

Uma abordagem não supervisionada para modelagem e análise do comportamento de motoristas

Marianne Silva* Gabriel Signoretti* Pedro Andrade*
Ivanovitch Silva* e Luiz Affonso Guedes*

* Universidade Federal do Rio Grande do Norte/PPgEEC, Natal-RN

E-mails: {marianne.silva.086, gabrielsig, pedro.meira.055}@ufrn.edu.br,
ivanovitch.silva@ufrn.br e affonso@dca.ufrn.br.

Abstract: The growth of population and urban activities provides the emergence of problems in urban systems, such as congestion, increased traffic, car accidents, among others, affecting Urban Mobility. Thus, it is known that one of the main villains are vehicles and that traditional solutions are no longer effective in solving the problem, requiring technological solutions. Therefore, the objective of this work is to propose an approach to be supported by urban mobility in order to identify anomalies in the pavements, as well as to establish the driver's behavior, through unsupervised algorithms. In addition, a case study was carried out in the city of Natal. As a result, it was found that it is possible to identify how drivers travel on roads with anomalies such as uneven pavements, speed reducers, elevated pedestrian crossings and potholes.

Resumo: O crescimento da população e das atividades urbanas proporciona o surgimento de problemas nos sistemas urbanos, como congestionamentos, aumento do tráfego, acidentes automobilísticos, entre outros, afetando a Mobilidade Urbana. Assim, sabe-se que um dos principais vilões são os veículos e que soluções tradicionais não são mais eficazes para solucionar o problema, necessitando de soluções tecnológicas. Diante disso, o objetivo desse trabalho é propor uma abordagem para ser suportada pela mobilidade urbana com o intuito de identificar anomalias nas pavimentações, bem como estabelecer o comportamento do motorista, por meio de algoritmos não supervisionados. Além disso, um estudo de caso foi realizado na cidade de Natal. Como resultado, foi verificado que é possível identificar como os motoristas trafegam sob vias com anomalias como pavimentos irregulares, redutores de velocidade, faixa de pedestres elevadas e buracos.

Keywords: Sustainable Cities; Urban mobility; Paving Detection; Driver Behavior; Unsupervised algorithm.

Palavras-chaves: Cidades Sustentáveis; Mobilidade Urbana; Detecção de Pavimentação; Comportamento do Motorista; Algoritmo não supervisionado.

1. INTRODUÇÃO

Um dos principais desafios das Cidades Sustentáveis é promover transformações espaciais, sociais e econômicas a fim de proporcionar as cidades capacidades inclusivas e inteligentes. Para isso, se faz necessário um planejamento e gestão combinados com estratégias de curto e longo prazo para o desenvolvimento da área urbana (Li et al., 2018).

As cidades precisam dispor de gestões e políticas que satisfaçam as necessidades que vão surgindo conforme o desenvolver da sociedade, correspondendo aos objetivos sociais, ambientais, políticos, culturais, econômicos e físicos dos cidadãos, utilizando os recursos da melhor forma possível (Kolesnichenko et al., 2021).

Neste sentido, a Agenda 2030 para o Desenvolvimento Sustentável da Organização das Nações Unidas (ONU), determina o Objetivo 11 que visa tornar as cidades “inclusivas, seguras, resilientes e sustentáveis”, considerando

o desenvolvimento urbano nas próximas décadas (Oliveira et al., 2021).

Desta forma, sabe-se que o crescimento da população e das atividades urbanas levam a um aumento pela demanda dos sistemas de transporte urbano (Faria et al., 2017). Assim, isso proporciona o surgimento e/ou agravamento de problemas nos sistemas urbanos como: congestionamentos, aumento do tráfego, redução do bem-estar, superlotação, dificuldade no planejamento de rotas, segurança, entre outros, o que podem afetar a Mobilidade Urbana (Chen et al., 2019).

Sabe-se que os problemas relacionados à Mobilidade Urbana não são novos, e suas deficiências provêm tanto de escolhas históricas, quanto da falta de planejamento e investimentos. Somado a isso, também existe a forte dependência de veículos motorizados como principal alternativa de transporte (Hu et al., 2020).

