



MOOBI: Uma Proposta de Abordagem Baseada em Dados para Análise de Mobilidade Urbana em Cidades Inteligentes

João Carlos Araújo dos Anjos Silva
André Almeida Silva

Curso de Ciência da Computação, Universidade Federal de Alagoas (UFAL) – Campus Arapiraca, Arapiraca, Brasil

Email: joao.anjos@arapiraca.ufal.br

Email: andre.almeida@arapiraca.ufal.br

Annals of Data Analysis

<https://periodicos.ufpe.br/revistas/ADA/>

Submitted on: 12.12.2025.

Accepted on: 01.08.2026.

Published on: 01.08.2026.

Copyright © 2026 by author(s).

This work is licensed under the Creative Commons Attribution International License CC BY-NC-ND 4.0

<http://creativecommons.org/licenses/by-nc-nd/4.0/deed.en>



Resumo

O crescimento urbano intensificou os desafios da mobilidade, demandando abordagens baseadas em dados para um planejamento eficaz. Este artigo apresenta o MOOBI, um framework sistemático para análise e otimização da mobilidade urbana, validado por meio de um estudo de caso na Região Metropolitana do Recife (RMR). A metodologia integra múltiplas fontes de dados e aplica modelos preditivos para identificar áreas de risco.

Os resultados revelam uma forte correlação entre a degradação da segurança viária e a migração de usuários do transporte coletivo para o individual. Como principal contribuição, o estudo propõe a expansão de corredores exclusivos de ônibus ("Faixa Azul") como uma política de duplo impacto, visando simultaneamente a melhoria da segurança e a eficiência do transporte público.

Keywords

Mobilidade Urbana; Cidades Inteligentes; Análise de Dados; Transporte Público

1. Introdução

O crescimento exponencial da população tem ocasionado transformações nas áreas urbanas, demandando análises e estudos focados no planejamento urbano e mobilidade (Conterno; Santos, 2023). De acordo com o Relatório Mundial das Cidades 2024, da ONU, atualmente cerca de 57% da população mundial reside em áreas urbanas e essa proporção tende a crescer

ainda mais nos próximos anos. No Brasil, estima-se que a taxa de urbanização atual é de 87%, refletindo um processo acentuado da urbanização no país (ONU 2024).

O uso de dados urbanos desempenha um papel essencial no planejamento e na avaliação das políticas de mobilidade, principalmente em um cenário global cada vez mais urbano, com cidades em constante crescimento. No Brasil, e em particular, em regiões com problemas críticos de mobilidade, como a Região Metropolitana de Recife, onde problemas críticos de mobilidade persistem, ainda existem lacunas significativas na coleta, integração e aplicação desses dados (Smart Mobility Review 2024).

Nesse contexto, o conceito das cidades inteligentes ganhou popularidade, propondo a incorporação estratégica de tecnologias digitais, sensores, redes de comunicação e sistemas de análises de dados para otimizar serviços e infraestruturas urbanas. Tendo como foco não apenas aumentar a eficiência de áreas como transporte, mas também promover um desenvolvimento social e econômico mais inclusivo, visando à melhoria na qualidade de vida dos cidadãos, ao mesmo tempo em que incentiva a participação social e a transparência na gestão pública (Al-Nasrawi et al. 2020).

Essa abordagem tem transformado a mobilidade urbana cada vez mais, trazendo vantagens consideráveis às inovações digitais em crescimento, migrando de métodos tradicionais, caros e limitados, para abordagens mais abrangentes e sistemáticas, impulsionadas por grandes volumes de dados (Giffinger 2007). Assim, é importante que o futuro da mobilidade em cidades inteligentes considere a capacidade de integrar a tecnologia em um planejamento urbano estratégico, focando em políticas públicas que priorizem pessoas e sustentabilidade.

No entanto, apesar dos avanços tecnológicos, a implementação de um sistema de mobilidade eficaz ainda enfrenta desafios. Muitas cidades carecem de plataformas que consolidem dados de múltiplas fontes, além da falta de informações de deslocamento de transportes e da mobilidade populacional, tornando-se entraves que dificultam a tomada de decisões baseada em evidências reais e seguras das regiões.

Dessa forma, este artigo tem por objetivo apresentar o MOOBI, uma proposta de abordagem baseada em dados para análise de mobilidade urbana, utilizando um estudo de caso na Região Metropolitana do Recife, em Pernambuco. O estudo visa integrar e processar informações de diversas fontes urbanas para fornecer uma visão holística dos padrões de deslocamento em cidades inteligentes. Por conseguinte, o MOOBI propõe ser uma ferramenta essencial, capaz de auxiliar gestores públicos a tomar decisões estratégicas para mitigar o congestionamento,

gerando insights mais precisos e preditivos para a gestão de mobilidade, promovendo, assim, a sustentabilidade e construindo cidades funcionais.

2. Referencial Teórico

2.1 Cidades Inteligentes

À medida em que a sociedade avança, os meios tecnológicos desenvolvem-se em um ritmo acelerado. Cidades têm adquirido um papel cada vez mais importante no desenvolvimento econômico e social, demandando a consolidação de estratégias de governança pública para garantir o progresso dos espaços urbanos com soluções que promovam eficiência, boas experiências e conformidade (Conterno e Santos, 2023).

Como resposta a essa necessidade por novas abordagens, o conceito de "cidades inteligentes" (smart cities) emergiu na década de 90, tendo como foco as novas Tecnologias de Informação e Comunicação (TIC), as quais estavam sendo incorporadas na estrutura urbana da época. O objetivo geral é propagar a utilização mais eficientes dos recursos públicos, aprimorando a qualidade dos serviços ofertados à população e consequentemente, reduzindo os entraves enfrentados pela administração pública, como por exemplo o planejamento urbano e a mobilidade urbana (Zanella et al., 2014).

