

# ADAPD: Sensor Adaptativo de Tempo Real para Buracos em Rodovias Baseado em Vibração

Jeferson Menegazzo<sup>1</sup>, Rodrigo Curvêllo<sup>1</sup>, André A. Stein<sup>1</sup>

<sup>1</sup>Instituto Federal Catarinense (IFC) – Campus Rio do Sul  
Rua Abraham Lincoln – 89160-202 – Rio do Sul – SC – Brasil

jef.menegazzo@gmail.com, {rodrigo.curvello, andre.stein}@ifc.edu.br

**Abstract.** *The road modal is the main transport matrix for flow production and people circulation in the world. Structural problems arising from their conservation status result in a series of socio-economic implications. The potholes, in particular, constitute one of the most recurrent and dangerous deformities. Among the methods developed for its detection, those vibration-based constitute an effective and low cost means. However, related studies have several demands to be met. In this way, this work aimed the development of an adaptive sensor with self-calibration feature and algorithmic combinations to improve detection.*

**Resumo.** *O modal rodoviário constitui a principal matriz de transporte para escoamento de produção e circulação de pessoas no mundo. Problemas estruturais decorrentes de seu estado de conservação acarretam uma série de implicações socioeconômicas. Os buracos, em especial, constituem uma das deformidades mais recorrentes e perigosas. Dentre os métodos desenvolvidos para sua detecção, os baseados em vibração constituem um meio eficaz e de baixo custo. Contudo, estudos correlatos apresentam diversas demandas a serem supridas. Desta forma, este trabalho objetivou o desenvolvimento de um sensor adaptativo com recurso de autocalibração e combinações algorítmicas para aprimorar a detecção.*

## 1. Introdução

A forte dependência do modal rodoviário pelos sistemas logísticos para escoamento de produção, assim como para a circulação de pessoas, denota a vital importância da conservação e manutenção da infraestrutura rodoviária no país [Pacheco 2011]. De acordo com o relatório gerencial da Confederação Nacional do Transporte – CNT (2016), o modal rodoviário nacional possui uma participação de 61,1% na matriz de transporte de cargas, e de 95% na matriz de transporte de passageiros, contribuindo significativamente para o desenvolvimento socioeconômico do país.

Apesar da sua evidente relevância, os investimentos efetuados nos últimos anos não foram suficientes para proporcionar condições adequadas de segurança e qualidade às rodovias. Dos 1.720.756 km que compõem a malha rodoviária brasileira, apenas 12,3% são pavimentados, e destes, 58,2% apresentam algum tipo de deficiência, sendo que 48,3% possuem problemas relativos à conservação do pavimento [CNT 2016].

As rodovias quando em mau estado de conservação, ocasionam uma série de implicações socioeconômicas. Para as cadeias logísticas, os defeitos e as irregularidades

do pavimento acarretam em maior custo operacional dos veículos que, conseqüentemente, oneram o escoamento de produtos e seu preço final [Pacheco 2011]. Além disso, os problemas estruturais do modal rodoviário implicam em maiores gastos com manutenção dos veículos, com o consumo de combustível e tempo de viagem, além de afetar a segurança e conforto de seus usuários [CNT 2016].

Desta forma, a concepção de uma aplicação capaz de indicar as coordenadas geográficas correspondentes à essas falhas estruturais, assim como o estado geral da rodovia em função deste tipo de defeito, se mostra interessante a diversos propósitos. Com a disponibilização deste tipo de dado, empresas responsáveis pela manutenção de rodovias podem utilizá-lo como critério para planejamento de futuras manutenções, definindo-se onde e quando realizar, tendo, portanto, maior controle das falhas, ganho na eficiência e redução de custos operacionais [Borges et al. 2011]. Para os motoristas, possibilita a escolha de trajetos com base na qualidade de conservação das rodovias, evitando problemas supracitados. Para as cadeias logísticas, permite o planejamento de estratégias para escoamento que não onerem a produção, acarretando, dentre outras vantagens, o ganho na competitividade. Além disso, sistemas colaborativos baseados em *crowdsensing* podem ser desenvolvidos, com recursos de consulta e alerta para auxiliar os condutores durante a viagem.