Para isso, percebe-se a necessidade de uma infraestrutura inovadora para auxiliar o tráfego e transporte, com o intuito de economizar recursos, melhorar a eficiência e fornecer acessibilidade aos vários serviços urbanos (Paiva et al., 2021), uma vez que a mobilidade e os meios de transporte utilizados são essenciais para que uma cidade funcione adequadamente (Faria et al., 2017).

Em vista disso, as tecnologias associadas à Internet das Coisas (IoT) vêm auxiliando em novos modelos para mobilidade, com o uso de soluções que permitem a identificação do comportamento do motorista, o que pode ser um facilitador para essa área, visto que há diversos comportamentos que podem aumentar ou reduzir a chance de acidentes, a exemplo do desrespeito às normas de trânsito Mahrez et al. (2021).

Desse modo, surgem tendências sociais e novas práticas, como é o caso dos *crowdsensing*, técnica em que grupos de pessoas com dispositivos são capazes de detectar, coletar e compartilhar os dados coletivamente para serem utilizados com o intuito de analisar, medir, mapear e outros, visando o interesse comum (Silva et al., 2019; Liu and Wu, 2021). Além disso, a utilização de técnicas de TinyML, que busca maneiras de implementar modelos de aprendizado de máquina em dispositivos de baixo poder computacional, vem sendo utilizada para auxiliar a mobilidade (Gorospé et al., 2021), conforme ilustrado na Figura 1. Nela, pode-se visualizar transportes suportados com tecnologia IoT, juntamente com a utilização de algoritmos de *Machine Learning* — neste cenário, representado pelo TinyML — logo os dados resultantes podem ser utilizados para análises de dados ou serem distribuídos para utilização posterior.

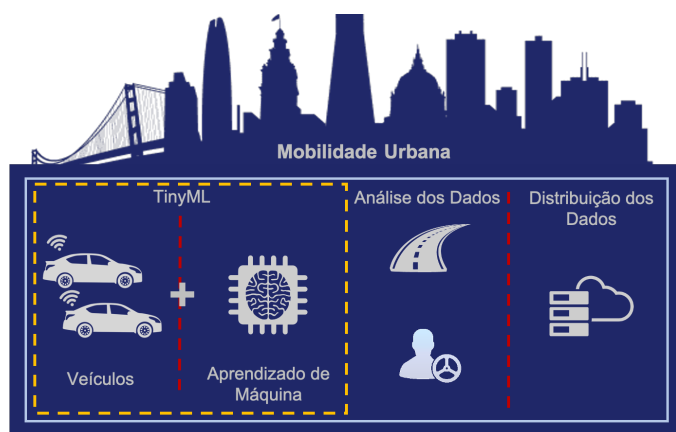


Figura 1. Tendências de tecnologias para Mobilidade Urbana.

Desta forma, este trabalho tem como objetivo propor uma abordagem para ser suportada pela mobilidade urbana, com o intuito de identificar anomalias nas pavimentações, bem como estabelecer o comportamento do motoristas com relação a elas. Para isso, utilizou-se o *Typicality and Eccentricity Data Analytics* (TEDA) e AutoCloud, algoritmos de aprendizagem adaptativas não supervisionados, que são capazes de processar *streams* de dados em modo online, aprender novos padrões com o tempo e se atualizar de forma automática, sempre que necessário (Angelov, 2014; Bezerra et al., 2020).

Ademais, um estudo de caso foi realizado na cidade de Natal-RN. Como resultado, foi verificado que é possível identificar como os motoristas trafegam sob vias com anomalias como pavimentos irregulares, redutores de velocidade, faixa de pedestres elevadas e buracos.

