



UFOP

Universidade Federal
de Ouro Preto

**Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Departamento de Computação e Sistemas**

MobMetrics: Análise Automatizada de Dados de Mobilidade Baseada em Métricas Espaciais, Temporais e Sociais

Lucas Novais da Silva

TRABALHO DE CONCLUSÃO DE CURSO

ORIENTAÇÃO:

Tatiana Alves Costa

COORIENTAÇÃO:

Bruno Pereira dos Santos

**Setembro, 2025
João Monlevade–MG**

Lucas Novais da Silva

**MobMetrics: Análise Automatizada de Dados de
Mobilidade Baseada em Métricas Espaciais,
Temporais e Sociais**

Orientador: Tatiana Alves Costa

Coorientador: Bruno Pereira dos Santos

Monografia apresentada ao curso de Engenharia de
Computação do Instituto de Ciências Exatas e Apli-
cadas, da Universidade Federal de Ouro Preto, como
requisito parcial para aprovação na Disciplina “Traba-
lho de Conclusão de Curso II”.

Universidade Federal de Ouro Preto

João Monlevade

Setembro de 2025

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

S586m Silva, Lucas Novais da.

MobMetrics [manuscrito]: análise automatizada de dados de mobilidade baseada em métricas espaciais, temporais e sociais. / Lucas Novais da Silva. - 2025.

38 f.: il.: color., gráf., tab., mapa.

Orientadora: Profa. Dra. Tatiana Alves Costa.

Coorientador: Prof. Dr. Bruno Pereira dos Santos.

Monografia (Bacharelado). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia de Computação .

1. Aplicações Web. 2. Dados geoespaciais - Análise. 3. Internet das coisas. 4. Mobilidade social. 5. Mobilidade urbana. 6. Software de aplicação - Desenvolvimento. I. Costa, Tatiana Alves. II. Santos, Bruno Pereira dos. III. Universidade Federal de Ouro Preto. IV. Título.

CDU 004.41

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



FOLHA DE APROVAÇÃO

Lucas Novais da Silva

MobiMetrics: Análise Automatizada de Dados de Mobilidade Baseada em Métricas Espaciais, Temporais e Sociais

Monografia apresentada ao Curso de Engenharia da Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de bacharel em Engenharia da Computação

Aprovada em 04 de Setembro de 2025

Membros da banca

Profa. Dra. Tatiana Alves Costa - Orientadora - Universidade Federal de Ouro Preto
Prof. Dr. Bruno Pereira dos Santos - Co-orientador - Universidade Federal da Bahia
Prof. Dr. Paulo Henrique Lopes Rettore - Fraunhofer FKIE
Prof. Dr. Luiz Carlos Bambirra Torres - Universidade Federal de Ouro Preto

Profa. Dra. Tatiana Alves Costa, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 04/09/2025



Documento assinado eletronicamente por **Tatiana Alves Costa**, **PROFESSOR DE MAGISTERIO SUPERIOR**, em 30/10/2025, às 13:40, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0977549** e o código CRC **FB48693E**.

Este trabalho é dedicado a todos que me ajudaram durante essa jornada, e a todos os pesquisadores que possam fazer uso desta ferramenta.

Agradecimentos

Agradeço imensamente aos meus pais, Antônio Carlos e Roseni, por sempre me apoiarem nos estudos e proporcionarem um ambiente tranquilo para que eu pudesse me desenvolver, mesmo em momentos de dificuldade. Agradeço também aos meus orientadores, Bruno e Tatiana, que me proporcionaram um apoio fundamental para o desenvolvimento deste trabalho, que, por sua vez, abriu minha visão sobre análise de dados e me despertou um entusiasmo enorme a respeito deste assunto. Agradeço aos meus colegas de curso, que sem dúvida deixaram o dia a dia rodeado de desafios mais leves com todo o companheirismo. Por fim, agradeço à UFOP pela estrutura proporcionada e pelo suporte que me foi dado.

“To those like the misguided; look at the story of Man, and come to your senses! It is not the destination, but the trip that matters. What you do today influences tomorrow, not the other way around. Love Today, and seize All Tomorrows!”