A aplicabilidade deste tipo de ferramenta se mostra vasta. Entretanto, a detecção de todos os tipos de defeitos presentes, tais como os elencados pelo estudo da CNT (2016), torna-se dificultoso. Desta forma, diversos estudos conduzidos para identificação de falhas na pavimentação voltaram-se aos buracos, uma vez que constituem uma das deficiências mais perigosas e recorrentes nas rodovias. De acordo com Kim e Ryu (2014), os métodos desenvolvidos para detecção de buracos podem ser classificados em baseados em reconstrução 3D, baseados em visão ou baseados em vibração.

Os métodos baseados em reconstrução 3D realizam a detecção via *scanner de laser 3D*, *stereo vision* ou sensor Kinect, para estabelecer um modelo tridimensional da superfície do pavimento. Os métodos baseados em visão utilizam de análise de imagens 2D ou vídeo, segmentando o(s) *frame(s)* e extraíndo-se propriedades visuais úteis ao reconhecimento e classificação, como textura, forma e dimensão [Kim e Ryu 2014]. Ambos os modelos podem detectar buracos em tempo real, entretanto, seu custo é significativamente alto e dependente de um campo de visão do equipamento que, conforme seu posicionamento, pode ser obstruído. Além disso, o impacto da superfície ao veículo pode ocasionar vibrações que desalinhem os dispositivos empregados e, com isso, afetar a qualidade, a precisão e o resultado da detecção.

Os métodos baseados em vibração, por sua vez, utilizam de acelerômetros para detecção, consistindo da análise das forças de aceleração aplicadas. Constituindo uma alternativa de baixo custo e eficaz, utiliza consideravelmente menos recursos computacionais, alcançando até 92% de detecções corretas [Mednis et al. 2011], enquanto que os demais métodos, como apontados por Kim e Ryu (2014), normalmente possuem menor percentagem de acurácia.

Entretanto, os estudos em torno da temática se mostram escassos, sendo necessário a elaboração de diversas tratativas. Desta forma, neste trabalho propõe-se o desenvolvimento de um sensor baseado em *software* para detecção de buracos em

tempo real, empregando métodos baseados em vibração. Dentre as tratativas propostas para as demandas apresentadas em estudos correlatos, está o desenvolvimento de uma abordagem adaptativa para autocalibração de acelerometria, assim como a formulação de combinações algorítmicas com o intuito de aprimorar a precisão e acurácia das identificações.

## 2. Métodos Baseados em Vibração

Segundo Kim e Ryu (2014), a detecção de buracos quando realizada manualmente por uma pessoa, torna-se cara e lenta, além de comprometer a qualidade dos dados. Portanto, a aplicação de métodos computacionais para realizar a tarefa se torna a opção mais adequada. Dentre as abordagens desenvolvidas para esta finalidade, encontram-se os métodos baseados em vibração, os quais utilizam de dados de acelerometria para realizar a detecção, consistindo da análise das forças de aceleração aplicadas ao veículo e, conseqüentemente, ao sensor interno [Kim e Ryu 2014]. A Figura 1 ilustra esse comportamento.

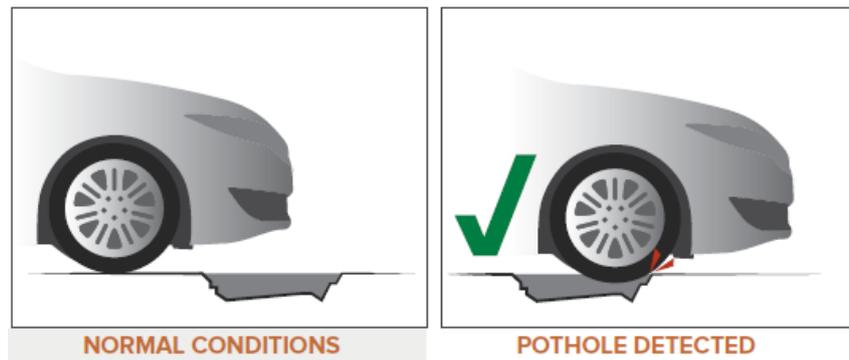


Figura 1. Aplicação de forças ao veículo e ao sensor (adaptado de Nicolas, 2014).

Quando em condições normais da rodovia, o sensor interno registra apenas ruídos. Entretanto, quando o veículo passa sobre um buraco, forças são aplicadas ao longo do eixo Z, referente ao sistema de coordenadas do mundo real. Estas forças, capturadas pelo acelerômetro, são analisadas para verificar a existência de alguma falha no pavimento.