Por fim, o restante desse artigo encontra-se organizado da seguinte forma: na Seção 2 são detalhados alguns conceitos sobre os algoritmos TEDA e AutoCloud; na Seção 3 são apresentados os trabalhos relacionados, enquanto que na Seção 4 são elucidados detalhes da abordagem proposta; a Seção 5 descreve o estudo de caso realizado; a Seção 6 discute os principais resultados obtidos; por fim, a Seção 8 apresenta as considerações finais e indica caminhos promissores para trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

O *Typicality and Eccentricity Data Analytics* (TEDA) é um conjunto de conceitos proposto por Angelov (2014) que inclui um algoritmo para detecção de *outliers* em *streams* de dados. O seu método estatístico é baseado nos conceitos de tipicidade e excentricidade. Esses conceitos são complementares e baseados na distância de uma observação de dados específica ao conjunto de dados inteiro. Desta forma, a tipicidade relaciona-se com a similaridade de uma amostra de dados, em particular com o restante das amostras do conjunto de dados a que ela pertence. Essa similaridade normalmente é calculada com base na proximidade espacial entre as amostras em um espaço n -dimensional. Em contrapartida, a excentricidade é o oposto da tipicidade, analisando o quanto uma amostra de dados é diferente das demais amostras do conjunto. Uma amostra de dados com excentricidade alta e tipicidade baixa, possui uma tendência de ser um *outlier*.

Outra característica do TEDA que o relaciona a *streams* de dados é que ele pode se adaptar às mudanças que ocorrem no comportamento dos dados ao longo do tempo. Assim, o TEDA considera a relação histórico temporal entre as amostras, se adaptando de forma autônoma e evolutiva sem a necessidade de treinamento.

Além da abordagem TEDA para detecção de *outliers*, uma nova abordagem para agrupamento de dados fuzzy foi proposta por Bezerra et al. (2020), chamada AutoCloud. Esse modelo é capaz de agrupar observações de dados semelhantes em um fluxos de dados ao longo do tempo por meio do uso dos mesmos conceitos de tipicidade e excentricidade. Além disso, é totalmente online, não necessitando de processamento offline. Ele permite a criação e fusão de *clusters* de forma autônoma, conforme novas observações de dados se tornam disponíveis. Os *clusters* criados pelo AutoCloud são chamados de nuvens de dados, que são estruturas sem forma ou limites predefinidos. O AutoCloud permite que cada amostra de dados pertença a várias nuvens de dados simultaneamente usando conceitos difusos.

3. TRABALHOS RELACIONADOS

Muitas abordagens estão sendo desenvolvidas para identificar o comportamento dos motoristas. Nesta seção revisou-se os que identificam o comportamento do motorista ex-

plorando o uso de técnicas de Aprendizado de Máquina (AM) não-supervisionadas.

Os autores (Zhang et al., 2017), propõem uma abordagem online não-supervisionada e com reconhecimento de padrões, denominada *SafeDrive*, para detectar anomalias em comportamentos de condução a partir de dados veiculares. Os resultados da avaliação do *SafeDrive* demonstram que são capaz de identificarem uma variedade de anomalias de direção de forma eficaz. Os dados foram validados com um fluxo de dados de veículos em larga escala obtendo uma precisão geral de 93%. Assim, os autores retratam que as anomalias de condução identificadas podem ser usadas para alertar oportunamente os motoristas para corrigir seus comportamentos de direção.

Similarmente (Carfora et al., 2019), propõem uma abordagem para identificar o comportamento do motorista explorando o uso de técnicas de AM não-supervisionadas. Um estudo de caso real é realizado para avaliar a eficácia da solução proposta. Além disso, discutiu-se o modelo proposto, no qual pode ser adotado como indicador de risco para as seguradoras de automóveis.

Ainda no contexto de abordagem não-supervisionadas, encontrou-se os trabalhos (Kim et al., 2019; Nallaperuma et al., 2018). No trabalho de (Nallaperuma et al., 2018), os autores implementam um modelo com um algoritmo de aprendizado de máquina incremental não-supervisionado para detecção de mudança de comportamento abrupta e repetida. Os resultados demonstram e confirmam as capacidades do modelo e algoritmo propostos para detectar a mudança de comportamento do motorista, distinguindo entre mudanças de comportamento repentinas e repetidas. As alterações detectadas podem ser comunicadas a todos os veículos nas imediações, para uma coordenação eficaz e melhor compreensão da situação.

