



Anápolis, GO – Agosto de 2018

TÉCNICAS PARA DETECÇÃO DE ANOMALIAS EM PADRÕES DE SÉRIES ESPAÇOTEMPORAIS: UMA REVISÃO SISTEMÁTICA DE LITERATURA

LEANDRO PEDROSA¹

RESUMO

Justificativa: O uso de técnicas para detecção de anomalias e seus impactos é um dos fatores determinantes para a avaliação das condições de tráfego urbano. **Objetivo:** Investigar técnicas para detecção de padrões e anomalias em séries espaçotemporais. **Método:** Uma revisão sistemática foi realizada, a partir dos achados em uma base de dados científica (*Scopus*). Utilizou-se uma *string* de busca e, em seguida, a leitura e aplicação dos critérios de inclusão e exclusão para seleção dos estudos primários. **Resultados:** Trinta e dois artigos foram recuperados, sendo que destes, somente doze foram incluídos nesta revisão (38%). Esses diferentes estudos possuem alguns aspectos em comum. O principal é a necessidade de seleção inicial / preparação dos dados a serem coletados e analisados. Esta é uma etapa primordial para determinação dos padrões e anomalias no tráfego de veículos. Diferentes técnicas para identificação de anomalias foram analisadas, sendo as mais predominantes o cálculo da distância euclidiana e o uso de uma arquitetura orientada a serviços e a eventos. Essas técnicas demonstraram ser eficientes no fornecimento de fluxos de tráfego que causam anomalias. **Conclusão:** O uso dessas técnicas é essencial para a coleta de informações necessárias para o processo de tomada de decisão, em busca da melhoria da qualidade e mobilidade urbana.

PALAVRAS-CHAVE: Detecção de anomalias no tráfego; Detecção de padrões; Rede de ônibus; Avaliação do impacto em tráfego de veículos.

ABSTRACT

Justification: The use of techniques to detect anomalies and their impacts is one of the determining factors for the evaluation of urban traffic conditions. **Objective:** To investigate techniques for detecting patterns and anomalies in space-time series. **Method:** A systematic review was conducted based on the findings in a scientific database (*Scopus*). A search string was used and then the inclusion and exclusion criteria were applied for the selection of the primary studies. **Results:** Thirty-two papers were retrieved, of which only twelve were included in this review (38%). These different studies have some aspects in common. The main one is the need for initial selection / preparation of the data to be collected and analyzed. This is a key step in determining vehicle traffic patterns and anomalies. Different techniques for identifying anomalies were analyzed, the most prevalent being the calculation of the Euclidean distance and the use of a service and event oriented architecture. These techniques have proven to be efficient in providing traffic flows that cause malfunctions. **Conclusion:** The use of these techniques is essential for the collection of information necessary for the decision-making process, in order to improve quality and urban mobility.

KEY WORDS: Detection of Traffic Anomalies; Detection of patterns; Bus Network; Impact assessment in vehicle traffic.

¹ Estudante de Mestrado – Programa de Pós-Graduação em Sistemas de Informação. Universidade de São Paulo (USP) – São Paulo – SP – Brasil, leandropedrosalp@usp.br



INTRODUÇÃO

Grande parte da população, em sua rotina diária, faz uso de transportes públicos. Dentre eles, as redes de ônibus estão entre os mais populares. A implementação dessas redes deve ser feita de forma eficiente, devido sua forte dependência com as condições do trânsito. O desperdício de tempo, ocasionado por um mau planejamento de rotas, pode impactar diretamente na qualidade e condições de vida de uma grande parte da população (DUAN et al., 2010).

Neste quesito, os órgãos municipais responsáveis por monitorar o trânsito revisam, continuamente, as políticas de transporte e a rede rodoviária, visando melhorar as condições do trânsito, reduzindo o tempo de viagem, evitando congestionamentos no tráfego e reduzindo os conflitos entre as redes de ônibus e outros meios de transporte (LINDAU, 2014).

Com o intuito de melhorar as condições de trânsito, estratégias são aplicadas visando ampliar o conforto dos passageiros e a qualidade do serviço de transporte público prestado. Neste caso, avaliar as estratégias adotadas é determinar a eficácia do planejamento nas ações alternativas para mitigar os problemas de tráfego nas rotas de trânsito. Dentre os problemas, identificar as condições normais do trânsito e eventos que alteram estas condições, fazem parte de um processo de monitoramento e avaliação constantes, onde as autoridades municipais revisam continuamente suas estratégias (CARRIGAN et al., 2013).

Mesmo com a implementação de Sistemas de Gerenciamento de Tráfego (TMS) inteligentes, para a adoção de estratégias para o planejamento de tráfego, a maioria das grandes cidades do mundo sofre com o congestionamento. Apesar de existirem mecanismos avançados de controle, ainda demonstra-se necessário compreender os seus diferentes tipos e impactos, sejam eles recorrentes ou não recorrentes (DJAHEL et al., 2014).

