levantamento de dados de condições funcionais de pavimentos urbanos que, através da aplicação de um algoritmo de *Machine Learning* não-supervisionado, disponibilizado por Carvalho *et al.* (2019), gerem agrupamentos de dados e rotulação dos agrupamentos necessários, com tipologias dos pavimentos urbanos e interferências apresentadas nos trechos selecionados. Ainda, com o processamento de novos dados de campo coletados, compara-se os resultados do algoritmo com as condições reais de pavimentos urbanos por meio de vídeo, com posterior geração de um mapa de características dos trechos estudados em Sistema de Informação Geográfica (SIG).

#### 3.2.1 Coleta de dados e locais de levantamento

Antes de cada coleta, certificou-se que os dois *smartphones* tinham seus sensores operantes, para evitar perda de dados e inviabilizar o processamento de dados posteriormente. A posição inicial dos suportes veiculares fora ajustada para permanecerem na posição vertical durante os levantamentos, de modo a evitar erros nas leituras pela alteração do posicionam durante o processo.

Os suportes para os *smartphones* foram mantidos mais ao centro do para-brisas do veículo, para evitar qualquer variação dos sinais devido a movimentos em relação ao eixo do veículo e

comprometer a comparação dos dados levantados pela diferença dos dados interpretados pelos sensores dos *smartphones* nos diferentes suportes. Mapas dos locais de coletas foram gerados para ilustrar a posição em relação a cidade de Fortaleza, e a direção do tráfego da via escolhida.

### 3.2.2 Processamento e limpeza de dados

Após a coleta, os dados foram exportados da memória interna do *smartphone* para um dispositivo externo e convertidos para um *dataframe*, dessa forma, sendo possível a visualização em um *software* externo a esse ambiente, o Microsoft Excel 2016, além da visualização dos dados dentro do ambiente de programação em linguagem Python.

Após a exportação dos dados, faz-se uma limpeza e tratamento, para que possam ser aceitos como entrada para o modelo utilizado. Primeiramente, são removidas as células sem dados numéricos, representados no *dataframe* como *NaN* (*not a number*), que indica que aquele quadro da captura não registrou o valor detectado pelos sensores, excluindo essa linha de dado. Ainda, linhas associadas a velocidades menores que 10km/h foram excluídas, pois acelerações a partir do repouso do veículo e frenagens para parada foram recorrentes nessa faixa de velocidade, e afetavam a interpretação dos resultados obtidos. Para manter o máximo de dados intactos, todo levantamento com 10% ou mais de suas linhas excluídas por conterem *NaN* foram descartadas.

Com a arquivo de dados sem células registradas como *NaN*, novos parâmetros foram adicionados ao *dataframe*, como novas características para o modelo. Para cada novo parâmetro, utilizou-se uma série temporal de 20 registros (ou *frames*), que corresponde à frequência de captura do aplicativo utilizado, sendo o agrupamento de 20 registros chamados de janelas. Janelas são séries temporais de dados interpretados pelos sensores, e seus valores são a média dos *frames* que os compõem. Os parâmetros adicionados foram: desvio padrão, variância, coeficiente de correlação de Pearson das acelerações lineares e resultante de acelerações lineares (*Device Motion Resultant*).

O coeficiente de correlação de Pearson é uma variante padronizada, que oferece uma estimativa de correlação, positiva ou negativa, entre duas variáveis em uma mesma escala (BRUCE; BRUCE, 2017). Essa nova característica foi escolhida para compor a base de dados pois pode fornecer informações importantes sobre as alterações de padrões do pavimento, como uma mudança de um pavimento de concreto asfáltico para um de pedra poliédrica, por exemplo. Outra característica preditora adicionada para compor a base de dados foi a resultante de acelerações lineares interpretadas pelo acelerômetro.

