

Distinção de Modos de Transporte em Áreas Urbanas com base no uso de Protótipo de Receptor GNSS

*Distinction of Transport Modes in Urban Areas Based on the Use of GNSS Receiver
Prototype*

*Distinción de Modos de Transporte en Áreas Urbanas Basada en el Uso del Prototipo de
Receptor GNSS*

Thiago Botion Neri

Doutorando, UEL, Brasil
thiagobotion.neri@uel.br

Thiago Vinicius Louro

Mestrando, UEL, Brasil
tvinicius.louro@uel.br

Heliana Barbosa Fontenele

Professora Doutora, UEL, Brasil
heliana@uel.br

Carlos Alberto Prado da Silva Junior

Professor Doutor, UEL, Brasil
cprado@uel.br



RESUMO

Com o processo de urbanização pelo qual o mundo vem passando nas últimas décadas, os problemas inerentes às cidades tornam-se cada vez mais sérios. Assim, o planejamento de transporte precisa ser feito com maior precisão, em intervalos de tempo mais curtos e com custos mais acessíveis. Neste estudo, foi apresentado um processo para caracterizar e diferenciar viagens por diferentes modos de transporte através de dados brutos do receptor GNSS. Para a coleta de dados de viagem, foi utilizado um protótipo de receptor GNSS desenvolvido com a plataforma Arduino. Foram coletados dados de deslocamentos, realizados por quatro modos de transporte. A análise dos dados de velocidade e aceleração, permitiu diferenciar os deslocamentos por modos não motorizados e motorizados, além de, diferenciar as viagens realizadas por meio de caminhada e bicicleta. No entanto, somente com a ajuda de um SIG foi possível diferenciar viagens por carro e ônibus.

PALAVRAS-CHAVE: Planejamento de Transportes. Dados de Viagem. Deslocamentos Urbanos.

ABSTRACT

With the urbanization process that the world has been going through in recent decades, the problems inherent in cities become increasingly serious. Thus, transport planning needs to be done more precisely, at shorter time intervals and at more affordable costs. In this study, a process was presented to characterize and differentiate travel by different modes of transport through raw GNSS receiver data. For travel data collection, a GNSS receiver prototype developed with the Arduino platform was used. Displacement data were collected by four modes of transport. The analysis of speed and acceleration data made it possible to differentiate between non-motorized and motorized modes, as well as to distinguish between trips made by walking and cycling. However, only with the help of a GIS, it was possible to differentiate travel by car and bus.

KEYWORDS: *Transportation Planning. Travel data. Urban displacements.*

RESUMÉN

Con el proceso de urbanización que atraviesa el mundo en las últimas décadas, los problemas inherentes a las ciudades se vuelven cada vez más graves. Por lo tanto, la planificación del transporte debe hacerse con mayor precisión, a intervalos de tiempo más cortos y a costos más asequibles. En este estudio, se presentó un proceso para caracterizar y diferenciar los viajes por diferentes modos de transporte a través de los datos sin procesar del receptor GNSS. Para la recopilación de datos de viaje, se utilizó un prototipo de receptor GNSS desarrollado con la plataforma Arduino. Los datos de desplazamiento fueron recolectados por cuatro modos de transporte. El análisis de los datos de velocidad y aceleración permitió diferenciar entre modos no motorizados y motorizados, así como distinguir entre viajes realizados a pie y en bicicleta. Sin embargo, solo con la ayuda de un SIG, fue posible diferenciar los viajes en automóvil y autobús.

PALABRAS-CLAVE: *Planificación de Transporte. Datos de Viaje Desplazamientos Urbanos.*

1 INTRODUÇÃO

A humanidade passou por um intenso processo de urbanização a partir da década de 1950. De acordo com relatório divulgado pela Organização das Nações Unidas (ONU) em 2018, a população urbana no mundo saltou de 30% em 1950 para 55% em 2018. A expectativa é que até 2050 esse índice atinja 68%. Um fenômeno mais intenso pôde ser observado no Brasil, onde a população urbana saltou de 31,24% em 1940 para 84,36%, segundo o último censo (IBGE, 2010). A expectativa, no Brasil, segundo a ONU (2016), é de que a população que reside nas cidades alcance 91,1% até 2030.

De acordo com Laranjeiro et al. (2019), os desafios relacionados ao espaço urbano são ainda maiores em grandes cidades localizadas em países emergentes, onde os problemas de mobilidade têm de ser resolvidos em um contexto de alta densidade urbana, congestionamentos, exclusão social, problemas de segurança, entre outros. Diante da previsão de crescimento da população urbana, a expectativa é de que o fluxo de pessoas e mercadorias aumente, o que acarretaria em maiores tempos de viagem e na piora dos congestionamentos. Desse modo, é possível que ocorra uma intensificação de problemas que já acontecem nas cidades, tais como: poluição do ar e sonora, acidentes, problemas econômicos, entre outros. Diante desse contexto, segundo Bachir et al. (2019), cabe aos gestores a promoção de medidas que tornem as cidades mais eficientes, buscando soluções inovadoras que auxiliem no planejamento do sistema de transporte.

Compreender os padrões de viagem, identificar a demanda por transporte e as preferências dos usuários é fundamental no planejamento de transportes e para as cidades. Historicamente, segundo Prelicpcean et al. (2018), dados sobre essas informações têm sido coletados de modo manual, por meio de pesquisas realizadas pessoalmente, via correios e, mais recentemente, via internet. Esses métodos tradicionais possuem problemas como: elevado custo, baixa precisão etc. Com o surgimento de novas tecnologias, pesquisas têm sido realizadas de forma a desenvolver métodos automatizados de coleta de dados de viagem. Estes dados, foram inicialmente obtidos por meio de equipamentos que utilizam o sistema conhecido por GPS (Sistema de Posicionamento Global). Entretanto, na atualidade a aquisição dos padrões viagens tem sido por meio do sistema GNSS (Sistema Global de Navegação por Satélite), o qual capta sinais de todas as constelações de satélites usados para posicionamento e navegação global, tais como: GPS, *Glonass*, *Beidou* e Galileu.