Atualmente, os TMS existentes não fornecem informações de trânsito rodoviário precisas e suficientes para permitir o monitoramento e gerenciamento detalhados e oportunos da rede de tráfego rodoviário. Alguns dos motivos incluem: falta de coleta de dados granulares, incapacidade de agregação significativa de grande parte dos dados coletados e a falta de sistemas de gerenciamento complexos, capazes de fornecer visões precisas. Essa incapacidade de monitorar e gerenciar o tráfego efetivamente mantém alto o congestionamento do mesmo (DJAHEL et al., 2014).

A medida que esses dados são coletados, novas estratégias podem ser tomadas a partir do conhecimento adquirido, propondo diversas ações de melhoria ou a implementação de rotas ótimas para os veículos, previsões de tráfego de curto prazo e várias outras estatísticas de tráfego rodoviário (CARRIGAN et al., 2013; DJAHEL et al., 2014).

A identificação de parâmetros de tráfego e a detecção de eventos não casuais podem auxiliar no monitoramento do trânsito. Isso será possível a partir da análise de dados históricos posicionais, agrupando estes dados por período de tempo. Assim, para cada período encontrado, deve-se obter a velocidade e o tempo médio das viagens naquela rota, correlacionando com a localização em tempo real do ônibus, via GPS, e os valores médios identificados. Isso proporcionará uma maior detecção de eventos que podem representar incidentes aleatórios, além de validar em tempo real as estratégias de melhoria adotadas por órgãos responsáveis pelo tráfego rodoviário (LLANES et al., 2017).

Assim, o objetivo do presente estudo foi investigar técnicas para detecção de padrões e anomalias em séries espaçotemporais. A ênfase foi identificar as técnicas que fazem uso de dados históricos, obtidos via GPS (Sistema de Posicionamento Global), além de conhecer as técnicas adotadas para encontrar anomalias nesses padrões e as referidas ferramentas estatísticas usadas para avaliação do impacto em tráfego de veículos.



FUNDAMENTOS TEÓRICOS

Esta seção apresenta os conceitos essenciais relacionados ao transporte inteligente.

Conceitos básicos

A seguir, são apresentados os principais conceitos relacionados ao monitoramento inteligente de tráfego de veículos (Figura 1):

- Séries espaçotemporais: são definidas como sequências de observações de objetos que contém dados sobre o local e momento em que as coletas foram realizadas (CRESSIE et al., 2015).
- Objetos permanentes e móveis: Os objetos com localização fixa são classificados como permanentes (interpretados como sensores fixos), enquanto aqueles cujas localizações variam com o tempo são classificados como móveis (interpretados como trajetórias) (CRESSIE et al., 2015).
- AVL (*Automatic Vehicle Location*): Sistema de localização dos ônibus por GPS. Registra periodicamente a posição do ônibus e envia este dado a um servidor remoto; Aresta: Representa o caminho entre dois pontos de paradas consecutivos (ARIZONA, 2004).
- GTFS (*General Transit Feed Specification*): Formato de dados que permite a especificação de uma rede de transportes de uma cidade, com suas linhas e partidas planejadas (GOOGLE, 2018).
- Intervalo: Tempo, em minutos, entre duas partidas de ônibus consecutivas de uma determinada linha dentro de uma janela horária. O intervalo pode mudar dependendo da janela;
- Linha: Uma trajetória de ida ou volta planejadas na rede de transportes; Parada: Um ponto de ônibus;
- Segmento: O trajeto formado pela conexão de dois pontos geolocalizados consecutivos (*shapes*).
- Shape: Ponto geolocalizado que define o vértice de um dos segmentos que formam o trajeto de uma linha considerando-se a geometria das vias por onde trafegam os ônibus. Conectando-se os *shapes* consecutivos é possível obter o trajeto completo da linha no viário da cidade.
- Rota: Informações equivalente a linha de ida e a sua respectiva volta; Terminal Primário (TP): Local de partida dos ônibus no sentido de ida de uma linha;
- Viagem: O ato ou movimento de percorrer o trajeto da linha;
- Terminal Primário (TP): Local de partida dos ônibus no sentido de ida de uma linha;
- Terminal Secundário (TS): Local de partida dos ônibus no sentido de volta de uma linha;
- Trajetória: Sequência de pontos, a partir de um TP ou um TS, em ordem crescente de distância do ponto inicial, com destino ao TS ou TP correspondente. Se o sentido da viagem é TP → TS ela é chamada de trajetória de ida, ou trajetória de volta caso o sentido seja TS → TP.




Figura 1. Visualização dos conceitos presentes na nomenclatura. Fonte: (YAI, 2015).