De forma parecida, (Kim et al., 2019), propõem uma estrutura de segmentação não supervisionada para dados de séries temporais multivariadas heterogêneas, aplicado a dados de veículos real para extrair padrões de conduções. Para isso, aplicaram uma representação distribuída de métodos de incorporação, transformaram dados heterogêneos multivariados em vetores contínuos, permitindo que eles sejam segmentados por métricas de distância convencionais, como a distância euclidiana ou cosseno. Posteriormente, segmentos semelhantes são agrupados para gerar padrões gerais. Sem nenhum rótulo ou engenharia de recursos, a estrutura segmenta e descobre com sucesso padrões de direção.

Esses trabalhos apresentam características semelhantes, porém percebe-se que eles não combinam os resultados com a identificação dos dados de pavimentação, realiza apenas o comportamento do motorista, o que difere do trabalho proposto. Complementar, apenas (Carfora et al., 2019), tem o objetivo de voltar as informações para alguma organização, que no caso é para seguros automobilísticos. Desse modo, destaca-se a relevância e a relação de cada um dos trabalhos apresentados com o trabalho proposto. Assim, a partir da discussão apresentada anteriormente, percebe-se que ainda existem lacunas a serem exploradas nessa área, fomentando o desenvolvimento de novas soluções para mobilidade urbana, fornecendo indicadores para as cidades.

4. ABORDAGEM PROPOSTA

A abordagem proposta neste artigo permite que, a partir de dados coletados pelos veículos, seja possível fornecer visualizações e análises de dados em tempo real sobre eles. Desta forma, a coleta de dados pode ser feita de forma autônoma, ou seja, não fará parte do processo, o usuário quem escolhe a forma de coleta, porém estruturado de acordo com o modelo a ser utilizado. Na Figura 2, pode-se visualizar a estrutura dessa abordagem.



Figura 2. Visão Geral da Abordagem Proposta.

Observa-se que a solução proposta inicia-se pelo conjunto de dados capturados pelo veículo (sensores), são eles: acelerômetro, velocidade, posição do acelerador e GPS. Assim, com o conjunto de dados formalizados o processo de inteligência é iniciado, por meio de duas camadas. A **Camada 1**, detecção de anomalias de pavimentação, é realizada por meio do algoritmo TEDA.

De acordo com (Angelov, 2014), o TEDA precisa apenas do valor do parâmetro (m). Na versão implementada neste trabalho o valor do parâmetro m é calculado automaticamente a partir da quantidade de colunas de dados fornecidas. O valor de m indica a sensibilidade utilizada no threshold de detecção. Quanto maior o valor de m , menor a sensibilidade do método, ou seja, a quantidade de *outliers* detectados é menor.

Assim, na Camada 1 utiliza-se como entrada de dados o cálculo do módulo da força resultante da posição do veículo em coordenadas GPS, ou seja, os três eixos do sensor de acelerômetro (x , y e z), gerando um único valor indicativo da magnitude total, conforme demonstrado na Equação 1.

$$|\vec{a}| = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (1)$$

Com isso, retorna-se o número de anomalias identificados nos pavimentos, são eles: redutores de velocidades, faixas de pedestres elevadas e diferenças nos pavimentos entre asfalto e paralelepípedo.

Na **Camada 2**, responsável pela detecção do comportamento do motorista, utiliza-se o algoritmo AutoCloud. Como dito anteriormente, ele tem como objetivo o agrupamento dos dados em *clusters*. Assim, utiliza-se os sensores de velocidade e posição do acelerador para obter uma representação do comportamento do motorista por meio dos *clusters*.

Vale ressaltar que como ambas as camadas do modelo proposta aqui utilizam algoritmos não supervisionados e evolutivos, a aplicação deles é de forma direta, necessitando apenas do valores das entrada de dados.