### 3.2.3 Escalonamento de características (*feature scaling*) e aplicação do modelo

Após a adição dos novos parâmetros ao *dataframe*, os dados não relacionados ao tempo e localização passam por uma padronização (*standardization*), para que o alcance dos dados seja reduzido. Por exemplo, o valor numérico da velocidade tem grandeza maior que valores de aceleração linear do acelerômetro e angular do giroscópio, afetando negativamente o modelo utilizado.

O processo de padronização dos dados foi preferido ao de normalização (*normalization*) por *Min-Max scaling*, pois esse processo, tendo uma alteração dos valores para uma escala de 0 a 1, pode “esmagar” (*crush*) os dados caso haja grande discrepância entre os valores, concentrando valores próximo a 0, enquanto *outliers*, erros nos sensores, etc., ocupam valores

próximos a 1, comprometendo a formação dos agrupamentos pelo modelo. A padronização é menos sensível a *outliers*, não “esmagando” (*crushing*) os dados com a presença deles, pois o desvio padrão e a média variam conforme a presença de valores discrepantes.

### 3.2.4 Aplicação do modelo

O modelo utilizará o banco de dados das características estudadas, que foram levantadas em locais escolhidos para treinar o modelo, informando as características de todos os pontos levantados, para a formação dos *clusters* de caracterização da condição do pavimento. Cada *cluster* será rotulado conforme sua classificação observada em campo, com auxílio da análise das filmagens feitas junto as coletas de dados. Para a definição do número de *clusters* do modelo, será utilizado o método do cotovelo para obter uma estimativa do valor de grupos para o banco de dados utilizado para a formação do modelo.

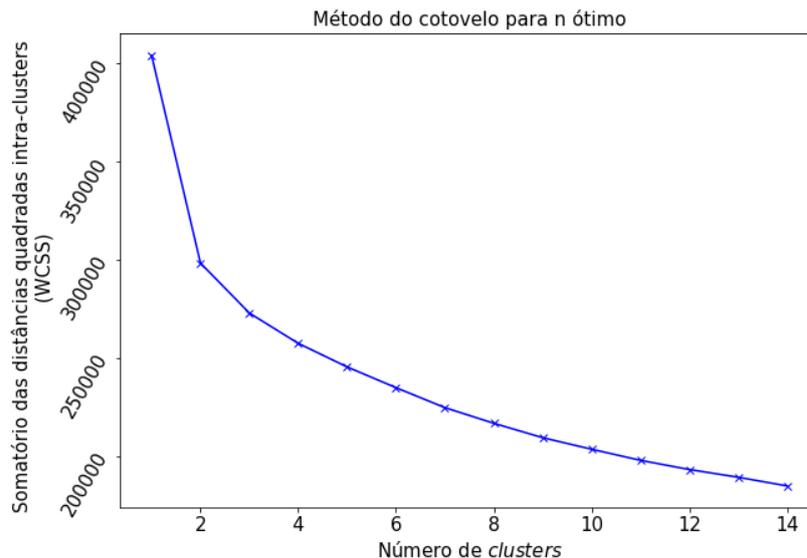
Os dados para um grupo de teste serão levantados no mesmo veículo utilizado na pesquisa, com ambos os suportes, com carga aplicada normal e aparelho 2. Além de dados de equipamentos já utilizados para a formação do modelo compondo o grupo de teste, será incluído dados referentes a equipamentos externos a pesquisa, sendo um veículo da marca Hyundai, modelo HB20, com um suporte diferente em relação ao dessa pesquisa, e um aparelho modelo Samsung S8. A adição de equipamentos não utilizados na pesquisa no grupo de teste, citado anteriormente, servirá para observar o comportamento do modelo em equipamentos diferentes, se ocorrem incoerências nos resultados obtidos para equipamento diferentes dos utilizados para a formação do grupo de treino. A classificação do grupo de teste está exposta na Tabela 1.