Smart Cities

Uma abordagem recentemente promissora para lidar com monitoramento inteligente de tráfego urbano é o conceito de cidades inteligentes (*Smart Cities*), especialmente sobre a mobilidade inteligente. A principal ideia do conceito de cidades inteligentes é o uso de tecnologias de informação e comunicação (TIC) para melhorar os serviços da cidade, especialmente os serviços de transportes públicos.

Existem algumas experiências *Smart Cities* em todo o mundo, com iniciativas em diferentes domínios. Uma delas está relacionada às ações de monitoramento do tempo em fluxo nas vias da cidade (CARRIGAN et al., 2013), cujo objetivo é construir sistemas inteligentes de transporte público com base em informações, em tempo real. Outro exemplo são os Sistemas de Gerenciamento de Tráfego (TMS) para evitar o congestionamento, segurança e aplicações verdes (por exemplo, para reduzir o consumo de combustível, emissões de gases ou consumo de energia) (DJAHEL et al., 2014). A detecção de eventos não casuais e seus impactos em padrões de trânsito de redes de ônibus é essencial para determinar a eficácia das estratégias para melhoria de tempo e velocidade de rotas, além da identificação de possíveis gargalos. Para isto, a adoção do conceito de cidades inteligentes, para criar um TMS inteligente, é de suma importância para a detecção de anomalias em tempo real, a partir de padrões identificados de dados históricos posicionais de GPS nos ônibus.

Anomalias de trânsito

Anomalias de trânsito significam alterações no fluxo de tráfego dos veículos, podendo ser significativas ou não. Elas podem surgir a partir da ocorrência de eventos, tais como: obras nas vias, acidentes de trânsito rodoviário, alterações do clima, provocando enchentes, quedas de árvores, dentre outros.

A existência de anomalias em um tráfego pode ocasionar altos níveis de congestionamento, o que pode resultar em um desperdício considerável de tempo por parte de um grande número de cidadãos, aumentar a poluição do ar e prejudicar segurança (LLANES et al., 2017).

A detecção de tais anomalias se faz necessário para avaliação da eficácia das medidas adotadas pelos órgãos competentes, na definição de melhores estratégias de rotas para o transporte público.

MÉTODO

O presente estudo trata-se de uma revisão sistemática de literatura relacionada à investigação de técnicas para detecção de anomalias e padrões em dados históricos de rotas de ônibus, visando a identificação de impactos e reflexos de tempo e velocidade. Os passos dessa revisão foram os seguintes:

Formulação da pergunta de pesquisa

Quais as técnicas têm sido utilizadas para identificação de padrões e anomalias em séries espacotemporais para avaliação de impactos de tempo e velocidade de viagens das rotas de veículos?
População:

- Tráfego de veículos com dados históricos georreferenciados (GPS)
- Exemplos: Dados históricos de tráfego de veículos (ônibus, aviões, dentre outros)

Intervenção:

- Estratégias para detecção de padrões e anomalias

Controle:

- Artigos sobre o tema identificados, previamente, com o orientador. Exemplos:



- (2016) Shi, A.; Weiming, K. *Prediction of Urban Traffic Abnormity Based on Causal Network. 6th International Conference on Intelligent Systems Design and Engineering Applications, ISDEA.*
- (2015) Kuang, W.; An, S.; Jiang, H. *Detecting Traffic Anomalies in Urban Areas Using Taxi GPS Data. Mathematical Problems in Engineering.*

Resultados:

- Identificar os impactos das anomalias em padrões de rotas de veículos.

Aplicação:

- Identificar estratégias para melhor avaliação das condições de tráfego de veículos.

Critérios de seleção de fontes

Métodos de busca de fontes: O acesso aos artigos foi realizado por meio do domínio da Universidade de São Paulo. A base de dados *Scopus*, disponível em <https://www.scopus.com/>, foi consultada. Uma *string* de busca foi elaborada e aplicada para identificação dos artigos retornados. Em seguida, foi realizada a leitura e aplicação dos critérios estabelecidos, justificando as possíveis exclusões (Tabela 1).

Tabela 1. Seleção dos estudos primários

Base de dados	Estudos retornados	Após os critérios de inclusão	Após os critérios de exclusão (artigos incluídos)
<i>Scopus</i>	32	30	12

Fonte: O autor.

Palavras-chave

- Em português: Detecção de anomalias no tráfego; Detecção de padrões; Rede de ônibus; Avaliação do impacto em tráfego de veículos.
- Em inglês: *Detection of Traffic Anomalies; Detection of patterns; Bus Network; Impact assessment in vehicle traffic.*

Listagem de fontes

População (P): Rotas de veículos com dados históricos obtidos de GPS

- *Population (P): Routes of vehicles with historical data obtained from GPS*

Intervenção (I): Detecção de padrões e anomalias

- *Intervention (I): Detect patterns and outliers*

Resultados (O): Impactos das anomalias nos padrões de rotas de veículos

- *Outcomes (O): Impacts of outliers in vehicle route patterns*

A *string* de busca a *Scopus* foi assim agrupada (P <and> I <and> O):

- *(TITLE-ABS-KEY((route OR traffic OR transit OR path) AND ("GPS data")) AND*
- *(TITLE-ABS-KEY(detection OR recognition OR determination OR identification) AND (patterns OR anomalies)) AND*
- *(TITLE-ABS-KEY((estimation OR analysis OR evaluation) AND (impact or repercussion OR result OR influence OR consequence OR effect)))*

Idiomas dos artigos

Foram aceitos artigos publicados nos idiomas Inglês e Português.