A maioria dos trabalhos que trata da automação da coleta e do desenvolvimento de métodos de análise de dados de viagem, se utilizam de dados de GPS, em geral obtidos por aplicativos para *smartphones* ou de aparelhos GPS comerciais. No contexto dos países em desenvolvimento é possível que não seja viável a aquisição de uma quantidade suficiente de aparelhos GPS comerciais para a realização de pesquisas de viagem em larga escala, enquanto os smartphones

ainda não estão presentes de modo igualitário em todas as classes sociais, o que não permite a realização de estudos de padrão de viagem apenas com este dispositivo.

Dessa forma, a caracterização das viagens urbanas poderia ser realizada por meio de equipamentos que sejam de baixo custo e de fácil tratamento das informações, podendo assim, viabilizar pesquisas com maior precisão e frequência, auxiliando os gestores urbanos nas tomadas de decisões em políticas públicas de transporte.

2 OBJETIVO

O presente trabalho objetivou caracterizar os diferentes modos de viagens urbanas por meio de dados brutos de GNSS, construído a partir de prototipagem eletrônica, através da plataforma Arduino.

3 COLETA DE DADOS EM TRANSPORTE

Pode-se dividir os métodos de coleta de dados de viagens em dois: preferência declarada e preferência revelada. O primeiro consiste na verificação de situações hipotéticas, onde o entrevistado responde qual seria o seu comportamento diante de uma situação apresentada. Essas pesquisas podem ser presenciais, com a utilização de questionários impressos ou digitais, ou não presenciais, tais como: telefone, correio ou e-mail. Os problemas desse tipo de pesquisa, consistem geralmente no alto custo da coleta dos dados, e na baixa precisão, já que as informações dependem da memória do usuário. Segundo Campos (2013), estas pesquisas podem ser muito úteis para se estabelecer curvas de demanda de sistemas ainda não implantados e também para verificar a opinião dos usuários acerca de determinado tema, como por exemplo, a implantação de pedágios urbanos.

O método de preferência revelada, consiste na coleta de informações obtidas a partir de situações reais. Esses dados podem ser genéricos, referentes a contagens de tráfego, pesquisas de embarque e desembarque, movimentação em linhas que separam zonas de tráfego, ou individuais, por meio da coleta das informações de viagem de um usuário (Campos, 2013). Os métodos de coleta de dados individuais consistem usualmente no uso de dispositivos como aparelhos GPS e *smartphones*. Os dados obtidos por meio destes dispositivos são normalmente tratados utilizando inteligência artificial, algoritmos, aprendizado de máquina, entre outros métodos (PRELICPCEAN, et al., 2018).

A utilização de dispositivos GPS para pesquisas de viagens começou a ocorrer na década de 1990. Inicialmente, os dispositivos GPS eram instalados nos veículos e carregados por meio das baterias veiculares, o que permitia obter os dados apenas de viagens realizadas por automóvel. Esse problema chegou ao fim com a diminuição do tamanho dos dispositivos GPS e a evolução das baterias, o que possibilitou a coleta de dados de outros modos de transporte. Alguns

problemas recorrentes desse tipo de dispositivo são: o participante esquecendo de levar o dispositivo consigo e problemas de sinais (GONG et al., 2014).

Mais recentemente, pesquisas sobre utilização de *smartphones* para a obtenção de dados de viagem têm sido realizadas. É comum que os aparelhos mais modernos possuam dispositivos como GPS, acelerômetro etc. A utilização de *smartphones* para a coleta de dados de viagens é justificada por já ser comum em vários países, que grande parte da população possua um aparelho, o que possibilitaria uma coleta de dados em períodos curtos de tempo e em grande escala. No entanto, existem problemas na utilização destes dispositivos para a coleta de dados de viagem, como: privacidade, consumo de bateria, preço dos dispositivos mais modernos, entre outros.

Pesquisas têm sido desenvolvidas com o objetivo de aperfeiçoar os métodos de coleta de dados GPS, seja por *smartphone* ou por dispositivo GPS. No trabalho de Stopher et al. (2018) os autores compararam o uso de aplicativo para *smartphone* e de um dispositivo GPS para a coleta de dados de viagem. Foram recrutadas mais de 600 pessoas para a pesquisa. Os autores concluíram que os participantes estiveram mais propensos a participar da pesquisa utilizando GPS dedicado do que utilizando *smartphone*. Segundo os autores, alguns participantes reportaram esta preferência por questões de privacidade. Após o processamento dos dados foram obtidos resultados semelhantes para os dois aparelhos. Os autores sugerem a utilização dos dois dispositivos na realização de pesquisas de viagem, de modo complementar.

No estudo de Montini et al. (2015), os autores compararam um aplicativo para *smartphone* e um dispositivo GPS para a obtenção de dados de viagem. O estudo foi conduzido com dados de 33 participantes, aos quais foi solicitado que levassem consigo ambos os dispositivos durante oito semanas. Os autores concluíram que o uso de dispositivos GPS traz benefícios em relação a bateria e precisão dos dados. No caso específico desse estudo, os participantes estiveram mais propensos a levar consigo o GPS dedicado.