5. ESTUDO DE CASO

O estudo de caso visa avaliar a abordagem proposta a fim de investigar a viabilidade de identificar o comportamento do motorista e detectar anomalias nos pavimentos. Os resultados desta análise podem inferir em indicadores para mobilidade urbana. Para isso, as próximas subseções descrevem a coleta de dados, métricas de avaliação e processo de execução.

5.1 Coleta de Dados

O processo de coleta de dados foi realizada em cenário real. Assim, participou-se como voluntários dois motoristas com carros distintos, conforme a Tabela 1.

Tabela 1. Caracterização dos Participantes.

| Modelo | Ano | Motor | Transmissão | Combustível |
|-------------------|------|-------|-------------|-------------|
| Hyundai HB-20 | 2019 | 1.0 | Manual | flex |
| Chevrolet Classic | 2015 | 1.4 | Manual | flex |

Em seguida se definiu a instrumentação, ou seja, a realização da configuração do ambiente para coleta de dados desses veículos. Deste modo, utilizou-se:

- **OBD-II:** dispositivo usado para coletar dados do acelerômetro, posição do acelerador, rotação por minuto (RPM) e velocidade dos sensores dos carros. Com uma taxa de amostragem de 500 milissegundos entre cada requisição.
- **Smartphone:** dispositivo utilizado para a comunicação entre o OBD-II e o aplicativo. Além disso, para capturar os dados de GPS.
- **App Torque Pro:** aplicativo móvel usado para armazenar os dados coletados pelo OBD-II.

Vale ressaltar que, durante a viagem o app Torque Pro irá armazenar os dados enviados via Bluetooth pelo OBD-II e, ao final de cada viagem os dados coletados serão enviados ao servidor na nuvem para análises, conforme visualização da Figura 3.

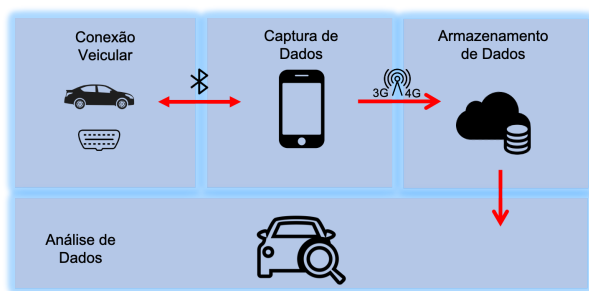


Figura 3. Visão Geral da Captura e Análise dos Dados.

Desta forma, definiu-se um percurso na cidade de Natal-RN, previamente conhecido pelos participantes, com cerca de 5km de extensão, com trechos pavimentados e asfaltados. Além disso, definiu-se o período entre 14h e 16h, para execução da rota de forma a evitar congestionamentos de trânsito.

Por fim, resultou-se dois banco de dados um para cada veículo, o Hyundai HB-20 com 1484 amostras e o Chevrolet Classic com 1218 amostras.

5.2 Análise de Dados

A tarefa de identificação de anomalias de pavimentação, como dito anteriormente não requer configuração de parâmetros, sendo calculado automaticamente. Para a identificação do perfil do motorista, definiu o valor de $m = 2$. Assim, após cada execução das camadas, gravou-se os dados em arquivo CSV para serem visualizados por meio da sua geolocalização.

6. RESULTADOS E DISCUSSÃO

Essa seção detalha os resultados obtidos após a realização do estudo de caso. Desta forma, para validar as camadas de inteligência, em relação a Camada 1, o uso do acelerômetro, constatou-se em estudos que ele é ideal para análise de pavimentos Chan et al. (2020). Para a Camada 2, realizou-se uma análise com relação aos sensores necessários para determinar o comportamento do motorista. Assim, investigou-se alguns sensores capturados pelo OBD-II (RPM, velocidade, carga do motor e posição do acelerador), além desses uma combinação criada a partir da proporção de parada, que seria o tempo no qual a velocidade inferior a 5km. Após essa análise, verificou-se a correlação entre os sensores velocidade e posição do acelerador, conforme a Figura 4, o que confirmar os sensores utilizados na Camada 2 da abordagem proposta.