Critérios de inclusão e exclusão dos artigos



Critérios de inclusão:

- Artigos completos que demonstram as técnicas para detecção de padrões ou anomalias em tráfego de veículos.
- Artigos escritos no idioma inglês ou português.

Critérios de exclusão:

- Artigos que não apresentam os impactos das anomalias em tráfego de veículos.
- Artigos em que o seu texto completo não esteja disponível para leitura ou download (versão completa).
- Estudos do tipo resumos, cursos, tutoriais, *workshops* e afins.
- Artigos com mais de dez anos de publicação (2007-2017).
- Artigos escritos em outro idioma, além do inglês ou português.

Critérios de qualidade dos estudos primários

- Trabalho teórico ou prático, o qual descreve técnicas para detecção de padrões em dados históricos em rotas de veículos, assim como as técnicas para identificação de anomalias nestes padrões.
- Artigos que contenham dados históricos de rotas de veículos, conduzidos por profissionais ou estudantes da área de computação.

Processo de seleção dos estudos primários

As etapas do processo para seleção dos artigos foram:

- Definição da *string* de busca específica para a base de dados *Scopus*;
- Aplicação da *string* no site de busca da base de dados adotada;
- Leitura do título, resumo, introdução e conclusão de cada artigo do resultado da busca para inclusão ou exclusão do mesmo, a partir dos critérios definidos;
- Se houver dúvidas quanto a inclusão ou exclusão, o orientador será consultado.

Avaliação da qualidade dos estudos primários

- Resultados de pesquisas científicas, publicadas em revistas com qualis acima de B3;
- Atinja algum dos critérios de inclusão;
- Se um artigo não contemplar um critério de inclusão ou nenhum de exclusão, o orientador será consultado;
- Caso algum artigo atinja um critério de inclusão e um de exclusão, o orientador será consultado.

Estratégia de extração de informação

Todos os artigos incluídos, a partir das análises dos critérios de inclusão e exclusão, foram lidos integralmente. Um resumo foi realizado a partir das leituras, destacando as técnicas para detecção de padrão e anomalias em rotas de veículos.

Sumarização dos resultados

A síntese dos resultados faz uma avaliação descritiva das técnicas encontradas para detecção de padrões e anomalias.

RESULTADOS



No período entre os dias 26 à 31 de outubro de 2017 foram realizadas consultas na bases de dados *Scopus*. Ao total, 32 artigos foram recuperados. Destes, somente 12 foram incluídos nesta revisão (38% dos resultados recuperados), sendo que 2 foram publicados em 2017, 6 em 2016, 3 em 2015 e 1 em 2011.

Os principais fatores que levaram à exclusão dos estudos foram: (1) não apresentam as técnicas e/ou impactos provocados pelas anomalias em tráfego de veículos; artigos publicados em idiomas não considerados e o download do texto completo do artigo não foi encontrado, mesmo utilizando a rede institucional da USP.

O resultado da análise dos estudos incluídos nesta revisão sistemática foi organizado em dois subtópicos: (a) detecção de padrões e anomalias e (b) avaliação do impacto provocados por tais anomalias. O Quadro 1 contempla a descrição das técnicas utilizadas para a detecção de padrões e anomalias nos estudos analisados.