— C. M. Kosemen,
in: All Tomorrows (2006)

Resumo

Para apoiar a análise de rastros de mobilidade e o processamento de métricas de mobilidade, propomos o MobMetrics, um sistema web projetado para processar e extrair métricas de mobilidade abrangentes. O sistema é uma aplicação de código aberto que permite aos usuários carregar dados brutos (dados geoespaciais ou cartesianos n -dimensionais) e obter uma ampla gama de métricas, agrupadas em quatro categorias: social, espacial, cinemática e temporal. Essas métricas permitem análises detalhadas de padrões do comportamento de movimento das entidades. Além disso, a plataforma integra uma técnica de redução de multidimensionalidade baseada em métricas e gráficos/tabelas para visualizar métricas e rastros. Como um projeto modular, fácil de estender e de código aberto, ele permite que os usuários adicionem suas próprias métricas e visualizações. Esta ferramenta mostrou potencial para aplicações como previsão de custo e tempo de deslocamentos, estimativas de consumo de combustível e emissões de carbono, além da identificação de áreas com maior concentração de tráfego, evidenciando sua utilidade em cenários reais de mobilidade urbana. Avaliamos rastros de mobilidade com diferentes características comparando entidades móveis e seus respectivos rótulos, com o objetivo de analisá-los, compará-los e agrupá-los.

Palavras-chaves: Métricas de Mobilidade. Mobilidade. Rastros. Internet das Coisas.

Abstract

To support mobility trace analysis and mobility metrics processing, we propose MobMetrics, a web-based system designed to process and extract comprehensive mobility metrics. The system is an open-source application that allows users to upload raw data (geospatial or n-dimensional Cartesian data) and obtain a wide range of metrics, grouped into four categories: social, spatial, kinematic, and temporal. These metrics allow for detailed analysis of entity movement behavior patterns. Furthermore, the platform integrates a metric-based multidimensionality reduction technique and graphs/tables to visualize metrics and traces. As a modular, easily extendable, and open-source project, it allows users to add their own metrics and visualizations. This tool has shown potential for applications such as travel time and cost prediction, fuel consumption and carbon emissions estimates, and the identification of areas with the highest traffic concentration, demonstrating its usefulness in real-world urban mobility scenarios. We evaluate mobility traces with different characteristics by comparing mobile entities and their respective labels, with the aim of analyzing, comparing, and grouping them.

Key-words: Mobility Metrics. Mobility. Traces. Internet of Things.

Lista de ilustrações

Figura 1 – Fluxo de funcionamento do <i>MobMetrics</i>	25
Figura 2 – Interface gráfica do <i>MobMetrics</i> contendo o formulário de submissão do rastro de mobilidade a ser analisado	27
Figura 3 – Visão geral do rastro <i>RJBus</i>	30
Figura 4 – Visão comparativa.	33
Figura 5 – Classificação por K-Means	34

Lista de tabelas

Tabela 1 – Trabalhos Relacionados	17
Tabela 2 – Relação entre métricas e grupos de cálculo	20
Tabela 3 – Valores dos parâmetros utilizados para o estudo de caso.	29

Lista de abreviaturas e siglas

JAS *Journey Average Speed* [Velocidade Média da Jornada]

SVC *Speed Variation Coefficient* [Coeficiente de Variação da Velocidade]

TAS *Total Average Speed* [Velocidade Média Total]

JT *Journey Time* [Tempo de Jornada]

TT *Travel Time* [Tempo de Viagem]

VTVC *Visit Time Variation Coefficient* [Coeficiente de Variação do Tempo de Visita]

AVC *Angle Variation Coefficient* [Coeficiente de Variação Angular]

JD *Journey Distance* [Distância da Jornada]

TD *Travel Distance* [Distância da Viagem]

RG *Radius of Gyration* [Raio de Giro]

SP *Stay Points* [Pontos de Parada]

SPI *Stay Point Importance Degree* [Grau de Importância de Stay Points]

TC *Trajectory Correlation* [Correlação de Trajetórias]

TADA *Travel Average Direction Angle* [Direção Média do Ângulo da Viagem]

SC *Spatial Cover* [Cobertura Espacial]

Ctt *Contacts* [Contatos]

Etp *Entropy* [Entropia]

QEtp *Quadrant Entropy* [Entropia por Quadrante]

D_{ths} *Distance Threshold* [Limiar de Distância]

T_{ths} *Time Threshold* [Limiar de Tempo]

Q_{parts} *Quadrant Parts* [Partes do Quadrante]

R_{ths} *Radius Threshold* [Limiar de Raio]

Ctt_{ths} *Contact Time Threshold* [Limiar de Contato]

Lista de símbolos

Σ	Operador de somatório
θ	Letra grega theta
σ	Letra grega sigma
$\forall$	Para todo
Δ	Letra grega delta
α	Letra grega alpha
β	Letra grega beta
γ	Letra grega gamma
μ	Letra grega mu

Sumário

1	INTRODUÇÃO	15
2	REVISÃO BIBLIOGRÁFICA	17
3	DESENVOLVIMENTO	20
3.0.1	Métricas Cinemáticas, Temporais, e Transversais	21
3.0.2	Espaciais	22
3.0.3	Sociais	24
3.0.4	Métricas Derivadas	25
3.0.5	Configuração do sistema	26
3.0.6	Visualizações	28
4	RESULTADOS	29
4.0.1	Visão Geral do <i>RJBus</i>	29
4.0.2	Visão Comparativa e Classificativa	32
5	CONCLUSÃO	35
	REFERÊNCIAS	36