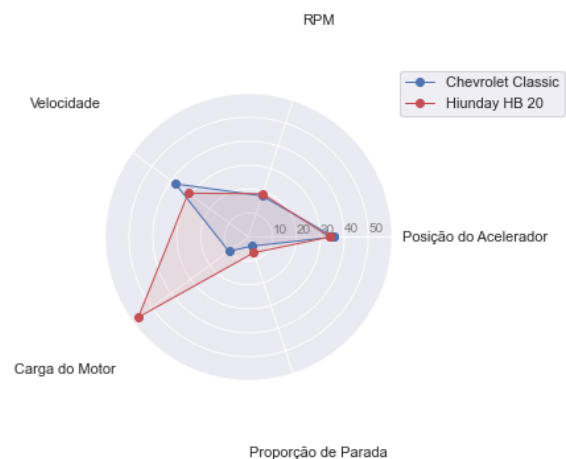


Figura 4. Relação entre os sensores capturados.

Após identificar os sensores correlacionados para detectar o comportamento do motorista, avaliou-se o sensor de velocidade. Na Figura 5, o que permite-se dizer que o condutor do Chevrolet Classic representou o comportamento mais agressivo. Atingindo uma velocidade máxima de (85km) e média de 37,7km, durante o percurso. Já o condutor do Hyundai HB-20, obteve velocidade máxima de 68km e média de 31,1km. Estes dados traz uma reflexão sobre o que pode ser realçado como resultados na Camada 2 de inteligência.

Desta forma, validou a abordagem proposta, por meio do TEDA na Camada 1, utilizando o módulo da força resultante do acelerômetro, o que foi capaz de capturar os picos bruscos de magnitude ou por mudanças no ângulo. Assim, foi possível validar a identificação dos trechos pavimentados, redutores de velocidades e faixas de pedestres elevadas. Na Figura 6, observa-se os dados da primeira

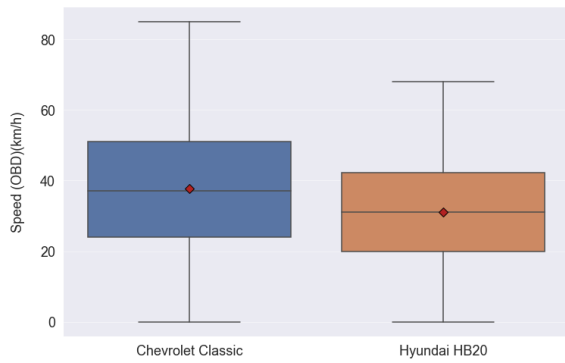


Figura 5. Distribuição de Velocidade.

camada destacados em vermelhos. Desta forma, o trecho contínuo é o local pavimentado, o qual possui cerca de 1km, bem como os pontos ao decorrer da rota são redutores de velocidade ou faixa de pedestre elevada. Quanto aos pontos duplos, caracterizam-se de redutores de velocidade seguidos de faixas de pedestre elevadas.

Na Camada 2, utilizou-se o AutoCloud, combinado com variáveis de interesse coletadas por meio do OBD-II, velocidade e posição do acelerador. Assim, o resultado foi obtido por meio de uma clusterização dos diferentes grupos de comportamento dos motoristas. Esses dados podem ser visualizados na Figura 6, nas variações em azul. Portanto, os pontos mais claros são os locais com velocidades reduzidas e os pontos mais escuros são as maiores velocidades. Quanto ao ponto amarelo, são os pontos iniciais e finais da rota.

Deste modo, observa-se que a análise da distribuição da velocidade coincide com os *clusters* encontrados, visto que o Chevrolet Classic foi o que mais oscilou entre velocidades altas e baixas, podendo inferir em freadas ou acelerações bruscas. Já o Hyundai HB-20 teve uma média de velocidade similar ao Chevrolet Classic, mesmo com sua velocidade máxima sendo inferior, ou seja, um padrão de direção mais constante.

Neste contexto, verifica-se que essas análises são indicadores de apoio para mobilidade urbana, podendo fornecer vários *insights* para melhorias da pavimentação, segura dos pedestres, monitoramento entre outros.