Quadro 1. Extração dos dados dos estudos incluídos

Artigo	Técnica para detecção de padrão	Técnica para detecção de anomalia
Artigo 1 (GOKASAR; CETINEL, 2017)	As distâncias euclidianas (1) entre os padrões de parada de ônibus são calculadas para cada momento. Os padrões são agrupados usando o máximo das distâncias calculadas (2). $\ a - b\ _2 = \sqrt{\sum_i (a_i - b_i)^2} \quad (1)$ $\max \{d(a, b) : a \in A, b \in B\}. \quad (2)$	As paradas de ônibus são selecionadas como <i>outliers</i> quando seu tempo de permanência é superior a um minuto a qualquer momento.
Artigo 2 (D'ANDREA; MARCELLONI, 2017)	Algoritmo de roteamento adaptado do algoritmo <i>GraphHopper Route Planner</i> (GRAPH HOPPER, 2018) Algoritmo clássico de Dijkstra Arquitetura orientada a serviços e orientada para eventos	A escolha dos possíveis estados de tráfego foi realizada de acordo com a classificação empregada em conhecidos sistemas de informação de trânsito, como o <i>Google Traffic</i> e " <i>Autostrade per l'Italia</i> ", a principal rede de notícias de trânsito na Itália.
Artigo 3 (TANG et al., 2016)	Distribuição de grau e força Método de Louvain e método de visualização de semelhanças (VOS)	Índice Rand e o índice Fowlkes-Mallows
Artigo 4 (SHI; WEIMING, 2015)	Modelo de Previsão de Condição do Tráfego de Curto Prazo	Modelo de Previsão Temporal
Artigo 5 (YU et al., 2016)	Modelo de previsão de condição do tráfego de curto prazo	Modelo clusterizado k-NN
Artigo 6 (D'ANDREA; MARCELLONI, 2016)	Arquitetura de Sistemas para detecção de incidentes	Classificação do Tráfego de Segmentação
Artigo 7 (ZENG, 2015)	Processo de análise proposto	Processo de análise proposto
Artigo 8 (ZHOU, 2016)	Algoritmo de detecção online Algoritmo de recomendação de rota	Método de detecção de trajetória anômala online, denominado <i>OnATrade</i>
Artigo 9 (WEIMING et al., 2015)	Método do gráfico de controle <i>Shewhart</i> e do método do gráfico de controle EWMA	Processo de detecção de anomalia de trânsito
Artigo 10 (NECULA, 2015)	Algoritmo de clusterização	Algoritmo APRIORI
Artigo 11 (SHEN, 2015)	Distância euclidiana	Segmentação do status do trânsito
Artigo 12 (BAZZANI, 2011)	Algoritmos para reconstrução da rota	Distribuição estatística para o erro de posição e direção para o georreferenciamento dos dados

Fonte: O autor.

Detecção de padrões e anomalias



As técnicas para detecção de padrões, encontradas nos estudos analisados, foram: o cálculo de distâncias euclidianas para determinação do local dos ônibus (GOKASAR; CETINEL, 2017; SHEN et al., 2015), algoritmo de roteamento e o algoritmo clássico de Dijkstra (D'ANDREA; MARCELLONI, 2017), método de Louvain e o método de visualização de semelhanças (TANG et al., 2016), modelo de previsão de condição do tráfego de curto prazo (YU et al., 2016).

A análise dos estudos incluídos nesta revisão sistemática permitiu identificar modelos de arquiteturas e técnicas utilizadas para detectar congestionamento no tráfego de veículos. Os estudos propõem o uso de uma arquitetura orientada a serviços e orientada para eventos (D'ANDREA; MARCELLONI, 2017), um processo para análise e detecção de pontos anormais (Figura 2) (ZENG et al., 2016), uma arquitetura de Sistemas para detecção de anomalias (Figura 3) (D'ANDREA; MARCELLONI, 2016), um método para detecção online de anomalias (Figura 4) (ZHOU et al., 2016), um modelo para detectar anomalias de tráfego de rede (Figura 5), um processo para detecção de anomalias de trânsito (Figura 6) e, por último, um método para segmentação de status do tráfego (Figura 7).

Esses diferentes estudos possuem alguns aspectos em comum. O principal é a necessidade de seleção inicial / preparação dos dados a serem coletados e analisados. Esta é uma etapa primordial para determinação dos padrões e anomalias no tráfego de veículos.

Após a seleção dos dados, torna-se possível realizar o agrupamentos dos mesmos, por meio de gráficos que facilitam a identificação de anomalias e o local onde as mesmas ocorrem. Essa análise é um fator chave para melhoria da eficiência nas redes de tráfego de veículos, pois os níveis de anomalia de trânsito podem ser graves devido à propagação do fluxo de tráfego (WEIMING et al., 2015).

No modelo de arquitetura proposto por (D'ANDREA; MARCELLONI, 2017) são utilizadas técnicas para o Pré-processamento:

- Algoritmo de roteamento, adaptado de *Graph Hopper Route Planner* (GRAPH HOPPER, 2018), necessário para reconstruir o caminho que falta entre os segmentos anterior e atual.
- Algoritmo clássico de Dijkstra, que gera o melhor caminho aproximado entre dois segmentos não adjacentes, dando prioridade às ruas principais no mapa e escolhendo o caminho mais curto para planejamento de rotas.

Além destas, também são utilizadas as técnicas para o Classificação do Tráfego de Segmentos:

- A escolha dos possíveis estados de tráfego foi realizada de acordo com a classificação empregada em conhecidos sistemas de informação de trânsito, como o *Google Traffic* e *Autostrade per l'Italia*, a principal rede de notícias de trânsito na Itália.
- Foram criadas regras próprias no caso de um número insuficiente de veículos que passam no segmento.