Para detecção de buracos em rodovias diversos métodos baseados em vibração foram desenvolvidos, incluindo, mais recentemente, a utilização de aprendizado de máquina. Contudo, os métodos baseados em Inteligência Artificial, como o de Kulkarni et al. (2014), não demonstraram resultados muito superiores quando comparados à heurísticas simples baseadas em limiar (*thresholds*). Neste contexto, os métodos desenvolvidos por Mednis et al. (2011), em especial, são amplamente adotados em estudos relacionados, devido sua eficácia, eficiência e simplicidade.

Na Tabela 1 são apresentados os métodos de detecção de buracos em rodovias desenvolvidos por Mednis et al. (2011). Os algoritmos derivados em estudos correlatos, tais como os de Kalra et al. (2014), Burgart (2014) e Garg et al. (2015) não são detalhados neste trabalho, uma vez que o princípio básico de funcionamento para detecção é o mesmo, diferenciando-se apenas em adaptações pontuais ao problema e questões de aplicabilidade. Todos os métodos apresentados utilizam de valor de limiar fixo (*threshold*) para comparação.

**Tabela 1. Métodos de detecção desenvolvidos por Mednis et al. (2011).**

Método	Abordagem de Detecção	Acurácia
Z-THRESH	<i>Online.</i> A partir da análise de amplitude da aceleração do eixo Z, os valores que excedem o <i>threshold</i> identificam um buraco.	78%
Z-DIFF	<i>Online.</i> Diferenças entre dois valores de força aceleração consecutivos no eixo Z ( $Z_i - Z_{i-1}$ ) que excedem o <i>threshold</i> caracterizam um buraco.	92%
STDEV(Z)	<i>Offline.</i> O desvio padrão dos dados referentes ao eixo Z de partições específicas da amostra é comparado ao <i>threshold</i> . Um buraco é detectado caso este valor seja superior.	81%
G-ZERO	<i>Offline.</i> Quando os valores dos três eixos estão perto de 0g a falha no pavimento é identificada. Isto decorre da queda livre temporária quando o pneu do carro entra ou sai de um buraco.	73%

Devido a constituir um segmento de pesquisa relativamente recente, estudos relacionados demandam o desenvolvimento de diversas tratativas. Dentre as mais recorrentes estão a necessidade de buscar-se combinações algorítmicas dos métodos Z-THRESH, Z-DIFF, STDEV(Z) e G-ZERO, além do desenvolvimento de um recurso para autocalibração do sensor, mencionados nos trabalhos de Mednis et al. (2011), Chugh et al. (2014) e Garg et al. (2015). A primeira delas decorre da necessidade de aprimorar a interpretação dos dados na detecção. Já a segunda demanda se deve à variação de sensibilidade entre sensores de acelerometria [Kalra et al. 2014], além do sistema de amortecimento dos veículos impactarem de forma particular na força de aceleração obtida, gerando diferentes valores de força para um mesmo buraco [Chugh et al. 2014].

Desta forma, o estudo conduzido buscou formular um novo método de detecção através da combinação algorítmica dos métodos apresentados, visando interpretar os dados do acelerômetro de forma mais confiável. Também foi desenvolvido um recurso para autocalibração, objetivando tornar o algoritmo de detecção adaptável aos diversos sensores e veículos, não sendo necessário, conforme apresentado nos estudos mencionados, a determinação de um valor de comparação fixo para cada um deles.

### 3. Sensor ADAPD

O sensor baseado em *software* ADAPD - *Adaptive Pothole Detection* foi desenvolvido derivando seus dados de dois sensores baseados em *hardware*, sendo eles o sensor de gravidade e o acelerômetro, empregando conjuntamente técnicas de fusão de sensores e filtros de sinais. A taxa de amostragem utilizada foi baseada no estudo de Kalra et al. (2014), definida em 200 milissegundos, mostrando-se um valor condizente para manter a confiabilidade da detecção e o uso eficiente de recursos. Em razão de sua característica de tempo real, definiu-se também um *deadline* correspondente à 250 milissegundos.