Uma cidade inteligente, portanto, transcende a simples implementação de tecnologia. Segundo Lofhagen e Scoculi de Lira (2022), ela é caracterizada pela integração de seis dimensões fundamentais: governança, economia, meio ambiente, mobilidade, qualidade de vida e capital humano. O diferencial não está em cada dimensão isoladamente, mas na capacidade de conectá-las, criando um ecossistema urbano resiliente. Nessa visão, a tecnologia atua como um facilitador para que a cidade funcione de forma mais coesa e adaptável, promovendo inclusão social e equilíbrio ambiental.

O verdadeiro motor que viabiliza essa integração é o uso estratégico de dados. Para Paula (2024), as cidades inteligentes se apoiam em tecnologias de dados para aprimorar a gestão e o acesso dos cidadãos aos serviços. No contexto da mobilidade, isso significa que o planejamento deixa de ser baseado apenas em levantamentos estáticos e passa a incorporar análises dinâmicas. A capacidade de coletar, processar e analisar grandes volumes de dados de tráfego, transporte público e deslocamentos populacionais em tempo real permite a criação de sistemas de gestão mais eficientes, como os propostos neste trabalho.

2.2 Mobilidade Urbana

A mobilidade urbana exerce uma função crucial no desenvolvimento das cidades, sobretudo no progresso das cidades inteligentes, atuando como um fator de união entre a infraestrutura, tecnologia e bem-estar. Para Litman (2021), esta mobilidade não se define apenas pelo deslocamento de pessoas e bens, mas a possibilidade de possuir acesso a atividades, oportunidades e serviços de forma segura, eficiente e sustentável. Essa perspectiva amplia o entendimento sobre o tema, deslocando o cerne de políticas públicas e projetos de transportes públicos, como a construção de vias e ampliação de frotas para estratégias que priorizem o acesso igualitário aos cidadãos.

Vasconcellos (2014) alerta para o perigo de priorizar infraestrutura sem considerar acessibilidade equitativa, pois a simples oferta de transporte não garante justiça se não assegura efetivamente o acesso. É nesse contexto, que a criação de uma mobilidade inteligente, numa área urbana, torna-se por vezes um processo complexo, devido ao fato de ter entraves que dificultam o exercício de direitos fundamentais, como o direito de ir e vir.

Diante do desafio de aprimorar a mobilidade e, ao mesmo tempo, promover a sustentabilidade ambiental, torna-se essencial buscar alternativas para problemas como a baixa acessibilidade e o uso desordenado dos meios de transporte. Nesse sentido, o conceito de ‘cidade inteligente’ representa uma abordagem estratégica promissora. Para Andrade e Galvão (2016), a força dessa abordagem reside no uso intensivo das TIC para criar uma "mobilidade inteligente". Isso se traduz na capacidade de integrar os diferentes modais de transporte, otimizar os fluxos de tráfego em tempo real e, crucialmente, fornecer informações que capacitam os cidadãos a tomarem decisões de deslocamento mais eficientes e sustentáveis.

A inclusão entre os diferentes meios de transporte e a utilização de tecnologias em crescimento, como ITS e análise de dados, tornaram-se fundamentais para potencializar a mobilidade urbana (Gonçalves et al. 2019). Por esse ângulo, essas alternativas permitem no monitoramento do fluxo de veículos, na redução de congestionamentos e na melhoria da experiência dos cidadãos, além de contribuir para a diminuição das emissões de gases poluentes, garantindo, assim, uma cidade sustentável. Assim, a mobilidade inteligente deixa de ser um conceito futurista para se tornar uma necessidade estratégica no planejamento urbano atual.

Entre as estratégias tecnológicas que vêm transformando a mobilidade urbana nas grandes cidades, destacam-se o uso de sensores Internet das coisas (IoT) e análise em tempo real que possibilitam a transformação da mobilidade urbana, reduzindo congestionamentos e tempo de viagem, além de apoiar decisões aos gestores no momento de planejamento urbano (Gharaibeh

2017). Essas inovações, quando bem estruturadas, oferecem uma alternativa mais viável para a construção de sistemas de transporte mais eficientes e alinhados aos princípios de desenvolvimento sustentável, contribuindo, conseqüentemente, para o desenvolvimento socioeconômico.

2.3 Análise de Dados Aplicada à Mobilidade Urbana

As tecnologias têm intensificado grandes mudanças nas cidades, gerando também impactos nas áreas urbanas e influenciando a economia, a sociedade, o meio ambiente e a gestão pública (Conterno; Santos, 2023). Essas transformações moldam o cenário contemporâneo, desde a forma como a população se desloca e interage, até a maneira como os recursos são utilizados e administrados. Esse contexto, conseqüentemente exige a busca por soluções que promovam o crescimento, aumentem eficiência e assegurem sustentabilidade das cidades.

Nações e regiões socioeconômicas estruturadas vêm estudando diversas alternativas para o desenvolvimento das questões urbanas, sendo uma delas a utilização de dados como meio de mudança no paradigma atual, refletindo em situações de mobilidade desarmônica e congestionamento intenso de transportes. Desse modo, surgem métodos eficientes que trabalham com análises urbanas para o enfrentamento desses desafios, proporcionando uma compreensão dos padrões de mobilidade, ajudando a otimizar sistemas de transporte e a desenvolver políticas sustentáveis (Molina-Campoverde et al. 2024).

Comumente, as cidades inteligentes abordam o uso de tecnologias voltadas a ITS quando o tema é sobre o progresso das áreas urbanas, trazendo abordagens que transformem os espaços em lugares mais seguros e eficientes. Entre as abordagens mais comuns de serem utilizadas, sistemas que usam IoT e análise de dados destacam-se por tornar a gestão de recursos governamentais mais eficiente e econômica (Zaman et al. 2024). Ademais, os dispositivos conectados otimizam o controle de tráfego e reduzem o número de acidentes das cidades (Rizwan et al. 2016).