O método proposto na Figura 2 detecta pontos anormais em tempo real e o resultado da análise pode ser útil no planejamento da rota e na gestão do tráfego. Para tanto, propõe-se um fator de congestionamento em tempo real (RRCF) da região para detectar os pontos anormais (AHSP) em tempo real. Para demonstrar o RRCF são apresentadas várias definições inovadoras, e uma maneira específica de medir a velocidade média de alguma região (ZENG et al., 2016).




Figura 2 - Processo para análise e detecção de pontos anormais. Fonte: (ZENG et al., 2016)



Na Figura 3 é apresentado um sistema para detectar incidentes que causam congestionamento de tráfego na rede rodoviária através da análise de dados GPS em tempo real. Esses dados são coletados dos dispositivos de rastreamento instalados nos veículos ou dos *smartphones* dos motoristas. Depois de posicionar as coordenadas GPS no roteiro, o sistema atribui um estado de trânsito a cada segmento rodoviário com base nas velocidades dos veículos e gera alertas por incidente com base em uma análise espaçotemporal desses estados (D'ANDREA; MARCELLONI, 2016). Após a coleta, esses dados são segmentados, classificados e os devidos alertas são emitidos.

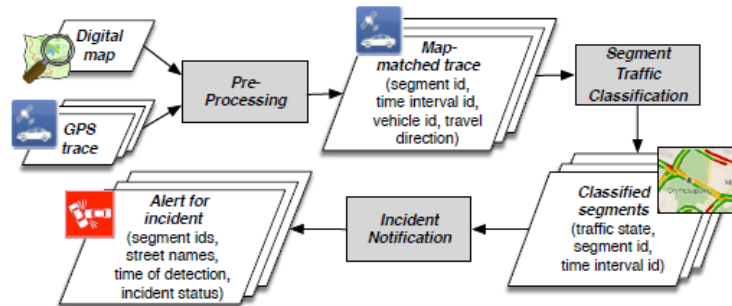


Figura 3 – Sistemas para detecção de anomalias. Fonte: (D'ANDREA; MARCELLONI, 2016).

Na Figura 4 é apresentado um método de detecção de trajetória anômala online, denominado *OnATrade*, o qual visa melhorar os serviços de táxi usando dados do GPS. O método consiste principalmente em duas etapas: recomendação de rota e detecção online (ZHOU et al., 2016).

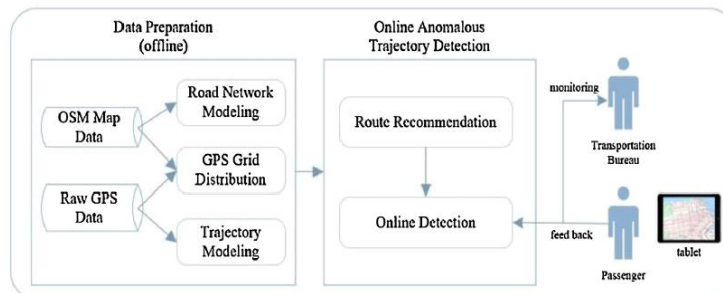


Figura 4 - Método para detecção online de anomalias. Fonte: online (ZHOU et al., 2016).

Anomalias de trânsito existem amplamente nas redes de tráfego urbano e afetam negativamente a eficiência do tráfego, tempo de viagem e poluição do ar (BAZZANI et al., 2011; NECULA, 2015; SHI; WEIMING, 2015). Considerando este cenário, os autores (WEIMING et al., 2015) propuseram um modelo de rede rodoviária utilizado para detectar anomalias de tráfego de rede (Figura 5).

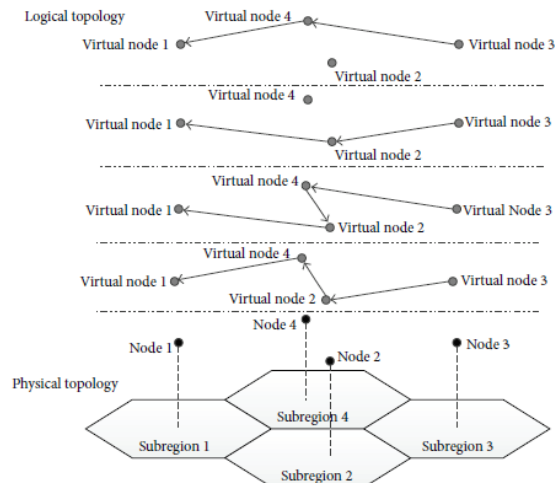


Figura 5 - Modelo de rede rodoviária usado para detectar anomalias de tráfego. Fonte: (WEIMING et al., 2015).

Esse modelo tem como base um processo para detecção de anomalias de trânsito (Figura 6), muito similar aos demais analisados, pois o mesmo utiliza, como fonte de dados, os GPS's instalados nos veículos para coletar os dados, fazer a análise, segmentação e agrupamento dos mesmos (ZENG et al., 2016; (D'ANDREA; MARCELLONI, 2016; 2017).