Previamente ao processo de detecção, o sensor ADAPD obtém um vetor multidimensional de valores do acelerômetro, referente à força de aceleração aplicada ao sensor em cada um de seus três eixos físicos, incluindo a gravidade. Contudo, no método de reconhecimento considera-se apenas a força de aceleração real (linear). Desta forma, a força gravitacional deve ser removida dos dados de acelerometria através de pré-processamento, conforme detalha a Figura 2.

```

float alpha = 0.8;

// Filtro passa-baixa
gravity_x = alpha * gravity_x + (1 - alpha) * acceleration_x;
gravity_y = alpha * gravity_y + (1 - alpha) * acceleration_y;
gravity_z = alpha * gravity_z + (1 - alpha) * acceleration_z;

// Filtro passa-alta
linear_acceleration_x = acceleration_x - gravity_x;
linear_acceleration_y = acceleration_y - gravity_y;
linear_acceleration_z = acceleration_z - gravity_z;

```

**Figura 2. Filtros de sinais aplicados na remoção do componente de gravidade (adaptado de Android Developers, 2017).**

Para aplicação dos filtros de sinais são obtidos subsequentemente dados de força gravitacional que incidem nos três eixos do sensor de gravidade. Devido à utilização de dois sensores existem, conseqüentemente, diferenças temporais entre as amostras obtidas, de forma que a força de gravidade a ser considerada deve passar por uma filtragem do tipo passa-baixa antes de ser removida dos valores do acelerômetro. O filtro passa-baixa empregado utiliza de um fator alfa para fazer uma compensação de valores, definido através da seguinte fórmula:

$$\alpha = \frac{t}{t + dt} \quad \text{com} \quad t = \frac{1}{2 \cdot \pi \cdot fc} \quad \text{e} \quad dt = t_2 - t_1 \quad (1)$$

Onde  $t$  é uma constante de tempo, representando a latência que o filtro adiciona aos valores do sensor, e  $dt$  a taxa de amostragem definida, correspondente à 0,2 segundos em todos os sensores empregados. Já  $fc$  indica a frequência de corte aplicada aos sinais [Android Developers 2017]. De acordo com Bayat et al. (2014), para a exclusão do componente de gravidade dos dados de acelerometria, a frequência de corte  $fc$  ideal deve ser estabelecida entre 0,1Hz e 0,5Hz. Determinando-se  $fc$  igual a 0,2Hz, obteve-se o valor alfa resultante de 0,8. Desta maneira, a gravidade relativa é obtida pelo somatório dos dados proporcionais à 80% do sensor de gravidade e 20% do acelerômetro. Após a obtenção da gravidade desejada, a remoção deste componente dos valores do acelerômetro é realizada por um filtro passa-alta simples, produzindo valores de força de aceleração real (linear).

Após pré-processamento, os dados são parametrizados ao algoritmo de detecção. O desenvolvimento do método detector de buracos baseou-se em um estudo combinatório dos métodos Z-THRESH e Z-DIFF de Mednis et al. (2011), com utilização de valores *Z-Peak*, conforme Kulkarni et al. (2014), realizando a detecção em tempo real, com compensação de valores de força de aceleração através do recurso de autocalibração elaborado. Este recurso, por sua vez, baseou-se no método STDEV(Z) de Mednis et al. (2011).

Inicialmente, o detector obtém os dados de força de aceleração real aplicada ao eixo Z, relativo ao sistema de coordenadas do mundo real, onde o referido eixo é perpendicular ao solo. Devido aos sensores empregados possuírem sistema de coordenadas próprios e a detecção necessitar dos valores localizados no sistema

supracitado, utilizou-se da técnica de posicionamento controlado, tal como abordado por Mednis et al. (2011) e Kalra et al. (2014), onde os sensores permanecem fixos e alinhados de forma que o eixo de avaliação coincida em ambos os sistemas.

No processamento dos dados obtidos, a amostra corrente é analisada em conjunto com amostras anteriores, localizando-se valores máximos e mínimos locais, denominados *Z-Peak*. O sensor, portanto, apenas processa dados de picos de força, ignorando as demais amostras. Esta seleção se fundamenta no contexto do problema, uma vez que a taxa de amostragem é mais rápida que os eventos externos monitorados. Desta forma, diversas amostras retornam um valor de força de aceleração real parcial crescente, enquanto apenas poucas delas retornam o valor de força de aceleração real total aplicada.

No caso da detecção de buracos, partindo do momento em que o pneu perde o contato com o pavimento, até chocar-se com o fundo do buraco, tem-se a captura de várias amostras de força de aceleração real parcial crescente, ou seja, da força exercida enquanto o pneu está em queda. Contudo, essas amostras são irrelevantes, uma vez que somente a amostra de força de aceleração real total aplicada deve ser considerada. Esta, por sua vez, é obtida quando ocorre o contato do pneu com o solo do buraco, identificado como valor de pico.