Zong et al. (2019) desenvolveram modelos de previsão de destino baseado em dados de GPS de vários dias de viagem na cidade de Changchun, China. Foi utilizado um dispositivo GPS para a coleta dos dados, além de questionários preenchidos pelos participantes com informações sobre as viagens. Para a elaboração dos modelos foram utilizados cadeia de Markov e modelo Multinomial. No trabalho de Dabiri e Heaslip (2018), os autores utilizam redes neurais convolucionais para identificar cinco modos de transporte a partir de dados brutos de GPS. Foram extraídas características como: velocidade, aceleração, desaceleração, variação da aceleração e desvio do ponto de coleta em relação ao norte.

Na pesquisa realizada por Xiao et al. (2017), foi desenvolvido um método para a identificação de seis modos de transporte utilizando *machine learning*. A metodologia apresentada possui quatro etapas: pré-processamento, extração das características, classificação e avaliação dos modelos. Foram considerados quatro parâmetros principais: velocidade, aceleração, ângulo entre dois pontos consecutivos e sinuosidade (variação da altura entre pontos dividida pela distância entre eles). Extraíu-se onze características de cada um desses parâmetros, como:

média, desvio padrão, moda, entre outros. Foi utilizado 70% dos dados para extrair as características dos modos, e com os 30% restantes, os autores compararam três métodos de aprendizado por agrupamento para a identificação do modo de transporte: *Random Forest*, *Gradient Boosting Decision Tree* e *XGBoost*. O método *XGBoost* foi o que apresentou melhor resultado, com aproximadamente 90% de acurácia.

O uso de sensores existentes em smartphones, foi estudado por Shafique e Hato (2016) para a extração de nove características em viagens realizadas por seis modos de transporte. Foram coletados dados de 50 participantes em Kobe, no Japão, com a utilização de um aplicativo para *smartphone*. Foram armazenados os dados de um acelerômetro, sensor de orientação e GPS. Para a extração das características, utilizou-se apenas os dados do acelerômetro, os dados do sensor de orientação e do GPS utilizados apenas para verificação. A partir dos dados do acelerômetro foram extraídas características como: aceleração resultante, desvio padrão, aceleração resultante máxima e média, entre outras. Após a definição das características foi utilizado o método de *learning machine Random Forest*, de forma a desenvolver um algoritmo para identificar modos de viagem automaticamente. Os autores identificaram que maiores frequências implicam em melhores acurácias na identificação de modos de transporte, ao passo que aumentam o custo do tratamento dos dados.

No estudo de Bol Bol et al. (2012), os autores buscaram diferenciar os modos de transporte por meio de alguns fatores. Concluiu-se que os mais importantes na diferenciação foram os padrões de velocidade e aceleração. Foram coletados dados de 81 participantes em Londres num período de duas semanas. Os autores utilizaram a ferramenta estatística *boxplot* visando caracterizar o comportamento dos dados coletados. Com os dados de velocidade, foi possível identificar apenas o modo a pé e o modo trem, por apresentarem velocidades muito contrastantes com os demais. Com os dados de aceleração foi possível identificar o modo carro. Xiao et al. (2015) desenvolveram um trabalho com o objetivo de inferir o modo de transporte a partir de dados de GPS coletados via *smartphone*. Foram coletados dados de 101 pessoas na cidade de Shanghai. O aplicativo utilizado na coleta, foi desenvolvido de modo que parasse de funcionar depois de mais de 5 minutos de inatividade. Utilizando redes neurais, os autores conseguiram identificar o modo de aproximadamente 95% das viagens. Por meio da ferramenta estatística *bloxspot*, na distribuição dos dados de velocidade, foi possível diferenciar os modos a pé e bicicleta, os quais atingiram velocidades médias e máximas inferiores a 5 m/s, dos modos ônibus e automóveis, com velocidades médias superiores que 5 m/s e velocidade máxima de 10 m/s a 15 m/s. Nesta pesquisa, os autores observaram também que a distribuição dos dados de aceleração não auxiliou na diferenciação entre os modos carro e ônibus.

Os novos e diversificados métodos de coleta de dados de viagem precisam ser aprimorados de forma que possam ser utilizados em grande escala, substituindo os métodos tradicionais. Não existe consenso quanto às metodologias a serem utilizadas para a aferição de características de viagem a partir de dados de GPS, nem da forma de coleta dos dados. A realização de pesquisas utilizando unicamente *smartphones* ou dispositivos GPS dedicados, podem resultar na falta de

informações sobre determinadas faixas da população. O custo de dispositivos GPS tradicionais é um fator importante no custo total das pesquisas realizadas. O desenvolvimento de dispositivos de baixo custo para a coleta de dados de viagem e fácil tratamento das informações, atende a uma demanda existente na literatura e na sociedade.

4 METODOLOGIA

A partir dos dados adquiridos, caracterizou-se os modos bicicleta, ônibus, a pé e automóvel, por meio das velocidades e acelerações obtidas. Em sequência, as viagens foram representadas e diferenciadas espacialmente em um SIG (Sistema de Informação Geográfica).

Assim a pesquisa tem o intuito de contribuir para o desenvolvimento de procedimentos e ferramentas para coleta e análise de dados de viagem, de forma mais acessível, ampla e contínua, visando o seu uso no planejamento dos transportes nas cidades.

A pesquisa compreendeu a caracterização e a diferenciação de deslocamentos realizados por diferentes modos de viagem. Foi realizada a coleta de dados relacionada aos deslocamentos por quatro diferentes modos de transporte. Para realizar a coleta de dados, foi usado um protótipo de receptor GNSS, o qual foi desenvolvido por Kihara et al. (2019). A análise dos dados foi feita por meio de ferramentas estatísticas e análise de densidade de *kernel* em um SIG.