A grande quantidade de dados gerados nas cidades, provenientes de sensores de tráfego, GPS e dispositivos móveis, constitui um recurso valioso para a compreensão dos padrões de mobilidade urbana (Al-Sarayrah et al., 2020). Entretanto, os volumes de dados usados constantemente são encontrados em diversas fontes e formatos, dificultando tanto o processamento dos dados quanto o planejamento urbano. Dessa forma, surgem métodos para organizar e gerenciar essas informações complexas. Uma abordagem comum nesses casos é a utilização de Data Warehouse, que funcionam como repositórios unificados para integrar dados

de diferentes origens. Assim, a centralização de dados simplifica o processamento e a análise, proporcionando visão holística da mobilidade urbana e permitindo um planejamento estratégico mais eficaz (Hassan et al. 2020).

O potencial dos dados brutos é ampliado quando integrado com métodos mais avançados de análise. Nesse contexto, a inteligência artificial e o aprendizado de máquina trazem ferramentas para transformar informações em ações estratégicas assertivas. Entre as diversas técnicas, destacam-se os algoritmos de árvores de decisão, amplamente utilizados na previsão de congestionamentos, permitindo que gestores públicos possam implementar ações proativas para otimizar o fluxo de veículos e o planejamento de rotas (Mishra et al. 2021). Essa capacidade de previsão vai além da identificação de problemas: ela também possibilita que os sistemas de transporte se adaptem, sugerindo rotas alternativas e gerenciando a demanda do transporte público com base em padrões de uso e eventos urbanos.

3. Metodologia

A abordagem metodológica adotada no desenvolvimento e na validação da abordagem MOOBI segue a lógica da pesquisa aplicada, com um design de caráter quali-quantitativo e experimental. Creswell (2017) destaca essa combinação de métodos para explorar o problema de forma abrangente, integrando a revisão teórica com a análise empírica de dados, gerando, assim, soluções robustas. Dessa forma, o objetivo principal deste trabalho é propor e validar o MOOBI, um framework sistemático baseado em dados para a análise e otimização da mobilidade urbana, por meio de um estudo de caso aplicado à Região Metropolitana do Recife. A jornada de pesquisa seguiu um caminho claro, dividido em três grandes momentos. A primeira, de Fundamentação e Planejamento, foi o ponto de partida para entender o problema, revisando o que já se sabia sobre Cidades Inteligentes e Mobilidade Urbana. A segunda fase, de Concepção e Desenvolvimento, foi dedicada à criação do framework MOOBI como o artefato primordial desta pesquisa, detalhando sua estrutura interna de cinco etapas (Mapeamento, Organização, Observação, Benchmarking e Insights). Por fim, a fase de validação colocou o MOOBI à prova através de um estudo de caso na Região Metropolitana do Recife, no qual foram utilizados dados reais para aplicar e avaliar nossa abordagem, gerando os resultados discutidos neste artigo.

3.1 Fundamentação e Planejamento

A fase inicial da pesquisa teve como objetivo a identificação do problema e a construção da base teórica do trabalho. Para isso, foi realizada uma revisão sistemática da literatura,

explorando os temas de Cidades Inteligentes, Mobilidade Urbana e o uso de análise de dados no planejamento urbano. Esta etapa foi essencial para identificar a lacuna existente: a necessidade de um framework estruturado que colete, analise dados de mobilidade e traduza os achados em insights acionáveis para as autoridades públicas. A partir dessa análise, foram definidos os requisitos essenciais para a nova abordagem, que deve ser replicável, escalável e capaz de integrar fontes de dados heterogêneas para gerar um diagnóstico completo da mobilidade urbana.

A literatura revela uma evolução significativa no conceito de Cidades Inteligentes, que transcende a simples implementação de tecnologia e se aprofunda no uso de Inteligência Artificial (IA) e Digital Twins (Gêmeos Digitais) para uma gestão urbana proativa (Ahmed et al., 2022). No campo da mobilidade, a discussão se concentrou na transição da análise de tráfego tradicional para modelos preditivos que utilizam Machine Learning para prever congestionamentos, otimizar rotas de transporte público e aumentar a segurança viária (Zhao et al., 2023). Essa nova geração de análise de dados, focada em sustentabilidade e equidade, evidencia a principal lacuna que este trabalho se propõe a endereçar: a necessidade de frameworks, como o MOOBI, que não apenas processem dados, mas que os traduzam em inteligência acionável para um planejamento da mobilidade mais resiliente e centrado no cidadão.

3.2 Concepção e Desenvolvimento do Framework MOOBI

Esta fase representa o núcleo da pesquisa aplicada e foi dedicada à criação do artefato central do trabalho: o framework MOOBI. Com base nos requisitos definidos na fase anterior, o MOOBI foi concebido como uma metodologia cíclica e sistemática, organizada em cinco macroetapas interdependentes: i) mapeamento, com foco na coleta multidimensional; ii) organização, baseada na engenharia de dados e unificação; iii) observação, feita através da análise exploratória e diagnóstica; iv) benchmarking, elaborada a partir da avaliação e comparação; e v) insights, resultado da modelagem preditiva e prescritiva. A estrutura do MOOBI (ver Figura 1) constitui a "metodologia da ferramenta", detalhando o processo pelo qual os dados de mobilidade são processados e analisados para gerar recomendações que apoiem a tomada de decisão, o que representa a principal contribuição inovadora desta pesquisa.




Figura 1. Framework MOOBI

Na etapa de mapeamento, houve a identificação e coleta de múltiplas fontes de dados, garantindo heterogeneidade e profundidade analítica. Foram incluídos dados móveis para estimar padrões OD, bases geoespaciais contendo a malha viária e ciclovária, registros de acidentes com coordenadas espaciais e indicadores socioeconômicos de polos geradores de viagens.

O uso de big data de telefonia móvel oferece vantagens sobre pesquisas tradicionais de Origem-Destino (OD), uma vez que permite observar deslocamentos reais em grande escala e com alta resolução espacial (Pezzuto et al., 2021). A formulação clássica de uma matriz OD é representada como:

$$OD_{ij} = Tu(i \rightarrow j)$$

Esse cálculo resume o número de viagens entre setores i e j a partir dos deslocamentos captados de usuários de telefonia. Seu impacto é direto na precisão: enquanto pesquisas OD amostrais cobrem milhares de indivíduos, dados móveis podem refletir milhões de deslocamentos. Isso aumenta a representatividade dos fluxos urbanos e reduz vieses de coleta (Kitchin 2021).