Figura 6 – Processo de detecção de anomalia de trânsito. Fonte: (WEIMING et al., 2015).

Um aspecto importante a ser ressaltado é a necessidade de considerar que o tempo para detectar um incidente depende fortemente da condição de tráfego atual e da distância média entre a localização do incidente e o ponto de partida das rotas dos veículos (NECULA, 2015; D'ANDREA; MARCELLONI, 2016).

Um método que apresentou alta precisão foi proposto por (SHEN et al., 2015). Os autores analisaram dados de posição da área de GPS de Pequim, extraíndo as viagens de posição, obtendo os segmentos e os pontos de segmento, com base na distância euclidiana para medida de similaridade e no intervalo de tempo (Figura 7).

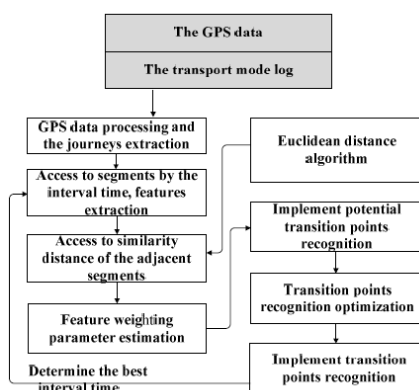




Figura 7 – Método para segmentação de status de viagem de tráfego. Fonte: (SHEN et al., 2015).

Esse método possui como fases (SHEN et al., 2015):

- Extrair viagens;
- Segmentar a trajetória de posição pelo tempo de intervalo T, obtendo os segmentos e os pontos de segmento;
- Extrair os recursos usados para medida de similaridade com base na distância euclidiana, adquirindo a distância métrica;
- Identificar os possíveis pontos de transição pelos algoritmos de distância máxima;
- Definir métricas e correção sobre os pontos de transição potenciais;
- Reconhecer os pontos de transição.

Analisando impactos provocados pelas anomalias

Foram identificados nos estudos analisados que, mediante a ocorrência de anomalia nos padrões de uma determinada via, são possíveis os seguintes cenários:

- O trânsito é normalmente congestionado, de modo que a redução de velocidade não é percebida (WEIMING et al., 2015);
- O trânsito reflete a redução de capacidade da via pela redução de velocidade (SHEN et al., 2015);
- Havendo indícios de congestionamento, os motoristas optam por vias alternativas (ZHOU et al., 2016), minimizando a influência do acidente principalmente em locais mais afastados.

Nota-se, portanto, que em alguns estudos de casos, as velocidades apresentam pequenas variações tanto antes quanto depois da ocorrência do fato. Para detectar se o valor de velocidade observado é considerado normal, propõe-se empregar um indicador baseado na probabilidade de observar valores inferiores a ele, observados no mesmo dia da semana e no mesmo intervalo. Esse indicador, doravante chamado de frequências relativas cumulativas (FRC), é numericamente igual à soma das frequências relativas (D'ANDREA; MARCELLONI, 2016), nas faixas de velocidade inferiores. Com isso, baixos valores de velocidade poderão ser identificados como normais ao invés de ser classificado como reflexos do acidente.

O tempo estimado de recuperação de trânsito também foi demonstrado por (ZENG et al., 2016), onde foram utilizados dois valores que poderiam ilustrar a ocorrência do acidente e estimar o tempo de recuperação. Os autores acreditam que o método proposto realmente detecta pontos anormais em tempo real.

Alguns autores demonstraram que, uma vez mapeadas as características de parada de ônibus torna-se possível identificar anomalias que afetam os tempos de parada (GOKASAR; CETINEL, 2017). Isso pode ajudar os governantes a localizarem uma nova parada de ônibus em processo de planejamento de rotas. Para evitar os longos períodos de habitação de um ponto de ônibus, ele pode ser deslocado para uma área com características semelhantes de paradas de ônibus com padrões de habitação normais.

CONCLUSÃO

Uma das funções mais críticas de um sistema de transporte inteligente é fornecer uma previsão precisa e em tempo real das condições de trânsito, visando a implementação de políticas para melhoria da qualidade e mobilidade urbana.

Para tanto, a identificação de padrões e as respectivas anomalias presentes se faz necessário para o planejamento da rota e para a gestão do tráfego, pois é sabido que tais anomalias existem e afetam,



negativamente, a eficiência do trânsito, gerando impactos de tempo e reduzindo a satisfação e qualidade de vida da população.

Dentre as técnicas analisadas nos estudos incluídos nessa revisão, o cálculo da distância euclidiana e o uso de uma arquitetura orientada a serviços e a eventos foram os mais predominantes. Verifica-se, portanto, a necessidade de identificação do conjunto de dados para calcular a distância entre os pontos e, assim, identificar pontos de anormalidade.