4.1 Protótipo de Receptor GNSS

O protótipo de receptor GNSS usado neste estudo foi o mesmo desenvolvido por Kihara et al. (2019). Este dispositivo, considerado de baixo custo, foi construído por meio de prototipagem eletrônica com um microcontrolador Arduino, módulo GPS, SD *card* e duas baterias de Li-Ion 18650 de 3,7 volts cada uma. A programação do protótipo foi realizada por meio da Arduino IDE. Este protótipo de receptor GNSS possui as mesmas funcionalidades requeridas nesta pesquisa que um aparelho comercial, porém a um custo mais acessível.

4.2 Coleta de Dados de Viagem por Modo

Foram coletados dados de viagens de três estudantes voluntários em seus deslocamentos semanais para um campus universitário. Os participantes possuíam em comum a origem de suas viagens, neste caso o campus, sendo os destinos variáveis. O protótipo de receptor GNSS estava programado para coletar dados a cada 5 segundos. Cada voluntário contribuiu na coleta de dados com viagens feitas por um único modo de transporte: a pé; bicicleta; carro e ônibus. Para caso específico das análises das viagens a pé foram considerados os trechos de caminhada entre a origem e o ponto de ônibus e do ponto de ônibus ao destino. Os participantes foram orientados sobre o funcionamento, modo de utilização e armazenamento do protótipo de receptor GNSS. Foi solicitado que o equipamento ficasse ligado somente durante as viagens.

Uma das preocupações da etapa de coleta de dados foi a autonomia das baterias de alimentação do protótipo GNSS. As cargas eram verificadas a cada dois dias e quando necessário feita a troca das baterias. Para cada novo voluntário também era feita a substituição das mesmas. Em média cada conjunto de baterias teve autonomia de quatro dias. Os dados coletados compreenderam: latitude; longitude, altitude, horário, velocidade instantânea, direção do deslocamento e número de satélites conectados.

4.3 Tratamento e Caracterização dos Modos de Viagem

Os dados gerados pelo protótipo GNSS foram armazenados em um cartão de memória em formato .csv. Ao final do ciclo de viagens semanais de cada voluntário, o cartão de memória era extraído e os registros transferidos para a memória de um computador. Estes registros foram manuseados em uma planilha eletrônica. Cada linha nesta planilha representava um ponto georreferenciado pelo protótipo GNSS com os atributos de coordenadas geográficas, velocidade instantânea, horário e quantidade de satélites.

A primeira etapa do tratamento foi a filtragem dos dados obtidos, com o objetivo de garantir maior precisão na análise. A quantidade de satélites identificados pelo protótipo GNSS e os dados de velocidade máxima, foram considerados, sendo excluídos todos que obtiveram menos de quatro satélites e/ou velocidades incompatíveis com o modo de transporte em questão. A partir dos dados de variação de velocidade e tempo foi possível estimar os dados de aceleração entre dois pontos consecutivos, sendo esta, juntamente com velocidade, duas das variáveis presentes nas pesquisas correlatas analisadas. As latitudes e longitudes foram transformadas de coordenadas geográficas para UTM (*Universal Transversa de Mercator*). Os dados de velocidade e aceleração foram analisados por meio de gráficos *boxplot* que permitiram caracterizar estatisticamente os valores dos parâmetros das seis viagens realizadas em cada modo de transporte.

Para refinar a caracterização, os dados coletados foram analisados em um SIG. No software utilizado, foram gerados mapas temáticos com a representação georreferenciada de todas as viagens. Para fins de análise foi usada uma viagem de cada modo, partindo de uma mesma origem. No SIG as informações foram transformadas em uma camada de pontos, por meio das latitudes e longitudes fornecidas e em seguida em arquivos geográficos do tipo ponto. Esta camada foi incorporada a rede de vias georreferenciada da cidade de Londrina, a qual é uma camada de linhas em formato .shp e disponibilizada no site da Prefeitura local. Todas as camadas foram trabalhadas com o sistema de referência SIRGAS 2000 UTM Zone 22S.

Para analisar características importantes referentes aos dados coletados, como a formação de *clusters* de pontos coletados ou o distanciamento dos mesmos, foi utilizada a ferramenta *density grid* do software TransCAD. Este recurso torna capaz a visualização em forma de grade, dos dados de pontos. O seu funcionamento se dá por meio da densidade de pontos próximos que

gera um valor, atribuído a célula de cada grade. Trata-se de uma ferramenta bastante utilizada na identificação de congestionamentos, por exemplo (CALIPER, 2019).

5 RESULTADOS

Em consonância com o estado da arte apresentado nesta pesquisa, os parâmetros básicos utilizados inicialmente para caracterizar os modos de transporte, foram a velocidade instantânea e a aceleração alcançadas durante os deslocamentos. Em seguida, a espacialização dos dados com a criação de mapas temáticos, permitiu caracterizar melhor o comportamento dos diferentes modos de transporte, por meio da identificação de clusters dos pontos georreferenciados. Os dados foram coletados em deslocamentos no sistema viário de Londrina, sendo o número de viagens analisadas por modo, limitado pelo total de viagens conseguidas pelo modo bicicleta. Esta limitação foi decorrente de alguns problemas ambientais e erros na gravação dos dados.

5.1 Uso do Protótipo de Receptor GNSS para a Coleta de Dados

O protótipo foi montado em uma caixa de papel *kraft*, apenas com a antena do GPS para o lado de fora. Os participantes tinham que acionar o receptor GNSS através de um interruptor. Nas viagens realizadas por automóvel, o protótipo estava localizado em um suporte próximo ao câmbio do veículo, procedimento este, que não gerou nenhum problema, como por exemplo, a perda de sinal do sistema de satélites. Os voluntários não reportaram nenhum tipo de problema de manuseio e funcionamento do protótipo, com exceção da bicicleta. Nas viagens por este modo, foram atestados os seguintes problemas: devido a trepidação, alguns jumpers de ligação do dispositivo soltaram-se, impedindo seu funcionamento efetivo e os dias chuvosos durante o período de coleta, que impossibilitaram o uso do protótipo.