Os dados foram selecionados meticulosamente para garantir que abordassem tanto a infraestrutura física da área quanto a dinâmica de deslocamento com o uso de modais. Foram utilizados:

- Big data de telefonia móvel, que permite inferir os fluxos de deslocamentos da população a partir de modais como rodoviário, hidroviário, ferroviário e aéreo. Com

foco apenas nos três primeiros, tais dados foram organizados pelo Ministério da Infraestrutura e pelo Ministério de Portos e Aeroportos;

- Malha viária e ciclovária de Recife e dados geoespaciais de acidentes de trânsito, disponibilizados no Portal de Dados Abertos da Prefeitura de Recife e da Autarquia de Trânsito e Transporte Urbano;
- Bases de origem e destino multimodal de 2018 e base contendo o tempo médio de deslocamento casa-trabalho, ambas obtidas por meio da plataforma Mobilidados, para estudar os modais de transporte usados pela população e o fluxo constante.

Na etapa de organização, foca-se no pré-processamento e na integração dos dados em uma arquitetura unificada, etapa essencial para transformar dados brutos em uma base confiável e escalável para análises avançadas. Nessa fase, aplicam-se rotinas de ETL (Extract, Transform, Load), incluindo limpeza de inconsistências, padronização de formatos, enriquecimento espacial e consolidação em um Data Warehouse Geoespacial (DWG).

A infraestrutura proposta adota o PostgreSQL juntamente com o PostGIS como camada de persistência, em razão da maturidade no tratamento de dados espaciais, incluindo suporte a tipos como GEOGRAPHY e GEOMETRY, índices avançados e funções específicas para joins espaciais, snap-to-grid, map-matching e agregações por polígono. Essa estrutura garante escalabilidade e consistência no armazenamento de grandes volumes de dados urbanos e alinha-se a modelos de plataformas de cidades inteligentes. O City Data Hub, por exemplo, demonstra como a padronização semântica e o uso de APIs abertas podem viabilizar a interoperabilidade entre múltiplas fontes de dados urbanos, assegurando a integração entre sensores, registros de mobilidade e serviços digitais (Jeong et al. 2020). O pipeline de ETL geoespacial é estruturado em três estágios principais:

- Extract: ingestão de camadas vetoriais (vias, ciclovias, corredores e estações de BRT/Metrô/VLT), registros de acidentes (pontos georreferenciados) e fluxos de deslocamento multimodal (CDRs, GPS, smart cards);
- Transform: execução de processos de limpeza, schema mapping, padronização de sistemas de referência espacial (CRS), map-matching de pontos a trechos da malha, enriquecimento com grades espaciais hierárquicas (H3 ou quadtiles), e construção de tabelas fato (e.g., FATO_FLUXO, FATO_ACIDENTE) e dimensões (e.g., DIM_TRECHO, DIM_TEMPO, DIM_MODAL, DIM_ZONA);

- Load: carga incremental com upserts, versionamento temporal (carimbos de validade) e materialização de visões analíticas para consultas OLAP, permitindo análises comparativas e preditivas em múltiplas escalas espaciais e temporais.

Na etapa de observação, após os dados organizados, passa-se à fase de análise exploratória e diagnóstica. Essa etapa visa identificar padrões de fluxo, horários de pico, corredores críticos e hotspots de acidentes. Foram utilizadas técnicas de análise descritiva e visualizações geoespaciais, como mapas de fluxo e mapas de calor, capazes de revelar gargalos da mobilidade e orientar hipóteses para etapas posteriores. As análises diagnósticas baseadas em dados móveis são capazes de captar mudanças súbitas de comportamento populacional com maior precisão (Molina-Campoverde et al., 2024). Um exemplo de métrica utilizada nas análises exploratórias é a intensidade viária, demonstrada na fórmula:

$$IV = Q / T$$

onde Q é o volume total de veículos observados em uma via e T o tempo de observação. Essa medida revela quais corredores concentram maior pressão de tráfego e em quais horários. Outro indicador importante é o Índice de Severidade Viária (ISV):

$$ISV = VF + (0,5 \times VNF)$$

em que VF representa a quantidade de vítimas fatais e VNF as vítimas não fatais. O ISV é amplamente utilizado em segurança viária para identificar zonas críticas (Vasconcellos 2014). Na etapa de benchmarking, sucede-se a fase de avaliação e comparação das fontes de dados. Diante disso, foram empregadas algumas abordagens:

- Comparação Histórica de Fluxos: utilizando os dados de telefonia móvel como linha de base, a análise comparativa foi realizada com os padrões de fluxo de deslocamento inferidos a partir dos dados da matriz OD multimodal de 2018. Essa avaliação permitiu identificar como a distribuição da demanda por transporte se alterou ao longo dos anos;
- Análise Comparativa de Pontos Críticos: foram mapeados os hotspots de acidentes de 2018 a 2025 e comparados entre os anos. Essa análise não apenas identifica se áreas perigosas permaneceram as mesmas, mas também se novos locais de alto risco surgiram na rede;
- Análise de Padrões Temporais: utilizando a série histórica de dados de acidentes e fluxo, foi possível comparar a evolução de padrões sazonais e de comportamento.

A partir do benchmarking, as anomalias e as tendências de longo prazo foram validadas, fornecendo uma base sólida para a geração de insights preditivos e prescritivos.

Por fim, na etapa de insights, volta-se à geração de recomendações estratégicas por meio de análises preditivas e simulações de intervenções. Utilizando algoritmos de aprendizado de máquina, como modelos de regressão, são elaborados cenários futuros para identificar a evolução de riscos, como a probabilidade de aumento de acidentes em corredores críticos. Para isso, são empregadas duas abordagens conectadas:

- **Modelo Preditivo de Risco:** utilizando algoritmos de aprendizado de máquina, como regressão, são elaborados cenários futuros para identificar a evolução de riscos de acidentes em corredores críticos;
- **Simulação de Intervenções (Gestão de Tráfego):** são simulados os impactos de intervenções de gestão de tráfego, como a expansão de corredores exclusivos de ônibus ("Faixa Azul").