1 Introdução

A mobilidade é um fator importante em nossas vidas. Quando seu entendimento é incorporado a dispositivos e sistemas computacionais, surgem aplicações mais flexíveis, adaptativas e ubíquas. A análise de padrões de mobilidade é essencial tanto para o desenvolvimento de protocolos e rotinas computacionais eficientes quanto para a identificação de entidades com comportamentos complexos, o que permite inferências em diversos domínios aplicados, como cidades inteligentes e computação ubíqua (ZISSNER et al., 2022; ULLAH et al., 2024), redes móveis e segurança (PRAJISHA; VASUDEVAN, 2025; RETTORE et al., 2025), ou processamento de alto desempenho (PRAMANIK; PAL; CHOUDHURY, 2024). No entanto, apesar da ampla aplicabilidade dessas análises, ainda são escassas as ferramentas abertas que integrem cálculo de métricas e visualizações, sendo frequente a adoção de soluções ad-hoc, limitadas a contextos específicos e de difícil reutilização.

Assim, propomos o *MobMetrics*, uma ferramenta inteligente que processa dados brutos de mobilidade e gera visualizações interativas e exportáveis. O usuário pode alimentar o *MobMetrics* com dados de mobilidade georreferenciados ou cartesianos n-dimensionais. Então, o sistema processa esses dados usando um amplo conjunto de métricas, as quais são agrupadas em quatro categorias principais: espaciais, temporais, cinemáticas e sociais. Além disso, técnicas de classificação e métodos de redução de dimensionalidade são aplicados para ampliar a capacidade de análise, detecção de padrões e apoio à tomada de decisão. Como resultado, o usuário pode interagir graficamente com o sistema, exportando suas visualizações ou dados processados em formato tabular, o que facilita o reuso e aumenta o escopo de aplicação da ferramenta.

O *MobMetrics* é open-source, desenvolvido em Python-Web através do *framework Django* (FOUNDATION, 2024) e apresenta como principal característica ser de fácil extensão, o que permite que seus usuários adicionem funcionalidades ou modifiquem módulos pré-existent. Isso se dá pois, além da organização bem definida do projeto, o *MobMetrics* também permite a integração com outras bibliotecas do Python, como de aprendizado de máquina e de inteligência artificial. Dessa forma, as principais contribuições deste trabalho são:

- *MobMetrics* um sistema de código-aberto¹ para processar, analisar e visualizar dados de mobilidade:
 - Calcula métricas espaciais, temporais, cinemáticas e sociais a partir de rastros de mobilidade;

¹ *MobMetrics* (<https://github.com/Marcio-Carvalho27/MobMetrics>)

- Usa técnicas de classificação para comparar rastros de mobilidade.
- Código-fonte e os dados disponíveis em um repositório público, com documentação para instalação e de uso básico do sistema.
- Uma interface web interativa que permite analisar e exportar dados e visualizações gerados pelo processamento.
- Um exemplo prático executável junto ao repositório do projeto, para que as principais funcionalidades possam ser facilmente testadas.

Ao possibilitar a análise de diferentes padrões de deslocamento, o *MobMetrics* também abre espaço para aplicações práticas relevantes em cenários reais. Por exemplo, suas métricas podem apoiar a previsão de custo e tempo de trajetos em transportes particulares, estimar consumo de combustível e emissões de carbono a partir de diferentes rotas, ou ainda identificar regiões críticas de tráfego pesado. Tais aplicações reforçam o papel da ferramenta não apenas como uma contribuição acadêmica, mas também como um recurso útil para planejamento urbano, mobilidade sustentável e apoio a tomadas de decisão em sistemas de transporte.

O restante desta dissertação está organizada da seguinte forma: o Capítulo 2 apresenta a revisão bibliográfica realizada para o desenvolvimento da ferramenta; o Capítulo 3 descreve o desenvolvimento da estrutura do *MobMetrics* e detalha as métricas implementadas; o Capítulo 4 apresenta os resultados obtidos através de dois casos de uso; e, por fim, o Capítulo 5 apresenta as conclusões e direções futuras.

2 Revisão bibliográfica

Ferramentas e frameworks voltados à análise de dados de mobilidade têm se tornado cada vez mais relevantes, especialmente diante da crescente disponibilidade de rastros geográficos oriundos de dispositivos móveis. Neste contexto, diferentes abordagens foram propostas para a extração de informações significativas a partir desses dados, as quais são comparadas ao **MobMetrics** na Tabela 1, destacando suas principais características e limitações.