7. AMEAÇAS À VALIDADE

As ameaças à validade para o presente estudo, foram:

Validade interna: para este tipo de ameaça, existem os defeitos do veículo, que considera que um artefato experimental pode ter uma interpretação da finalidade do experimento pelos participantes, levando a uma mudança de comportamento inconsciente para se adaptar a tal interpretação (Orne, 2009). O que pode ser causado pelo uso indevido ou desgaste de componentes do veículo. Para sua mitigação, antes do experimento, todos os veículos escolhidos foram diagnosticados e foi verificado que todos estavam em perfeitas condições para o experimento. Além disso, as condições de tráfego não foram mitigadas devido à limitação na gestão seus riscos e, portanto, pode ter influenciado nos resultados deste experimento.



(a) Chevrolet Classic.



(b) Hyundai HB-20.

Figura 6. Análise de Vias e Comportamento do Motorista por veículo.

Validade externa: apesar da aleatoriedade, o baixo número de voluntários foi uma limitação deste estudo e, portanto, não pode-se generalizar nossas conclusões para a população analisada neste estudo. No entanto, nossos resultados nos permitem traçar *insights* para orientar futuras investigações, que devem ser feitas para aumentar a generalização das conclusões promissoras apresentadas aqui.

Validade de Construção: para esse tipo de ameaça, existem as opções de rota e ferramentas de coleta de dados. O primeiro está relacionado com a possibilidade de escolha de uma rota desconhecida para os motoristas. Para mitigar esta ameaça, escolheu uma rota que é familiar aos participantes e definiu o melhor período para esta rota, a fim de evitar qualquer congestionamento de tráfego. Finalmente, o último pode ser causado pela escolha inadequada de ferramentas de coleta de dados. Para atenuá-la, antes do experimento, foi realizado um teste piloto com pesquisador não envolvido neste estudo, com o objetivo de avaliar a

eficácia do aplicativo OBD-II e Torque Pro para coleta de dados na viagem previamente definida. Após este teste, verificou a eficácia do OBD-II e do aplicativo Torque Pro para coleta de dados de sensores automotivos.

8. CONCLUSÃO

Este artigo investigou a viabilidade da abordagem de identificar o comportamento do motorista em relação ao tipo de anomalias nos pavimentos. O estudo de caso foi realizado na cidade de Natal-RN, em cenário real, para coleta de dados. Assim, validou que com apenas dois sensores, posição do acelerador e velocidade é possível identificar o comportamento do motorista. Quanto à detecção de anomalias no pavimento, somente com o sensor do acelerômetro foi possível detectar os *outliers* (reduzidores de velocidade e pavimentos) das vias. Para isso, utilizou-se dois algoritmos evolutivos não supervisionada, denominados TEDA e AutoCloud. Estes algoritmos não requerem conhecimento prévio do conjunto de dados a ser analisado e utilizam apenas um parâmetro, ambos.

Assim, foi possível verificar como o motorista se comporta nas vias com reduzidores de velocidade e trechos de pavimentos. Este pode ser um diferencial, para contribuir para mobilidade urbana, visto que a partir destas análises alguns indicadores de melhorias podem ser inseridos nas cidades. Sejam eles, aumento do número de reduzidores de velocidades e faixa de pedestres, diminuir a velocidade máxima de vias, entre outros.

Como trabalho futuro inclui, mas não está limitado a: melhoria do algoritmo para diferenciar outras anomalias nos pavimentos, como buracos; Incorporar a abordagem proposta em um dispositivo OBD-II Edge, que não requer um *smartphone* e opera de forma autônoma em seu processamento de informações.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Bem como a agência brasileira de fomento Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Processo nº 435683/2018-7.