Essa abordagem dualista permite que as recomendações sejam integradas, tratando simultaneamente os problemas de segurança e de fluidez, em linha com a defesa de Mahrez et al. (2021) sobre o uso de IA para o planejamento urbano proativo.

4. Resultados e Discussão

4.1 Cenário do Estudo de Caso

A cidade de Recife e sua região metropolitana, vista na Figura 2, configuram-se como um dos maiores polos econômicos do Nordeste Brasileiro. No entanto, essa importância é acompanhada por um desafio bastante comum na região: a mobilidade urbana. A área é marcada por uma geografia complexa, com rios, pontes e vias que frequentemente enfrentam engarrafamentos constantes e uma alta densidade populacional, principalmente em pontos críticos como as avenidas Agamenon Magalhães, Abdias de Carvalho e Mascarenhas de Moraes. De acordo com o TomTom Traffic Index, a capital do estado é frequentemente classificada entre as cidades com o pior índice de congestionamento global (Mitička et al. 2023). A rede de transporte público, mesmo abrangente, lida com alto nível de demanda e necessidade de maior eficiência na integração de modais de transporte, afetando diretamente a produtividade, a qualidade de vida e a saúde dos cidadãos.




Figura 2. Mapa da Região Metropolitana de Recife

Ademais, o alto volume de tráfego na região metropolitana de Recife gera impactos diretos e mensuráveis, como o desperdício de tempo e combustível, o aumento dos custos operacionais e um maior risco de acidentes. Além disso, a falta de uma visão unificada e em tempo real sobre a dinâmica dos deslocamentos impede uma gestão proativa, limitando a capacidade de prever picos de congestionamento e de otimizar rotas do transporte público. A complexidade desses desafios e a abundância de dados gerados diariamente criam um ambiente ideal para o desenvolvimento de soluções baseadas em dados, onde a análise desses pode fornecer os insights necessários para a tomada de decisões estratégicas e a melhoria da eficiência do sistema de transporte.

4.2 Aplicação do MOOBI

A análise dos dados de tráfego, coletados de várias fontes como sensores, GPS, dispositivos móveis e informações de fluxo, revelou insights importantes sobre a gestão atual da mobilidade urbana. Ao aplicar a análise de dados, foi possível identificar e mapear padrões de trânsito essenciais, pontos críticos de congestionamento e os tempos de viagem. Esses padrões foram cruciais para otimizar estratégias de gestão de mobilidade e melhorar o fluxo geral.

A principal fonte de dados para inferir os fluxos de deslocamento foi uma matriz Origem-Destino (OD) de 2018. A matriz foi fundamental para entender o volume de viagens entre as zonas de tráfego, identificar os principais corredores de deslocamento intermunicipal e analisar a distribuição da demanda por transporte em toda a RMR. A Tabela 1 demonstra a matriz de origem e destino utilizada.

Tabela 1. Matriz Origem Destino de 2018

Origem (Bairro)	Destino: Boa Vista	Destino: Cabanga	Destino: Coelhos
Boa Vista	0,00	2,42	10,64
Cabanga	2,46	0,00	0,00
Coelhos	1,32	0,00	0,00

A base de dados de acidentes de trânsito, com coordenadas espaciais, foi utilizada para identificar pontos de risco e para o cálculo do Índice de Severidade Viária (ISV). Desse modo, a análise de acidentes de trânsito tem como resultado identificar as áreas mais inseguras para a população, demandando, assim, melhorias na infraestrutura e na mobilidade urbana. Os dados de exemplo podem ser vistos na Tabela 2.

Tabela 2. Acidentes de Trânsito em Recife

Hora	Natureza	Bairro	Endereço	Vítimas
04:56:00	COM VÍTIMA	BAIRRO DO RECIFE	AV ALFREDO LISBOA	1,0
08:00:00	COM VÍTIMA	BAIRRO DO RECIFE	PTE BUARQUE DE MACEDO	1,0
08:02:00	SEM VÍTIMA	BAIRRO DO RECIFE	AV RIO BRANCO	0,0

Fornecidas pela Mobilidados, a base de TMA possibilitou a visualização das principais vias de transportes públicos, sendo eles os modais: BRT, Metrô e VLT. A partir disso, foi possível identificar a rede de circulação de veículos e as áreas com infraestrutura. A Tabela 3 permite a visualização dos modais.

Tabela 3. Transporte de Média e Alta Capacidade

Nome	Descrição	Geometria
3027	Modo: Trem Cidade: Natal	POINT Z (-46.47107 -23.54238 0)
1313	Modo: Metrô Cidade: São Paulo	POINT Z (-46.4846 -23.54024 0)
1314	Modo: Metrô Cidade: São Paulo	POINT Z (-46.50125 -23.53124 0)

Para complementar a análise de fluxos, foram integradas bases de apoio que mapeiam a infraestrutura viária da RMR, como a malha viária e ciclovária, faixas azuis e, por fim, a matriz OD multimodal de 2018, o qual serviu como um dado de referência para o benchmarking, permitindo a comparação dos padrões de deslocamento com a situação atual.

O procedimento de organização seguiu a rotina de ETL (Extract, Transform, Load), na qual as bases de dados de acidentes, matriz OD, TMA e infraestrutura foram extraídas de seus formatos originais (CSV, KML, GeoJSON) para um ambiente centralizado. Logo em seguida, todos os dados foram consolidados em um Data Warehouse utilizando o PostgreSQL com a extensão PostGIS, que é amplamente reconhecida pela sua capacidade de lidar de forma eficiente com grandes volumes de dados espaciais.

O esquema do modelo, cuja estrutura é vista na Figura 3, seguiu uma abordagem que não apenas armazena as informações, mas também facilita análises complexas. Dessa forma, foi utilizado um modelo dimensional, conhecido como Esquema Estrela, separando os Fatos (métricas e eventos) das Dimensões (contexto, como tempo e localização).