**Tabela 1:** Classificação dos levantamentos do grupo de teste

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

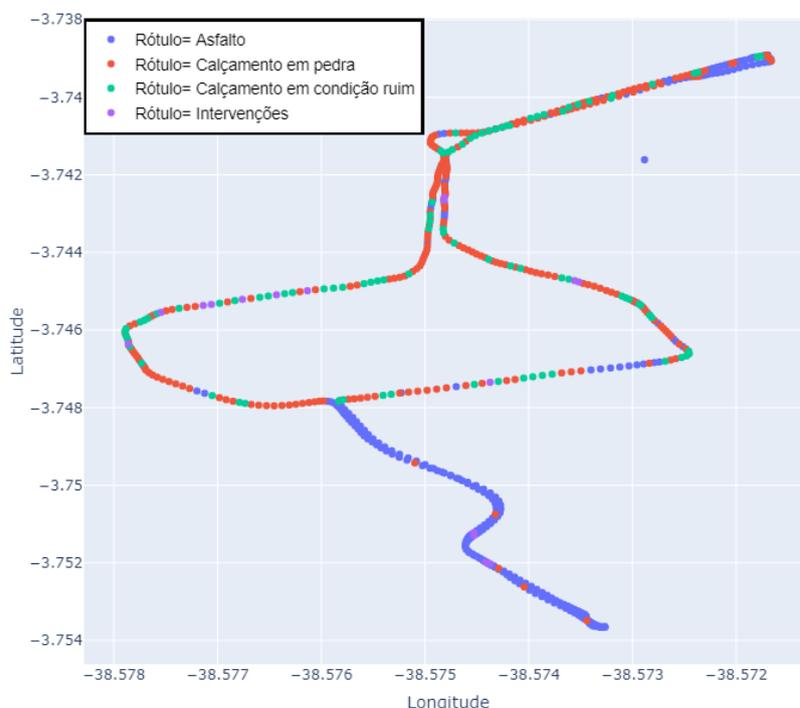
## 4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

A avaliação das vias urbanas a serem escolhidas para a coleta de dados dos sensores de *smartphone* teve como base uma análise preliminar das condições funcionais do pavimento. Para a análise, foram selecionados trechos que apresentavam quantidades razoáveis de características presentes no modelo do algoritmo preditivo *k-means* utilizado. Após atribuir ao algoritmo todos os dados tratados, 16.165 pontos com informações das características pertinentes ao agrupamento foram incorporados ao sistema. Após isso, o sistema foi submetido a um teste de cotovelo para a escolha de um número de *clusters* adequado para o conjunto de dados estudados. A Figura 1 apresenta o resultado desse processo.



**Figura 1:** Teste do cotovelo para o modelo gerado

O número de *clusters* escolhidos para o modelo foi de 4, por ser um valor adequado, por sua pequena variação de curvatura, o que indica pequena redução do WCSS. Os *clusters* serão interpretados como a presença de alguma interferência na via, como lombadas e buracos, pavimento em calçamento, pavimento em calçamento em condição ruim e asfalto. Após o algoritmo encontrar os centroides do modelo, foi aplicado o modelo sobre o grupo de teste e observou-se o comportamento em relação a identificação das características da via. A aplicação do modelo foi feita em cada elemento do grupo de teste separadamente, com o intuito de analisar de forma menos agregada a influência do equipamento sobre os resultados obtidos. A Figura 2 mostra a classificação no grupo de teste 1.