Os valores de pico encontrados são classificados em picos mínimos (mínimos locais) ou picos máximos (máximos locais), aplicados na seguinte equação:

$$average = \frac{(average \cdot amount) + ZPeak}{amount + 1} \quad (2)$$

A fórmula desenvolvida calcula em tempo de execução médias ponderadas dos valores de pico máximos (*averageMax*) e mínimos (*averageMin*). Desta forma, recebendo o valor de força *Z-Peak* com peso igual a 1, calcula-se o proporcional correspondente à soma deste com a média atual (*average*) de peso igual ao total de *Z-Peaks* processados até então (*amount*), divididos pelo total de pesos. Este cálculo, com o passar da execução, converge para o valor médio de ruído mais preciso, uma vez que a medida que o tempo passa, o próximo valor *Z-Peak* exerce menor influência na média.

Após o cálculo das médias ponderadas de valores máximos e mínimos de ruído, empregados posteriormente na autocalibração, o método de detecção testa o valor de *Z-Peak*, para verificar se o veículo passou por um buraco. Essa verificação é efetuada em duas etapas. A primeira delas baseia-se no método Z-DIFF, que calcula a diferença entre dois pontos de pico de força para comparação com um valor de limiar. Desta forma, obtém-se o valor absoluto da diferença entre a força de pico anterior e o atual (*diffPeak*). Este valor resultante consiste da força de aceleração real total aplicada entre dois eventos, tal como quando o pneu estava sobre o pavimento e, posteriormente, dentro de um buraco.

Contudo, ao contrário do Z-DIFF, a comparação não é feita com um valor predefinido, mas sim condicionado, o qual é obtido através do módulo da diferença entre as médias de ruído máximo e mínimo (*diffNoise*). As médias calculadas, por sua vez, estabelecem um intervalo de ruído. Sendo assim, todo valor localizado entre a média mínima e a máxima não constitui força de aceleração referente a passagem por um buraco. Logo, a diferença entre estas médias fornece a força de ruído aplicada. Sendo assim, todo *Z-Peak* menor ou igual a *diffNoise*, constitui um ruído.

Se o sensor verificar que a força de aceleração real total aplicada for maior que a força de ruído, é executada a segunda parte da verificação. Esta etapa baseia-se no método Z-THRESH, onde se compara o valor atual de *Z-Peak* com um valor de limiar. Devido ao recurso de autocalibração, novamente a comparação não é efetuada com um valor predefinido, mas condicionado pelo cálculo de um *threshold* com as médias de ruído. O *threshold* especificado corresponde a força de impacto isolada, ou seja, a força aplicada ao chocar-se com um buraco, excluindo qualquer outro componente.

Desta forma, a soma do *threshold* com *averageMax*, assim como a diferença do mesmo com *averageMin* indica a distância da média ( $STDEV(Z)$ ) em que deve estar localizado o valor de *Z-Peak*, para que seja classificado como buraco. Sendo assim, um buraco é identificado se a força de aceleração real total aplicada for maior que a soma da média de força máxima de ruído com a força de impacto isolada, ou menor que a diferença entre a média de força mínima de ruído com a força de impacto isolada. Caso a condição seja satisfeita, o sensor identifica um buraco.

#### 4. Análise de Resultados

Para análise do modelo proposto, efetuou-se dois testes específicos. O primeiro deles consistiu da validação e avaliação do pré-processamento de sinais aplicado incluindo, portanto, a análise da remoção do componente de gravidade dos dados de força de aceleração, através de filtros de sinais e fusão de sensores.