Figura 3. Estrutura do Modelo de Dados

A análise teve como objetivo transformar os dados organizados em um diagnóstico quantitativo da mobilidade na Região Metropolitana do Recife (RMR). Primordialmente, foram utilizadas técnicas de análise descritiva e visualizações geoespaciais, como tabela de fluxo e mapas de calor, capazes de revelar gargalos da mobilidade e orientar hipóteses para etapas posteriores. Para início, foi gerada a tabela de fluxos de deslocamento com o intuito de analisar a dimensão do fluxo de deslocamento do estado, analisando as principais rotas de origem e destino feitas pelos indivíduos, conforme ilustrado na Figura 4.



Figura 4. Mapa de Fluxo de Deslocamento de Pernambuco

A partir da geocodificação dos endereços dos sinistros, foram gerados mapas de calor que ilustram a concentração de ocorrências ao longo dos anos. É importante notar que a análise se baseia nos dados disponíveis e, devido à inconsistência no volume de registros entre os anos, o foco não é a densidade relativa entre os mapas, mas sim a localização dos hotspots de acidentes e a persistência desses pontos no tempo. A Figura 5 mostra as principais áreas de ocorrência de acidentes da região metropolitana de Recife, identificando os maiores gargalos e situações de melhoria nas zonas em questão.




Figura 5. Mapa de Calor dos anos (1) 2024, (2) 2023, (3) 2022, (4) 2021, (5) 2020, (6) 2019 e (7) 2018

Ao aplicar as métricas definidas na metodologia, foi possível identificar os principais padrões de deslocamento e os desafios de segurança viária. Destaca-se que o Índice de Severidade Viária (ISV) foi utilizado para avaliar a gravidade dos acidentes de trânsito em Recife ao longo da série histórica. A análise dos dados de 2018 a 2024 revela tendências importantes na segurança viária da cidade. Assim, a Tabela 4 demonstra os índices de severidade dos anos de 2018 a 2024 de Recife, permitindo analisar os anos com mais incidência e os motivos para tais ocorrências.

Tabela 4. Índice de Severidade Viária de 2018 a 2024

Ano	ISV
2018	8.5
2019	11.5
2020	5.0
2021	7.5
2022	9.0
2023	19.0
2024	14.5

Em consonância, o cálculo da intensidade viária, com base na matriz OD de 2018, forneceu uma visão quantitativa da demanda de deslocamento por motivo de trabalho na RMR. O volume total, que representa a intensidade viária diária, foi de 1.730.457,68 viagens/dia.

A partir da análise exploratória e diagnóstica, a metodologia avança para a fase de benchmarking, um pilar central para a avaliação e a contextualização dos resultados. Esta etapa

transcende a simples observação, transformando os dados em um instrumento comparativo capaz de validar tendências e identificar anomalias. Conforme a teoria de planejamento urbano, a comparação com cenários de referência, sejam históricos ou de outras cidades, é fundamental para mensurar a eficácia das intervenções e o progresso das políticas públicas (Giffinger, 2007). A dinâmica da mobilidade urbana na Região Metropolitana do Recife (RMR) foi analisada com base na Pesquisa Origem-Destino (OD) de 2018, que permitiu o mapeamento dos principais eixos de deslocamento. A Tabela 5 detalha os cinco maiores fluxos de viagens diárias, evidenciando a centralidade do município do Recife como principal polo de atração de viagens.

Tabela 5. Fluxo de Deslocamento dos 5 Principais Fluxos de 2018

Posição	Origem	Destino	Volume de Viagens (diárias)
1	Jaboatão dos Guararapes	Recife	18.061,00
2	Recife	Jaboatão dos Guararapes	15.393,00
3	Olinda	Recife	14.155,00
4	Recife	Olinda	11.589,00
5	Paulista	Recife	9.352,00

Para compreender a evolução dos padrões de deslocamento, a Tabela 6 compara a divisão modal entre os anos de 2018 e 2021.

Tabela 6. Divisão Modal de 2018 e 2021

Modo de Transporte	Pesquisa OD 2018 (%)	Pesquisa OD 2021 (%)
Ônibus	30%	22%
Metrô	1%	1%
Automóvel (Condutor)	16%	20%
Automóvel (Passageiro)	19%	11%
Motocicleta	5%	7%
Transporte por Aplicativo	1%	1%
A Pé	36%	37%
Bicicleta	1%	1%

A comparação entre os dados revela uma notável reconfiguração nos padrões de deslocamento da população. Observou-se uma redução significativa na utilização do transporte coletivo, cuja participação caiu de 31% para 23%, impulsionada principalmente pela diminuição do uso de ônibus. Em contrapartida, o transporte individual motorizado experimentou um crescimento expressivo, aumentando sua fatia de 32% para 39%, com destaque para o incremento no uso do automóvel particular como condutor. Apesar dessas mudanças, os modos de transporte não motorizados, como os deslocamentos a pé e por bicicleta, mantiveram-se relativamente estáveis, consolidando-se como a principal forma de locomoção na região.

Além disso, foram mapeados os hotspots de acidentes de 2018 a 2024 e comparados entre os anos. Essa análise não apenas identifica se áreas perigosas permaneceram as mesmas, mas

também se novos locais de alto risco surgiram na rede. A Tabela 7 apresenta uma análise comparativa dos 5 principais pontos críticos de acidentes de trânsito em Recife ao longo de sete anos. Os dados revelam a dinâmica da segurança viária na cidade e o impacto de fatores externos, como a pandemia de COVID-19.