**Figura 2:** Aplicação do modelo ao elemento 1 do grupo de teste

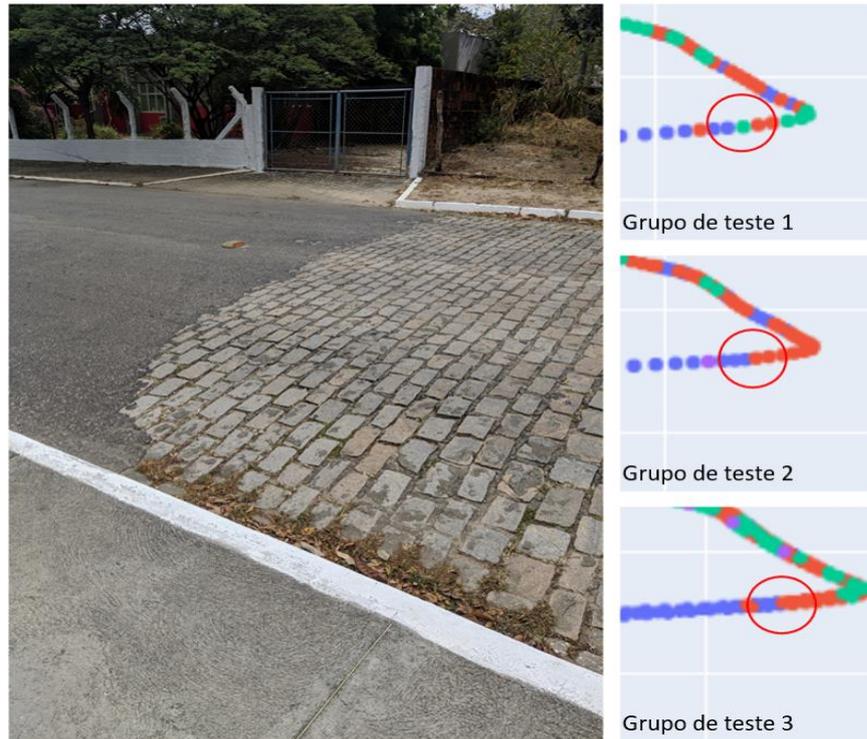
O modelo aplicado ao grupo de teste diferenciou diversos pontos de interesse, porém, alguns dos pontos de interesse foram diferenciados da parte majoritária dos dados (calçamento em pedra e asfalto) de formas diferentes, tendo as características dos pontos sido interpretados pelo modelo como *clusters* diferentes dos de campo. Essas diferenças podem ser observadas na Figura 3.



**Figura 3:** Diferenças entre a identificação de características da via

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

A transição entre padrões de pavimentação, situação já analisada em relação aos sinais interpretados pelos sensores, foram separados de forma correta entre o rótulo de asfalto e calçamento em pedra para os três elementos do grupo de teste. A Figura 4 mostra o local da mudança de padrão e classificação dada por cada elemento de grupo de teste.



**Figura 4:** Identificação de mudança de padrão de pavimentação de via

Como visto a Figura 4, a transição de padrões de via é bem diferenciada por todos os elementos do grupo de treino, tendo assim o modelo o potencial para diferenciar outras alterações de padrão de revestimento de via e a sua falta, indicando aos gestores responsáveis trechos com remoção parcial ou total do revestimento utilizado na via, e servindo como um mapa de gravidade da condição de vias para auxílio da priorização para intervenções futuras.

## 5. CONCLUSÃO

Após a análise dos dados levantados, elaboração do modelo com um algoritmo utilizado e aplicação do modelo a diversos padrões de pavimentação, alcançou-se um modelo que pode diferenciar esses padrões em pavimentos urbanos, identificar a qualidade de um calçamento em pedra e reconhecer interferências ocorridas no pavimento analisado, sendo eles defeitos funcionais, como panelas, e intervenções para controle de velocidade, como lombada e tachão. No entanto, há limitações do modelo em relação aos dados de treino utilizados, pois características não englobadas no treino podem se confundir com os utilizados caso seus sinais sejam semelhantes.

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

### Agradecimentos

Os autores agradecem ao aluno de Mestrado do Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará (PETRAN/UFC), Pedro Henrique Fontenele Costa Carvalho, por viabilizar grande

parte do processo de pesquisa com sua ajuda. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) - Código de Financiamento 001.