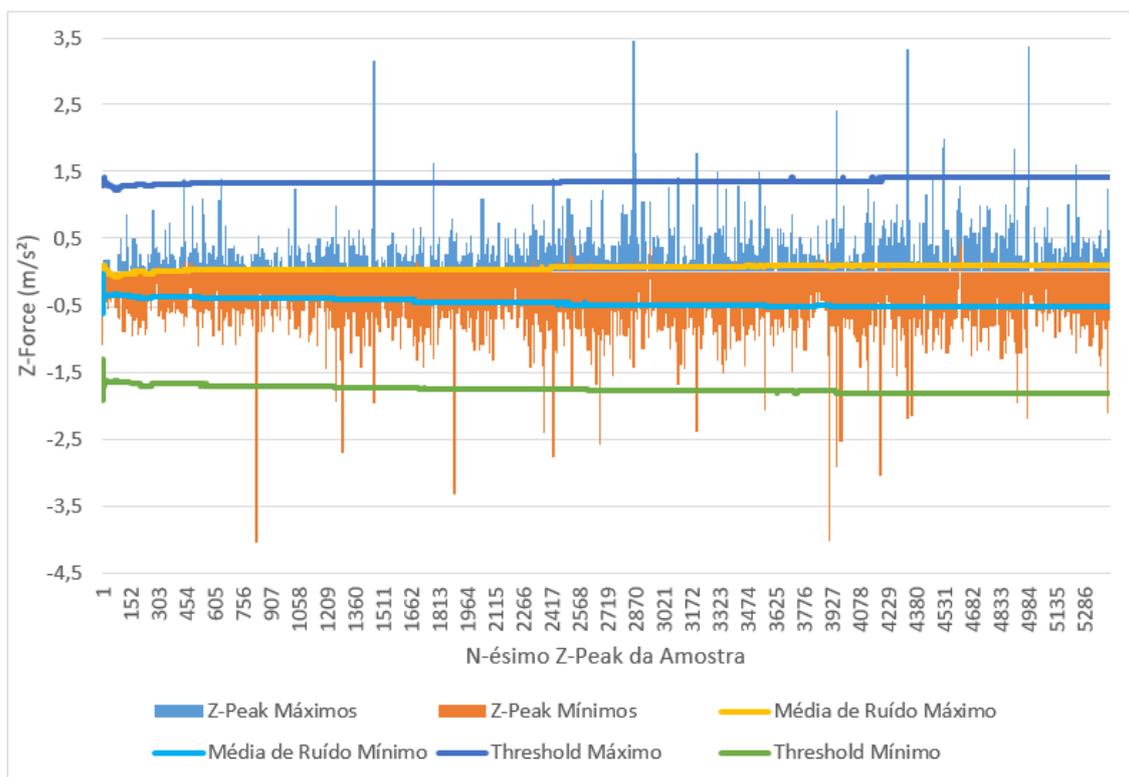
Consistindo de três etapas metodológicas, este teste baseia-se na técnica de posicionamento controlado, onde em cada etapa alinhava-se um dos eixos do sensor (X, Y ou Z) ao eixo Z do sistema de coordenadas do mundo real. Optou-se por avaliar somente em relação à Z devido este ser o eixo de maior interesse, além de os demais seguirem a mesma estratégia, resultando, portanto, em valores de erro similares. Em cada uma das etapas, com a respectiva coordenada do sensor alinhada à Z do mundo real, aplicou-se forças ao longo do eixo avaliado.

Devido à utilização de filtros de sinais que adicionam tempo de latência aos valores do sensor de gravidade, o cálculo de erro exato se mostra inviável. Contudo, foi possível estimar o erro máximo através dos dados capturados. Desta forma, para cada amostra foi estimado o erro absoluto máximo, obtido pela diferença entre o dado de força de aceleração com gravidade, o valor de gravidade aplicado ao eixo e o dado de força de aceleração real. Através do cálculo, obteve-se a média de erro máximo de  $0,060229388 \text{ m/s}^2$ . Portanto, se as amostras do sensor de gravidade e acelerômetro fossem obtidas no mesmo instante, este seria o erro alcançado. Contudo, sendo um evento difícil de ocorrer, o erro resultante considerado é menor. Desta forma, alcançando um resultado com valor de erro baixo, o recurso realizou a correta remoção do componente de gravidade.

Consistindo de duas etapas metodológicas, o segundo teste realizado compreendeu a avaliação e validação do algoritmo de detecção de buracos e seu recurso de autocalibração. Neste teste foram utilizados dois dispositivos para captura de dados, um Samsung Galaxy S2 Lite (D1) e um Samsung Galaxy J5 (D2), em dois veículos e duas rodovias diferentes. A primeira etapa do teste consistiu na captura de dados para cálculo do valor de força de impacto isolada e na determinação do valor de *threshold*, utilizado no algoritmo de detecção. Para isto, com o veículo 1, capturou-se aproximadamente 10.500 amostras, em um trecho de 20 km. Durante esta etapa, o veículo passou por

buracos de diversas profundidades e extensões, com o dispositivo D1 registrando os dados capturados. Posteriormente, aplicou-se nestes dados processamento *offline*, com simulação do algoritmo de detecção. Nesta etapa, obteve-se os valores das médias de ruído máximo e mínimo e, conseqüentemente, os valores de força de impacto isolada para cada buraco. Através da média aritmética destes valores, determinou-se um valor de *threshold* correspondente à  $1,3 \text{ m/s}^2$ , o qual foi validado através da simulação.