No seu estado atual o protótipo ainda requer melhorias em relação a autonomia de funcionamento. As baterias usadas são capazes de fornecer alimentação por 12 horas ininterruptas. Caso o voluntário se esquecesse de desligar o aparelho, o mesmo não registraria os dados das demais viagens necessárias ao experimento. Sendo assim, as melhorias no protótipo devem visar maior independência de manuseio por parte dos voluntários em relação ao correto funcionamento, de modo que ligar e desligar o dispositivo não dependesse do usuário.

5.2 Caracterização de Modos de Viagens pela Velocidade e Aceleração

Para a caracterização de diferentes modos de transporte por meio de dados brutos de GPS, as principais variáveis analisadas são as velocidades e acelerações médias e máximas. A partir da análise desses dados, é possível identificar um padrão para os modos de transporte estudados.

Assim, em uma viagem na qual o modo de transporte não é conhecido, pode ser realizada uma comparação do padrão dos dados dessa viagem com os valores de velocidade e aceleração média e máxima de modos conhecidos, estabelecidos em estudos prévios. Cabe ressaltar que apenas a análise do padrão de velocidade e aceleração pode não ser suficiente para a identificação do modo de transporte, de maneira que outras variáveis podem ser necessárias para que essa identificação ocorra. Na Tabela 1 são apresentados os valores de velocidade e aceleração média e máxima por modos de transporte utilizados neste estudo.

Tabela 1: Velocidades e acelerações médias e máximas por modo

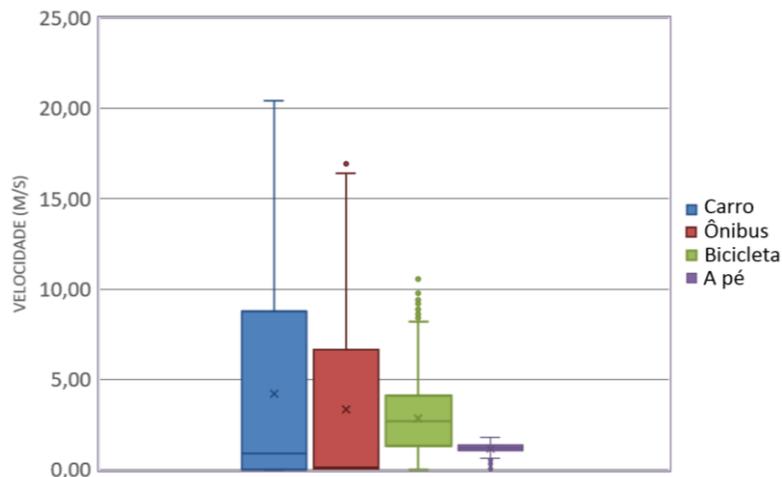
Modo	Velocidade Média (km/h)	Velocidade Máxima (km/h)	Aceleração Média (m/s ²)	Aceleração Máxima (m/s ²)
Bicicleta	10,22	37,98	0,13	1,24
A pé	4,20	6,44	0,05	0,3
Ônibus	21,61	60,99	0,41	2,04
Carro	25,8	73,55	0,37	2,37

Fonte: OS AUTORES, 2019

A partir dos dados brutos do protótipo GNSS foram criados gráficos *boxplot*. Isto permitiu a visualização da variação do padrão de velocidade em cada modo de viagem. Na Figura 1 é apresentado um *boxplot* dos dados de velocidade das seis viagens realizadas pelos quatro modos de transporte estudados.

Com os dados de velocidade é possível perceber uma diferenciação entre os modos não motorizados e motorizados. No modo carro são atingidas velocidades de até 20 m/s (72 km/h) e no modo ônibus velocidades de aproximadamente 17 m/s (61 km/h). No modo bicicleta, exceto por um valor, não foram atingidas velocidades maiores do que 10 m/s (36 km/h) e velocidades ainda menores no modo a pé. Entre os modos bicicleta e a pé também é possível notar diferença nos valores de velocidade, com o modo bicicleta apresentando uma maior dispersão dos valores de velocidade, assim como velocidades médias e máximas maiores do que no modo a pé.

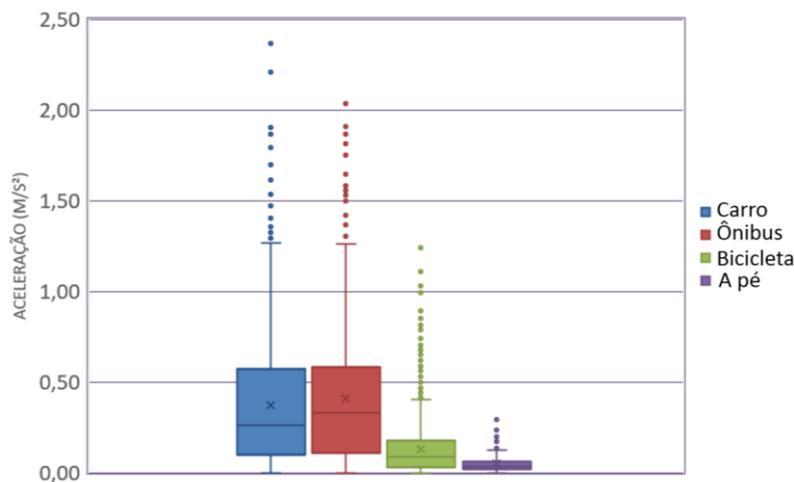
Figura 1: *Boxplot* das velocidades por modo de transporte



Fonte: Elaborado pelos autores, 2019.