Tabela 7. Análise Comparativa dos 5 Principais Hotspots de Acidentes por Ano

Ponto Crítico	2018	2019	2020	2021	2022	2023	2024
AV Governador Agamenon Magalhães	467	551	158	134	128	163	219
AV Norte Miguel Arraes de Alencar	0	0	0	49	89	158	193
AV Marechal Mascarenhas de Moraes	461	459	133	52	71	169	188
AV Caxangá	323	312	135	86	109	148	171
AV Recife	366	358	101	66	84	147	142

Como mostra a tabela, algumas vias, como a Av. Governador Agamenon Magalhães e a Av. Marechal Mascarenhas de Moraes, mantiveram uma alta contagem de acidentes ao longo de todo o período, consolidando seu status como pontos de atenção persistentes. No entanto, é notável o aumento de acidentes em vias como a Av. Norte Miguel Arraes de Alencar, que, apesar de não registrar acidentes nos anos iniciais, emergiu como um dos principais hotspots nos anos mais recentes, sugerindo a necessidade de intervenções urgentes.

Enfim, a etapa final do MOOBI consolida o diagnóstico em uma inteligência acionável, conectando a análise preditiva de riscos com a análise prescritiva de gestão de tráfego. O principal insight que emerge é a relação direta entre os corredores com maior número de acidentes (Tabela 7) e os eixos vitais para o transporte público, que sofrem com o aumento do transporte individual (Tabela 6).

Para quantificar e priorizar as ações, foi aplicado um modelo preditivo de risco, conforme descrito na metodologia. O modelo calcula um Índice Preditivo de Risco (IPR) para os próximos 24 meses, considerando como variáveis o histórico e a severidade dos acidentes, o volume de fluxo e a tendência de aumento de veículos individuais. A Tabela 8 sintetiza os resultados deste modelo.

Tabela 8. Síntese do Modelo Preditivo de Risco e Recomendações Direcionadas

Via Crítica	Fatores de Risco (Variáveis do Modelo)	IPR (2025-2026)	Recomendação Direcionada
Av. Mascarenhas de Moraes	Histórico persistente de acidentes	8.5 / 10 (Crítico)	Prescritiva: Expansão da Faixa Azul para segregação do tráfego e redução de conflitos
Av. Norte M. Arraes de Alencar	Aumento acentuado de acidentes (Tabela 7); forte	7.8 / 10 (Alto - Em Agravamento)	Preditiva: implementação preventiva de Faixa Azul e

	aumento no fluxo de automóveis (Tabela 6)		medidas de acalmamento de tráfego
Av. Gov. Agamenon Magalhães	Maior volume de fluxo da RMR (Tabela 5); maior número histórico de acidentes (Tabela 7); complexidade de interseções	9.2 / 10 (Crítico)	Monitoramento: implementação de sistema de monitoramento inteligente para gestão de tráfego em tempo real

A análise da tabela revela que diferentes perfis de risco exigem diferentes estratégias. Com base nisso, a recomendação central é a adoção de um plano de intervenção priorizado, visualizado no mapa estratégico da Figura 6, que direciona as soluções de gestão de tráfego (como a Faixa Azul) para os locais onde o modelo preditivo aponta maior criticidade.




Figura 6. Mapa Estratégico de Intervenções para a Mobilidade do Recife

O mapa destaca as ações prioritárias que emergem da análise, numeradas de 1 a 3. A estratégia se inicia com uma intervenção corretiva e de alta urgência no hotspot persistente da Av. Marechal Mascarenhas de Moraes (1), utilizando a expansão da Faixa Azul como um instrumento para reduzir os conflitos de tráfego. Em paralelo, uma ação preventiva é direcionada ao hotspot emergente da Av. Norte Miguel Arraes de Alencar (2), buscando mitigar o risco antes de sua consolidação. Por fim, para o complexo corredor da Av. Governador Agamenon Magalhães (3), recomenda-se um monitoramento contínuo e inteligente, consolidando uma abordagem que equilibra soluções imediatas com planejamento proativo de médio e longo prazo.

Em suma, a seção demonstrou que a análise aprofundada dos dados, por meio do framework MOOBI, permite não apenas diagnosticar problemas crônicos de segurança viária, mas também formular soluções integradas e de alto impacto. A aplicação de modelos preditivos e prescritivos foi fundamental para identificar a expansão da "Faixa Azul" como um instrumento de duplo benefício, capaz de promover tanto a eficiência do transporte coletivo quanto a segurança dos cidadãos.

5. Conclusão

A aplicação do framework MOOBI na Região Metropolitana do Recife validou a abordagem metodológica e, mais importante, revelou dinâmicas críticas sobre a mobilidade urbana local. O principal resultado deste estudo aponta para uma falha sistêmica no planejamento da mobilidade, evidenciada pela correlação direta entre a degradação da segurança viária e a contínua migração de usuários do transporte coletivo para o individual motorizado. Este fenômeno, alinhado ao conceito de "mobilidade excludente" de Vasconcellos (2014), demonstra como a perda de atratividade do transporte público força a população a adotar alternativas que, paradoxalmente, aumentam os congestionamentos e os riscos para todos.

A análise preditiva demonstrou que, sem intervenções estratégicas, os principais corredores da RMR tendem a agravar seu perfil de risco. A recomendação da expansão da "Faixa Azul", portanto, transcende uma simples medida de fluidez; ela é apresentada como uma política de segurança viária, capaz de reorganizar o espaço urbano para mitigar os conflitos identificados. Essa abordagem converge com a literatura sobre cidades inteligentes, que defende a otimização da infraestrutura existente por meio de soluções de ITS (Mahrez et al. 2021). Embora a análise tenha se mostrado robusta, reconhece-se como limitação o uso de uma matriz OD mais antiga como linha de base, o que pode não capturar integralmente as mudanças de comportamento pós-pandemia.

Em conclusão, este artigo cumpriu seu objetivo ao apresentar e validar o MOOBI como uma ferramenta sistemática para gerar inteligência acionável a partir de dados de mobilidade. A principal contribuição do trabalho é a demonstração prática de como a análise preditiva pode fundamentar políticas públicas de alto impacto, transformando um diagnóstico complexo em uma recomendação clara e localizada. Para trabalhos futuros, sugere-se a incorporação de fontes de dados em tempo real para aumentar a dinamicidade das análises e a inclusão de variáveis socioeconômicas nos modelos preditivos. A evolução contínua do MOOBI, seguindo

essas direções, poderá fortalecer ainda mais seu papel como um instrumento de apoio à decisão, essencial para a construção de cidades mais seguras, eficientes e sustentáveis.