A segunda etapa do teste consistiu da análise do valor de limiar e do recurso de autocalibração desenvolvido. Para isto, com o veículo 2, percorreu-se aproximadamente 16 km com os dispositivos D1 e D2 configurados com o *threshold* estimado na etapa anterior, capturando cerca de 11.000 amostras. A utilização de dois veículos e dois dispositivos, em duas rodovias diferentes, decorre da validação do recurso de autocalibração proposto, que possui o objetivo de contornar problemas de sensibilidade variada entre modelos dos sensores, assim como o impacto do sistema de amortecimento veicular aos dados de força de aceleração, tornando o algoritmo de detecção adaptável aos diversos sensores e automóveis. Os dados deste teste são ilustrados na Figura 3.



**Figura 3. Amostras processadas pelo sensor de buracos ADAPD.**

Para realizar a detecção de buracos, o algoritmo isolou e analisou somente pontos referentes aos picos de força (*Z-Peak*). As médias de força máxima e mínima de ruído, no decorrer da execução, convergiram para o valor mais preciso, conforme previsto no modelo teórico. Entre as médias calculadas está, portanto, o intervalo de ruído, através do qual é obtida a força de ruído aplicada. A média de força máxima teve seu menor valor em  $-0,075329306 \text{ m/s}^2$ , maior em  $0,100644195 \text{ m/s}^2$ , estabilizando-se ao final em  $0,099147457 \text{ m/s}^2$ . A média de força mínima, por sua vez, teve seu valor máximo

em  $-0,329358191 \text{ m/s}^2$ , e mínimo em  $-0,628315163 \text{ m/s}^2$ , convergindo ao final para  $-0,505596214 \text{ m/s}^2$ . Os valores de comparação finais, *threshold* máximo e *threshold* mínimo, foram obtidos em tempo de execução, através de cálculos do *threshold* estimado ( $1,3 \text{ m/s}^2$ ) com as médias de ruído.

Na Tabela 2 estão sumarizados os resultados obtidos. Os parâmetros avaliados são baseados no estudo de Mednis et al. (2011), acrescidos de outras variáveis específicas, resultando em uma análise completa. Com o dispositivo D1 obteve-se 83,3% de detecções corretas, nenhum buraco inexistente identificado e 16,7% de buracos existentes não reconhecidos. O dispositivo D2, por sua vez, obteve 92,8% de detecções corretas, 7,2% de buracos existentes não reconhecidos e 5 falhas não existentes, mas identificadas.

**Tabela 2. Resultados sumarizados.**

Dispositivo	Verdadeiros Positivos	Verdadeiros Negativos	Falsos Positivos	Total Identificado	Total Rodovia
D1	35	7	0	35	42
D2	39	3	5	44	42

Conforme é possível observar nos dados sumarizados, o sensor do dispositivo D2 se mostra mais sensível que o de D1. Desta forma, juntamente com a análise *offline* dos dados da rodovia, observou-se que o recurso de autocalibração desenvolvido compensa apenas parte dos valores e possui, portanto, efetividade parcial, em função de dois fatores. O primeiro deles decorre do valor fixo de *threshold*. Esta força de impacto, embora isolado do ruído, ainda tem leve variação, devido à diferentes sensibilidades dos sensores. Para sua correção, em trabalhos futuros, deve-se adicionar um fator de multiplicação obtido pela variação dos valores de ruído ou suas médias. O segundo problema, por sua vez, refere-se ao fator de velocidade. Uma vez que esta implica diretamente na força aplicada, seu valor deve ser considerado tanto na força de ruído, quanto na força de impacto isolada, podendo, em novos estudos, ser empregado como um fator de multiplicação ao *threshold* estimado.