De maneira semelhante aos dados de velocidade, pode-se novamente perceber uma clara diferenciação entre os dados de aceleração dos modos não motorizados e motorizados. Na Figura 2 tem-se um *boxplot* dos dados de aceleração das seis viagens realizadas pelos quatro modos de transporte estudados. Os valores de aceleração dos modos bicicleta e a pé são menores do que os valores dos modos carro e ônibus, o que já era esperado. Entre os modos bicicleta e a pé, pode-se perceber a ocorrência de valores *outliers*, ou seja, que se destacam do conjunto de dados. Especificamente nas viagens por bicicleta, nos trechos de rampas descendentes, onde o veículo adquire maiores acelerações e conseqüentemente alcança velocidades mais elevadas rapidamente.

Figura 2: *Boxplot* dos dados de aceleração por modo de transporte



Fonte: Elaborado pelos autores, 2019.

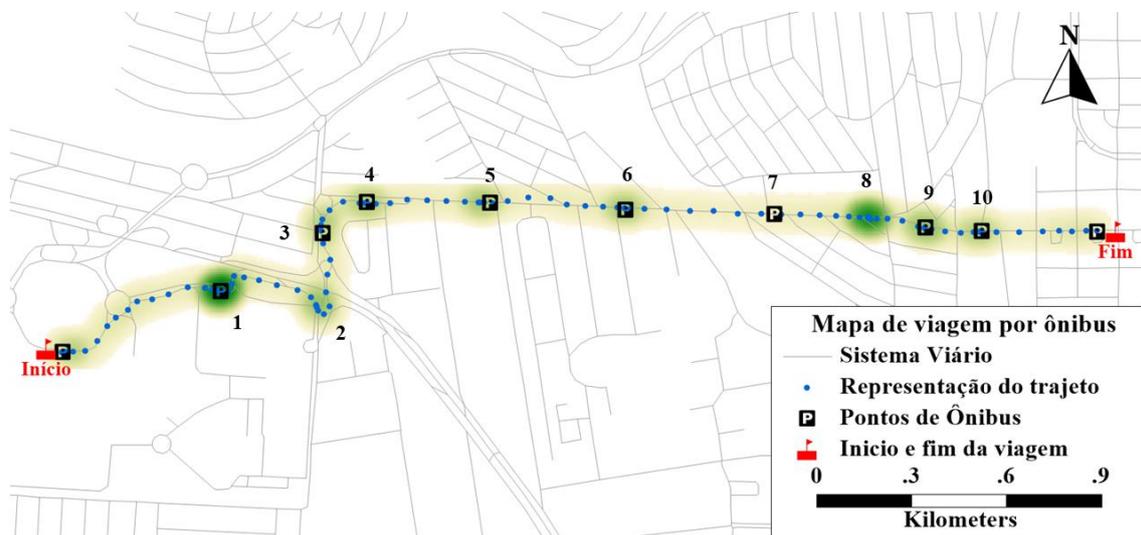
Os dados de aceleração podem ser utilizados para ratificar as características relacionadas aos dados de velocidades para diferentes modos de viagem. Por exemplo, nas viagens de bicicleta, que possuem velocidades similares a caminhada, a diferenciação entre estes modos pode ser feita pela análise dos valores de aceleração. De modo semelhante aos dados de velocidade, não é possível diferenciar os dados de aceleração dos modos carro e ônibus. Estes dois modos apresentam valores muito próximos de aceleração média e máxima e apresentam valores *outliers*, o que pode ser explicado por serem veículos motorizados, desenvolvendo maiores acelerações após paradas, tais como: semáforos; interseções; ponto de parada etc.

Conforme as pesquisas relacionadas ao tema deste trabalho, parece não existir uma clara diferenciação entre os modos de transporte apenas pela análise das velocidades e acelerações. Para que possa ocorrer a diferenciação entre todos os modos de viagem, é necessário que outras informações sejam utilizadas, como por exemplo, a representação dos dados de viagens em um SIG. Outro aspecto a ser notado é a diferença dos valores de velocidade e aceleração dos modos de transporte estudados, em relação a outras pesquisas realizadas em diferentes locais. Tal diferença pode ocorrer devido as particularidades dos sistemas de transportes e sistema viário das diversas cidades onde ocorreram estes outros estudos.

5.3 Representação Espacial dos Dados de Viagem em um SIG

A utilização de um SIG possibilita analisar os dados de viagem espacialmente nos sistemas de transportes e viário. Este processo complementa a identificação dos modos de transporte. Desta forma, é possível verificar se em um deslocamento, o usuário passou por vias que continham pontos de parada de ônibus, ou se utilizou uma linha de metrô, trem ou canaleta de ônibus. Foi utilizado um SIG para a geração de mapas temáticos dos dados gerados a partir do protótipo de receptor GNSS. Na Figura 3 tem-se o mapa com os dados georreferenciados de uma viagem por ônibus.