Essas atividades são essenciais para avaliação do impacto provocado por esses eventos, sendo possível fornecer informações de efetividade para que os gerentes solucionem o engarrafamento ou os problemas de resposta de emergência.

REFERÊNCIAS

- ARIZONA. One definition of AVL exists in, "Glossary," Arizona Phase II Final Report: Statewide Radio Interoperability Needs Assessment, Macro Corporation and The State of Arizona, 2004, p. 165.
- BAZZANI, A. et al. Towards congestion detection in transportation networks using GPS data. In: IEEE Third Int'l Conference on Privacy, Security, Risk and Trust and 2011 IEEE Third Int'l Conference on Social Computing, p. 1455-1459, 2011.
- CARRIGAN, A. et al. Social, environmental and economic impacts of BRT systems. Bus Rapid Transit Case Studies from Around the World, p. 151, 2013.
- D'ANDREA, E.; MARCELLONI, F. Detection of traffic congestion and incidents from GPS trace analysis. Expert Systems with Applications, v. 73, p. 43-56, 2017.
- D'ANDREA, E.; MARCELLONI, F. Incident Detection by Spatiotemporal Analysis of GPS Data. In: 2016 IEEE International Conference on Smart Computing, St. Louis, MO, p. 1-5, 2016.
- DJAHEL, S.; DOOLAN, R.; MUNTEAN, G.; MURPHY, J. A communications-oriented perspective on traffic management systems for smart cities: Challenges and innovative approaches. Communications Surveys Tutorials, IEEE, v. 99, p. 125-151, 2014.
- DUAN, Y.; LU, F.; OUYANG, F.; CHEN, C. Enhancing travel time forecasting with traffic condition detection. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. 38, p. 355-360, 2010.
- GOKASAR, I.; CETINEL, Y. Evaluation of bus dwelling patterns using bus GPS data. In: 5th IEEE International Conference on Models and Technologies for Intelligent Transportation Systems, p. 867-871, 2017.
- GOOGLE. Google Developers, 2017. O que é GTFS? Disponível em <https://developers.google.com/transit/gtfs/?hl=pt-br>. Acesso em: 02 abr. 2018.
- GRAPH HOPPER. The GraphHopper Directions API Route Planning For Your Application, 2018. Disponível em: <www.graphhopper.com>. Acesso em: 02 abr. 2018.
- LINDAU, L.A. et al. BRT and bus priority corridors: Scenario in the American continent. In: Transportation Research Board 93rd Annual Meeting, 2014.
- LLANES, K. R.; CASANOVA, M. A.; LOPES, H.; MACEDO, J. A. F. An Approach to Evaluate the Impact on Travel Time of Bus Network Changes. In: 19th International Conference on Enterprise Information Systems, p. 23-32, 2017.
- CRESSIE, N.; WIKLE, C. K. Statistics for Spatio-Temporal Data. John Wiley & Sons, ISBN-10: 0471692743, 2015.



- NECULA, E. Analyzing traffic patterns on street segments based on GPS data using R. *Transportation Research Procedia*, v. 10, 2015.
- SHEN, Y. et al. A Method of Traffic Travel Status Segmentation Based on Position Trajectories. In *IEEE Conference on Intelligent Transportation Systems*, Las Palmas, Spain, p. 2877-2882, 2015.
- SHI, A.; WEIMING, K. Prediction of Urban Traffic Abnormity Based on Causal Network. In: *6th International Conference on Intelligent Systems Design and Engineering Applications*, Guiyang, China, p. 574-577, 2015.
- TANG, J. et al. Statistical properties of urban mobility from location-based travel networks. *Physica A: Statistical Mechanics and its Applications*, v. 461, p. 694-707, 2016.
- WEIMING, K.; SHI, A.; HUIFU, J. Detecting Traffic Anomalies in Urban Areas Using Taxi GPS Data. *Mathematical Problems in Engineering*, ID 809582, p. 13, 2015.
- YAI, A. K. 2015. Análise e visualização de dados do transporte público de ônibus da cidade de São Paulo. Monografia, Instituto de Matemática e Estatística da Universidade de São Paulo. Disponível em <https://linux.ime.usp.br/~andreky/AndreYai_monografia_revisada.pdf>. Acesso em: 02 abr. 2018.
- YU, B.; SONG, X.; GUAN, F.; YANG, Z.; YAO, B. K-nearest neighbor model for multiple-time-step prediction of short-term traffic condition. *Journal of Transportation Engineering*, v. 142, n. 6, 2016.
- ZENG, L. et al. Abnormal hotspots detection method based on region real-Time congestion factor. In: *2016 IEEE 19th International Conference on Intelligent Transportation Systems*, Rio de Janeiro, p. 749-753, 2016.
- ZHOU, Z. et al. A method for real-time trajectory monitoring to improve taxi service using GPS big data. *Information and Management*, v. 53, n. 8, p. 964-977, 2016.