## 5. Considerações Finais

As deficiências no pavimento de rodovias constituem atualmente um dos principais entraves para o desenvolvimento socioeconômico de um país. Diante de suas implicações, o monitoramento constante da superfície, assim como seu reparo, quando necessário, se mostram essenciais para o desenvolvimento de uma nação. Desta forma, neste trabalho foi proposto um sensor adaptativo para detecção em tempo real de buracos, os quais constituem uma das deformidades mais recorrentes e perigosas presentes nas rodovias.

Utilizando de uma abordagem baseada em vibração, o sensor objetivou agregar tratativas a problemas recorrentes em estudos correlatos, como melhorias na detecção através de combinações algorítmicas, e desenvolvimento de recurso de autocalibração. Na detecção de buracos, especificamente em relação a remoção do componente de gravidade, empregou-se tratativas de sinais com desvios, como fusão de sensores e filtros de sinais, alcançando um resultado com valor de erro baixo. A combinação algorítmica, juntamente com o recurso de autocalibração produzido, implicaram em um algoritmo detector mais elaborado e adaptável aos diversos dispositivos e automóveis, embora

necessite de correções pontuais para sua efetividade total. Para melhor validação do sensor deve-se efetuar em estudos futuros testes com amostras maiores, diversos modelos de acelerômetros de três eixos, em variadas rodovias, com diferentes veículos, valores de aceleração e velocidade. Em relação à aplicabilidade, as mais diversas aplicações podem ser desenvolvidas empregando o sensor elaborado, tais como sistemas colaborativos baseados em *crowdsensing*, ou emprego junto ao transporte público para monitoramento das vias.

## Referências

- Android Developers (2017). API Guides: Motion Sensors. [https://developer.android.com/guide/topics/sensors/sensors\\_motion.html](https://developer.android.com/guide/topics/sensors/sensors_motion.html). Acesso em: 11 de outubro de 2017.
- Bayat, A., Pomplun, M., and Tran, D. A. (2014). A Study on Human Activity Recognition Using Accelerometer Data from Smartphones. *Procedia Computer Science*, 34(Supplement C):450–457.
- Borges, P. d. S. et al. (2011). Embedded System for Detecting and Georeferencing Holes in Roads. *IEEE Latin America Transactions*, 9(6):921–925.
- Burgart, S. (2014). Gap Trap: A Pothole Detection and Reporting System Utilizing Mobile Devices. [https://www.cs.umd.edu/sites/default/files/scholarly\\_papers/Burgart.pdf](https://www.cs.umd.edu/sites/default/files/scholarly_papers/Burgart.pdf). Acesso em: 11 de outubro de 2017.
- Chugh, G., Bansal, D., and Sofat, S. (2014). Road Condition Detection Using Smartphone Sensors: A survey. *International Journal of Electronic and Electrical Engineering*, 7(6):595–602.
- CNT (2016). Relatório Gerencial: Pesquisa CNT de Rodovias 2016. <http://pesquisarodovias.cnt.org.br/Paginas/relatorio-gerencial>. Acesso em: 11 de outubro de 2017.
- Garg, S. et al. (2015). RIPD: Route Information and Pothole Detection. *International Journal of Advanced Research in Computer and Communication Engineering*, 4(12):194–197.
- Kalra, N., Chugh, G., and Bansal, D. (2014). Analyzing Driving and Road Events via Smartphone. *International Journal of Computer Applications*, 98(12):5–9.
- Kim, T. and Ryu, S.-K. (2014). Review and Analysis of Pothole Detection Methods. *Journal of Emerging Trends in Computing and Information Sciences*, 5(8):603–608.
- Kulkarni, A. et al. (2014). Pothole Detection System Using Machine Learning on Android. *International Journal of Emerging Technology and Advanced Engineering*, 4(7):360–364.
- Mednis, A. et al. (2011). Real Time Pothole Detection Using Android Smartphones with Accelerometers. In *2011 International Conference on Distributed Computing in Sensor Systems and Workshops (DCOSS)*, pages 1–6. IEEE.
- Nicolas, R. (2014). Intelligent Suspension System of Lincoln MKZ to Help Mitigating Pothole. <http://www.car-engineer.com/intelligent-suspension-system-lincoln-mkz-help-mitigating-pothole-damage/>. Acesso em: 11 de outubro de 2017.
- Pacheco, H. M. (2011). Avaliação de Patologias em Pavimentos Rodoviários e suas Soluções Corretivas. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil), UEG (Universidade Estadual de Goiás), Anápolis, GO, Brasil.