Figura 3: Viagem por modo de ônibus

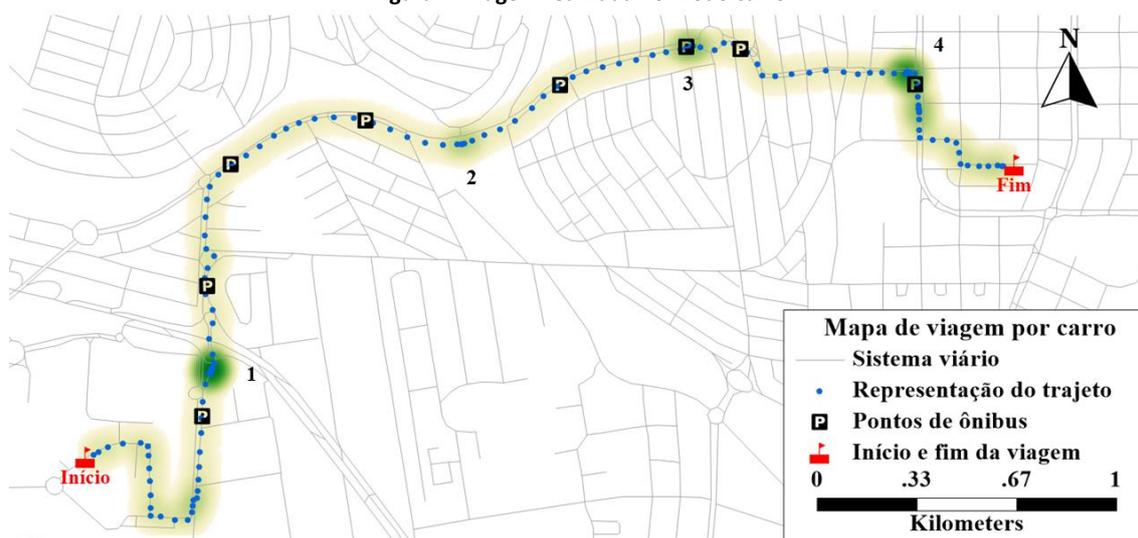


Fonte: Elaborado pelos autores, 2019.

É possível identificar os locais com maiores densidades devido as paradas, os quais podem ser visualizados no mapa por meio dos diferentes tons de verde. Percebe-se que os locais com maior densidade coincidem, na sua maioria, com a localização dos pontos de parada de ônibus, como nas marcações 1, 3, 4, 5, 6, 9 e 10 no mapa. As exceções ficam para as marcações 2 e 8, que constituem-se por interseções congestionadas e 7, que se caracteriza por um ponto de parada no qual, na viagem estudada, o ônibus parou. Nos locais onde as densidades são menores pode-se inferir que representam trechos da viagem sem paradas em pontos de ônibus e/ou trânsito livre.

A viagem realizada por automóvel, ao ser representada espacialmente, diferiu daquela feita por ônibus. O deslocamento realizado por carro também possui locais com alta densidade, o que indica a presença de paradas. No entanto, estas paradas ocorrem em locais diferentes daquelas do ônibus, o que pode ser visualizado na Figura 4 e representadas pelos números 1, 2, 3 e 4. Nos locais demarcado por 1 e 3, existem rotatórias, o que geralmente ocasiona concentração de veículos em suas entradas, fazendo com que as velocidades dos carros sejam reduzidas ou chegue a zero. Consequentemente estes locais são caracterizados por maiores densidades e representados por variações de tons de verde.

Figura 4: Viagem realizada no modo carro



Fonte: Elaborado pelos autores, 2019.

Os locais demarcados por 2 e 4 têm interseções semaforizadas, o que causa eventuais paradas e/ou perdas de velocidade conforme a fase semafórica. Desta maneira, os pontos que representam o trajeto encontram-se mais próximos e geram maiores densidades, representadas por variações de tons de verde. Vale destacar que em 3 e 4, apesar da presença de pontos de parada de ônibus próximos aos locais caracterizados com alta densidade, estes não tiveram relação com as reduções de velocidade e/ou paradas realizadas pelos automóveis.

Por meio do georreferenciamento das viagens realizadas pelos modos carro e ônibus, foi possível analisar as diferentes características espaciais entre eles. No caso dos automóveis os locais de maior densidade se encontram em interseções. Por outro lado, as viagens realizadas por ônibus possuem maiores densidades nos pontos de parada do transporte coletivo. Deste modo, a partir da análise espacial foi possível identificar e diferenciar os modos de transporte carro e ônibus.

6. CONCLUSÕES

O presente estudo permitiu caracterizar diferentes modos de viagens realizadas na área urbana. Foi utilizado um protótipo de receptor GNSS de baixo custo para gerar dados brutos dos deslocamentos. Para o caso específico deste estudo, a utilização do protótipo foi considerada viável, pois os usuários não reportaram dificuldades no uso do dispositivo. A exceção foi a viagem realizada por bicicleta, na qual os dados não foram salvos corretamente no cartão de memória. Além disso, outro inconveniente nos deslocamentos por bicicleta foram os dias chuvosos que impediram a realização do experimento. Cabe ressaltar que o protótipo de receptor GNSS ainda precisa ser aperfeiçoado em questões relacionadas ao seu invólucro e

autonomia da bateria. Estas melhorias tornariam o processo de coleta de dados menos dependente do usuário, o que evitaria perda ou erro na gravação dos dados.

Foi possível diferenciar os quatro modos de transporte estudados por meio dos parâmetros de velocidade e aceleração, bem como pela representação espacial dos dados. A magnitude dos parâmetros de velocidade e aceleração permitiu diferenciar os modos não motorizados dos motorizados. Isto só foi possível devido às diferenças de amplitude das velocidades e acelerações, uma vez que as velocidades médias e máximas dos modos motorizados são consideravelmente maiores que aquelas dos modos não motorizados. Além disso, os deslocamentos feitos por modos não motorizados, a pé e bicicleta, também puderam ser diferenciados pelos mesmos parâmetros. Neste caso o modo bicicleta teve velocidades médias e máximas maiores do que o modo a pé. Os valores de aceleração média e máxima possuíram os mesmos comportamentos que os valores das velocidades média e máxima. Vale ressaltar que as diferenças de magnitude nos dados de velocidade e aceleração entre este estudo e àqueles apresentados na revisão podem ser resultantes das características locais dos sistemas de transporte e circulação viária.