#### REFERÊNCIAS BIBLIOGRÁFICAS

- ALMEIDA, L. C.; F. H. L. OLIVEIRA e S. P. RAMOS (2018) *Estudo da condição de superfície em rodovias por meio do uso de aplicativo para smartphone*. – Revista Transportes vol.26 n.2, Rio de Janeiro.
- ARTHUR, D. e S. VASSILVITSKII (2007) *k-means++: The Advantages of Careful Seeding*. 18th Annual ACM-SIAM Symposium on Discrete Algorithms Nova Orleães, Louisiana, EUA.
- BERNUCCI, L. B.; J. B. SOARES; L. M. G. MOTTA e J. A. P. CERATTI (2006) *Pavimentação Asfáltica: Formação Básica para Engenheiros*. 3. ed. rev. Petrobrás, ABEDA. Rio de Janeiro.
- BISCONSINI, D. R.; J. LOUREIRO e J. L. FERNANDES JR. (2019). *Análise da influência de fatores relacionados ao uso de smartphones para a avaliação da irregularidade longitudinal de pavimentos*. 33º Congresso de Pesquisa e Ensino em Transportes Balneário Camboriú - SC. Anais do 33º Congresso de Pesquisa e Ensino em Transportes.
- BHORASKAR, R.; N. VANKADHARA; B. RAMAN e P. KULKARNI (2012) *Wolverine: Traffic and Road Condition Estimation using Smartphone Sensors*. Fourth International Conference on Communication Systems and Networks (COMSNETS 2012).
- BRUCE, P e A. BRUCE (2019) *Estatística Prática para Cientista de Dados: 50 Conceitos Essenciais*. O'Reilly Media, p. 392.
- BURKOV, A. (2019) *The Hundred-page Machine Learning*. [s.i]: 159 p.
- CARVALHO, P. H. F. C.; F. H. L OLIVEIRA e S. D. S. REIS (2019) *Identificação de Irregularidades de Superfície por Meio de Machine Learning para Sistemas de Gerência de Pavimentos*. Relatório de Dissertação (Mestrado) - XXXIII Congresso da Associação Nacional de Pesquisa e Ensino em Transportes – ANPET. Balneário Camboriú, Santa Catarina.
- DNIT (2006) *Manual de Pavimentação*. Departamento Nacional de Infraestrutura de Transportes. Publicação IPR-719. Rio de Janeiro.
- DNIT (2003) *Procedimento 008/2003: Levantamento visual contínuo para avaliação da superfície de pavimentos flexíveis e semi-rígidos - Procedimento*. Departamento Nacional de Infraestrutura de Transportes. Rio de Janeiro.
- ERIKSSON, J.; L. GIROD; B. HULL R. NEWTON; S. MADDEN e H. BALAKRISHNAN (2008) *The Pothole Patrol: Using a Mobile Sensor Network for Road Surface Monitoring*. MobiSys, Breckenridge, Colorado, USA.
- GÉRON, A. (2019) *Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media, 576p.
- GRUS, J. (2015) *Data Science from Scratch: First Principles with Python*. Sebastopol, Ca: O'reilly, 336 p.
- MOHAN, P; V. N. PADMANABHAN e R. RAMJEE. (2008) *Nericell: Rich Monitoring of Road and Traffic Conditions using Mobile Smartphones*. Embedded network sensor systems, n. 8, p. 323–336.
- PATERSON, W.D.O. (1987) *Road Deterioration and Maintenance Effects Models for Planning and Management*. The World Bank, Baltimore, The Johns Hopkins University Press.
- SANTOS, W. E. (2003) *Sistema para Identificação da Curvatura na Junta Prismática de um Robô via Quaternions*. 2003. 172 f. Tese (Doutorado) - Curso de Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis.
- SATTAR, S.; S. LI e M. CHAPMAN. (2018) *Road surface monitoring using smartphone sensors: A review*. Sensors (Switzerland), v. 18, n. 11, p. 21.
- VIEIRA, L. P. (2013) *Experimentos de Física com Tablets e Smartphones*. 107 f. Dissertação (Mestrado) - Curso de Física, Instituto de Física, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

---

Lucas Moreira Magalhães (lucasmoreiramagal@alu.ufc.br)  
Francisco Heber Lacerda de Oliveira (heber@det.ufc.br)  
Programa de Pós-Graduação em Engenharia de Transportes, Universidade Federal do Ceará  
Departamento de Engenharia de Transportes  
Bloco 703 - Campus do Pici, Fortaleza - CE, Brasil