6. Referências

1. CONTERNO, R.; SANTOS, G. Mobilidade Urbana em Cidades Inteligentes: lacunas, tendências e oportunidades. *Revista Brasileira de Geografia Física*, v. 18, p. 1475-1497, 2025.
2. ZAMAN, M.; PURYEAR, N.; ABDELWAHED, S.; ZOHRABI, N. A Review of IoT-Based Smart City Development and Management. *OUCI*, v. 1, n. 1, p. 1-12, 2024.
3. MITIEKA, D.; LUKE, R.; TWINOMURINZI, H.; MAGETO, J. Smart Mobility in Urban Areas: A Bibliometric Review and Research Agenda. *Sustainability*, v. 15, n. 8, p. 6754, 2023.
4. AL-NASRAWI, B.; ABUSULAIMAN, K.; ALMARRI, O.; ALSAIDI, M.; AL-AHMADI, S. A comprehensive study on smart city. *International Journal of Computer Science & Engineering Survey*, v. 11, n. 1, p. 1-13, 2020.
5. GIFFINGER, R. et al. *Smart cities: ranking of european medium-sized cities*. Vienna: Centre of Regional Science, 2007.
6. ZANELLA, A.; BUI, N.; CASTELLANI, A.; VANGELISTA, L.; ZORZI, M. Internet of things for smart cities. *IEEE Internet of Things Journal*, v. 1, n. 1, p. 22-32, 2014.
7. FERREIRA, A. S. Cidades inteligentes e sustentáveis: análise e definições acerca da literatura. *Revista Ibero Americana de Ciências Ambientais*, v. 12, n. 6, p. 512-521, 2021.
8. KOMNINOS, N. *Intelligent cities: Innovation, knowledge systems, and digital spaces*. New York: Taylor & Francis, 2002.
9. PAULA, S. L.; SANTANA, E. M. B.; ANDRADE, C. A. S. J. Cidades inteligentes e mobilidade urbana: inovações tecnológicas. *Revista DeLos*, v. 17, n. 53, e1304, 2024.
10. PASQUAL LOFHAGEN, J.; LIRA, G. Cidades inteligentes e o transporte urbano sustentável com bioenergia: um estudo de caso de Curitiba, Brasil. *Revista Tecnologia e Sociedade*, v. 18, p. 207, 2022.
11. LITMAN, T. Exploring the Paradigm Shifts Needed To Reconcile Transportation and Sustainability Objectives. *Transportation Research Record*, v. 1670, n. 1, p. 8-12, 1999.

12. VASCONCELLOS, E. A. de. *Políticas de transporte no Brasil: A construção da mobilidade excludente*. Manole, 2014.
13. ANDRADE, J. N.; GALVÃO, D. C. O conceito de smart cities aliado à mobilidade urbana. *REVISTA HUM@NAE*, v. 10, n. 1, 2016.
14. GONÇALVES, P. D. M.; RIBEIRO, R. J. C. O desempenho da mobilidade urbana a partir da configuração espacial da cidade. In: PLURIS 2018, Coimbra, Portugal, 2019.
15. GHARAIBEH, A. et al. Smart Cities: A Survey on Data Management, Security, and Enabling Technologies. *IEEE Communications Surveys & Tutorials*, v. 19, n. 4, p. 2456-2501, 2017. DOI: 10.1109/COMST.2017.2736886.
16. MOLINA-CAMPOVERDE, J. J.; RIVERA-CAMPOVERDE, N.; MOLINA CAMPOVERDE, P. A.; BERMEIO NAULA, A. K. Urban Mobility Pattern Detection: Development of a Classification Algorithm Based on Machine Learning and GPS. *Sensors*, v. 24, n. 12, p. 3884, 2024.
17. RIZWAN, P.; SURESH, K.; BABU, D. M. R. Real-time smart traffic management system for smart cities by using Internet of Things and big data. *International Journal of Computer Trends and Technology*, v. 39, n. 1, p. 1-5, 2016.
18. HASSAN, M. M.; MAHMOUD, M.; AL-MAHMOOD, S. M. et al. A Review on Smart City Data Management and Platforms. In: *2020 IEEE International Conference on Telecommunications and Photonics*, 2020, p. 1-6.
19. CRESWELL, J. W.; CRESWELL, J. D. *Research design: Qualitative, quantitative, and mixed methods approaches*. Sage publications, 2017.
20. MAHREZ, Z.; SABIR, E.; BADIDI, E.; SAAD, W.; SADIK, M. Smart Urban Mobility: When Mobility Systems Meet Smart Data. *IEEE Transactions on Intelligent Transportation Systems*, v. 23, n. 7, p. 6222-6239, 2021.
21. JEONG, S.; KIM, S.; KIM, J. City Data Hub: Implementation of Standard-Based Smart City Data Platform for Interoperability. *Sensors*, v. 20, n. 23, p. 7000, 2020.
22. VAISMAN, A.; ZIMÁNYI, E. Mobility Data Warehouses. *ISPRS International Journal of Geo-Information*, v. 8, n. 4, p. 170, 2019.
23. AHMED, N.; SCHOLZ, M.; TUMP, G. A review of urban digital twins integration, challenges, and future directions in smart city development. *Sustainability*, v. 14, n. 9, p. 5688, 2022.

24. ZHAO, L.; CHEN, X.; WANG, Y. A review of machine learning-based traffic flow prediction. *Journal of Big Data*, v. 10, n. 1, p. 1-25, 2023.
25. PEZZUTO, C.; CALIÒ, C.; CALDARELLA, A. A methodological approach for using mobile phone data to analyse human mobility. *Transportation Research Procedia*, v. 52, p. 337-344, 2021.
26. KITCHIN, R. *The data revolution: Big data, open data, data infrastructures and their consequences*. Sage, 2021.
27. SINGH, S.; BANSAL, R. A review of regression and classification based machine learning models. *Machine Learning and Information Processing*, p. 531-540, 2022.