As viagens realizadas por carro e ônibus apresentaram características bem distintas quanto ao comportamento ao longo dos seus respectivos trajetos, conforme a representação espacial. No caso dos ônibus, houve um padrão que relaciona as paradas, na maioria das vezes, aos pontos de ônibus. Já no caso dos automóveis, estas ocorrências se concentraram nas interseções viárias, consideradas como gargalos do sistema de trânsito. O mapeamento dos trajetos tornou possível diferenciar dois modos de transporte motorizados, que no caso de suas acelerações e velocidades, comparadas anteriormente, obtiveram resultados muito semelhantes.

Sendo assim, pesquisas sobre automação da aquisição de dados de viagens podem contribuir ao aperfeiçoamento do planejamento dos sistemas de transporte. A automação do processo de coleta de dados permitiria gerar informações mais precisas em intervalos de tempo menores, a custos mais acessíveis e, conseqüentemente, auxiliar os gestores públicos na tomada de decisões que atendam as demandas da sociedade em relação a transporte e mobilidade.

Agradecimentos

Os autores agradecem à CAPES pelo auxílio na forma de bolsa de mestrado e à Universidade Estadual de Londrina pela infraestrutura disponibilizada para a realização desta pesquisa.

REFERÊNCIAS BIBLIOGRÁFICAS

BACHIR, Danya; KHODABANDELOU, Ghazaleh; GAUTHIER, Vincent; EI YACOUBI, Mounim; PUCHINGER, Jakob. Inferring dynamic origin-Destination Flows by Transport Mode Using Mobile Phone Data. *Transport ResearchPart C*, v. 101. p. 254-275, 2019.

BOLBOL Adel; CHENG, Tao; TSAPAKIS, Ioannis; HAWORTH, James. Inferring Hybrid Transportation Modes From Sparse GPS Data Using a Moving Window SVM Classification. *Computer, Environment and Urban Systems*, v. 36, p.

526-537, 2012.

CALIPER. **What is a Density Grid?** Disponível em: <https://www.caliper.com/glossary/what-is-a-density-grid.htm>. Acesso em 03 de Jul. de 2019.

CAMPOS, Vânia. B. G. **Planejamento de Transportes – Conceitos e Modelos**. 1ª ed. Rio de Janeiro. Editora Interciência, 2013.

DABIRI, Sina; HEASLIP, Kevin. Inferring Transportation Modes from GPS Trajectories Using a Convolutional Neural Network. **Transportation Research Part C**, v. 86, p. 360-371, 2018.

GONG, Lei; MORIKAWA, Takayuki; YAMAMOT, Toshiyuki; SATO, Hitomi. Deriving Personal Trip Data from GPS Data: a literature review from the existing methodologies. **Procedia – Social and Behavioral Sciences**, v. 138, p. 557-565, 2014.

IBGE (2010) **Dados do Censo 2010**. Disponível em: <http://censo2010.ibge.gov.br/>. Acesso em 24 de maio de 2019.

KIHARA, Lorena M.; FONTENELE, Heliana B.; SILVA JÚNIOR, Carlos Alberto P. Automação do processo de mapeamento de rotas de ciclistas: testes com um GPS Arduino. **Simpósio de Engenharia, Gestão e Inovação**. Águas de Lindoia/SP, 2019.

LARANJEIRO, Patrícia F.; MERCHÁN, Daniel; GODOY, Leonardo A.; GIANNOTTI, Mariana; YOSHIZAKY, Hugo T. Y.; WINKENBACH, Mathias; CUNHA, Cláudio B. Using GPS data to explore speed patterns and Temporal Fluctuations in Urban Logistics: the case of São Paulo, Brazil. **Journal of Transport Geography**, v. 76. p. 114-129.

MONTINI, Lara; PROST, Sebastian; SCHRAMMEL, Johann; RIESER-SCHUSSLER, Nadine; AXHAUSEN, Kay W. Comparison of Travel Diaries Generated from Smartphone Data and Dedicated GPS Devices. **Transportation Research Procedia**, v. 11, p. 227-241, 2015.

ONU. Department of Economic and Social Affairs/population division. In: **World Urbanization Prospects: The 2018 Revision**. 2018.

PRELIPCEAN, Adrian C.; SUSILO, Yusak O.; GIDÓFALVI, Gyoza. Collecting Travel Diaries: current state of the art, best practices, and future research directions. **Transportation Research Procedia**. v. 32. p. 155-166, 2018.

SHAFIQUE, Muhammad Awais; HATO, Eiji. Travel Mode Detection With Varying Smartphone Data Collection Frequencies. **Sensors**, v. 16, p. 716., 2016

SILA-NOWICKA, Katarzyna; FOTHERINGHAM, A. Stewart. Calibrating Spatial Interaction Models from GPS Tracking Data: an example of retail behavior. **Computers, Environment and Urban Systems**, v. 74, p. 136-150, 2019.

STOPHER, Peter R.; DAIGLER Vivian; GRIFFITH, Sarah. Smartphone App Versus GPS Logger: a comparative study. **Transportation Research Procedia**, v. 32, p.135-145, 2018.

XIAO, Guangnian; JUAN, Zhicai; GAO, Jingxin. Travel Mode Detection Based on Neural Networks and Particle Swarm Optimization. **Information**, v. 6, p. 522-535, 2015.

XIAO, Zhibin; WANG, Yang; FU, Kun; WU, Fan. Identifying different transportation modes from trajectory data using tree-based ensemble classifiers. **International Journal of Geo-Information**. v. 6. p.57-79, 2017.

ZONG, Fang; TIAN, Yongda; HE, Yanan; TANG, Jinjun; LV, Jiannyu. Trip Destination Prediction Based on Multi-day GPS Data. **Physica A**, v. 515, p. 258-269, 2019.