REFERÊNCIAS

- Angelov, P. (2014). Anomaly detection based on eccentricity analysis. In *2014 IEEE Symposium on Evolving and Autonomous Learning Systems (EALS)*, 1–8. IEEE.
- Bezerra, C.G., Costa, B.S.J., Guedes, L.A., and Angelov, P.P. (2020). An evolving approach to data streams clustering based on typicality and eccentricity data analytics. *Information Sciences*, 518, 13–28.
- Carfora, M., Martinelli, F., Mercaldo, F., Nardone, V., Orlando, A., Santone, A., and Vaglini, G. (2019). A “pay-how-you-drive” car insurance approach through cluster analysis. *Soft Computing*, 23(9), 2863–2875.
- Chan, T.K., Chin, C.S., Chen, H., and Zhong, X. (2020). A comprehensive review of driver behavior analysis utilizing smartphones. *IEEE Transactions on Intelligent Transportation Systems*, 21(10), 4444–4475.
- Chen, S., Kuhn, M., Prettnner, K., and Bloom, D.E. (2019). The global macroeconomic burden of road injuries: estimates and projections for 166 countries. *The Lancet Planetary Health*, 3(9), e390–e398.
- Faria, R., Brito, L., Baras, K., and Silva, J. (2017). Smart mobility: A survey. In *2017 International Conference on Internet of Things for the Global Community (IoTGC)*, 1–8.
- Gorospe, J., Mulero, R., Arbelaitz, O., Muguerza, J., and Antón, M.Á. (2021). A generalization performance study using deep learning networks in embedded systems. *Sensors*, 21(4), 1031.
- Hu, L., Ou, J., Huang, J., Chen, Y., and Cao, D. (2020). A review of research on traffic conflicts based on intelligent vehicles. *Ieee Access*, 8, 24471–24483.
- Kim, H., Kim, H.K., Kim, M., Park, J., Cho, S., Im, K.B., and Ryu, C.R. (2019). Representation learning for unsupervised heterogeneous multivariate time series segmentation and its application. *Computers & Industrial Engineering*, 130, 272–281.
- Kolesnichenko, O., Mazelis, L., Sotnik, A., Yakovleva, D., Amelkin, S., Grigorevsky, I., and Kolesnichenko, Y. (2021). Sociological modeling of smart city with the implementation of un sustainable development goals. *Sustainability Science*, 16(2), 581–599.
- Li, D., Ma, J., Cheng, T., van Genderen, J., and Shao, Z. (2018). Challenges and opportunities for the development of megacities. *International Journal of Digital Earth*.
- Liu, Z. and Wu, K. (2021). A crowdsensing based traffic monitoring approach. In *Mobility Data-Driven Urban Traffic Monitoring*, 49–63. Springer.
- Mahrez, Z., Sabir, E., Badidi, E., Saad, W., and Sadik, M. (2021). Smart urban mobility: When mobility systems meet smart data. *IEEE Transactions on Intelligent Transportation Systems*.
- Nallaperuma, D., De Silva, D., Alahakoon, D., and Yu, X. (2018). Intelligent detection of driver behavior changes for effective coordination between autonomous and human driven vehicles. In *IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, 3120–3125.
- Oliveira, F., Nery, D., Costa, D.G., Silva, I., and Lima, L. (2021). A survey of technologies and recent developments for sustainable smart cycling. *Sustainability*, 13(6).
- Orne, M.T. (2009). Demand characteristics and the concept of quasi-controls. *Artifacts in behavioral research: Robert Rosenthal and Ralph L. Rosnow's classic books*, 110, 110–137.
- Paiva, S., Ahad, M.A., Tripathi, G., Feroz, N., and Casalino, G. (2021). Enabling technologies for urban smart mobility: Recent trends, opportunities and challenges. *Sensors*, 21(6), 2143.
- Silva, M., Signoretto, G., Oliveira, J., Silva, I., and Costa, D.G. (2019). A crowdsensing platform for monitoring of vehicular emissions: A smart city perspective. *Future Internet*, 11(1), 13.
- Zhang, M., Chen, C., Wo, T., Xie, T., Bhuiyan, M.Z.A., and Lin, X. (2017). Safedrive: Online driving anomaly detection from large-scale vehicle data. *IEEE Transactions on Industrial Informatics*, 13(4), 2087–2096.