O *Bandicoot* (MONTJOYE; ROCHER; PENTLAND, 2016) é uma biblioteca de código aberto desenvolvida em Python para extração de métricas a partir de dados de telefonia móvel. A ferramenta oferece funcionalidades de visualização individual e em grupo, análise espacial e social, além de filtros e verificações automáticas que identificam inconsistências como localizações ausentes ou datas inválidas. Embora o *Bandicoot* se destaque pela facilidade de uso e pela capacidade de tratar problemas recorrentes em dados de mobilidade, sua aplicação está restrita exclusivamente a dados de telefonia. Em contraste, o *MobMetrics* adota uma abordagem mais flexível, processando diferentes formatos de rastros geográficos, como arquivos no padrão GeoJSON e CSV, o que o torna aplicável a uma gama mais ampla de estudos e domínios.

Tabela 1 – Trabalhos Relacionados

Ferramentas	Métricas				Visualizações	Interface Web
	Sociais	Temporais	Espaciais	Cinemáticas		
Bandicoot	✓	✓	✓	-	-	-
BonnMotion	✓	▲	✓	-	-	-
MobVis	▲	▲	▲	-	▲	✓
MOCHA	▲	▲	▲	▲	-	-
MovingPandas	-	▲	✓	▲	✓	-
scikit-mobility	-	▲	▲	-	▲	-
Trackintel	-	✓	✓	-	✓	-
MoveMiner	-	✓	✓	✓	✓	-
MobMetrics	✓	✓	✓	✓	✓	✓

Legenda: ✓ = Atende totalmente ▲ = Atende parcialmente

Em (ASCHEENBRUCK et al., 2010), os autores propuseram o *BonnMotion*, uma ferramenta de código aberto desenvolvida em Java para a geração e análise de cenários de mobilidade sintética. A ferramenta implementa diversos modelos clássicos de mobilidade, como *Random Waypoint*, *SWIM (Small World in Motion)*, *Random Walk*, *Gaussian Markov*, entre outros. Assim, o *BonnMotion* é amplamente utilizado por pesquisadores interessados em simular comportamentos de mobilidade artificialmente. Diferentemente do *MobMetrics*, que opera sobre dados reais ou simulados de rastreamento e prioriza

a análise empírica da mobilidade urbana, o BonnMotion concentra-se na simulação de rastros sintéticos, sendo mais adequado para estudos baseados em cenários hipotéticos ou controlados.

Um dos trabalhos mais semelhantes nesse campo é o MobVis (SILVA et al., 2022), uma ferramenta voltada à exploração visual de dados de mobilidade, sendo o *MobMetrics* concebido como uma continuação e ampliação dessa proposta. O MobVis permite a análise de rastros por meio de visualizações. No entanto, não incorpora mecanismos de cálculo sistemático de métricas nem suporte a métodos de classificação de rastros múltiplos. Em contraste, o *MobMetrics* adota uma abordagem extensível, com foco na caracterização quantitativa dos rastros através de métricas espaciais, temporais, cinemáticas e sociais, além da integração com técnicas de classificação e modularização das análises, ampliando significativamente o potencial analítico da ferramenta.

MOCHA (SOUZA et al., 2018) é uma ferramenta de código aberto composta por módulos voltados à extração, classificação e comparação de características de rastros de mobilidade, sejam eles reais ou sintéticos. Seu principal objetivo é viabilizar comparações entre diferentes modelos de mobilidade ou entre modelos sintéticos e dados reais. Para isso, a ferramenta calcula diversas métricas espaciais, temporais e sociais, armazenadas em arquivos de saída distintos. Um de seus diferenciais é o uso da técnica *t-SNE* para comparação e redução de dimensionalidade, facilitando a identificação de padrões entre diferentes conjuntos de dados. No entanto, MOCHA apresenta limitações no que diz respeito à visualização: suas representações são restritas à comparação entre rastros, sem suporte nativo para visualizações espaciais ou temporais mais detalhadas. O *MobMetrics*, por outro lado, oferece um conjunto mais amplo de visualizações interativas, permitindo análises ricas e exploratórias tanto dos rastros quanto de seus *stay points* (veja Seção 3.0.2).

O *MovingPandas* (GRASER, 2019) é uma biblioteca Python para oferecer suporte a operações sobre dados de trajetórias. Suas funcionalidades incluem a modelagem de trajetórias, detecção de paradas e geração de visualizações interativas. Embora ofereça recursos importantes para manipulação e exploração visual de trajetórias, o *MovingPandas* é mais orientado à análise espacial interativa do que à definição sistemática de métricas de mobilidade. Em contraste, o *MobMetrics* propõe uma abordagem mais estruturada e extensível, integrando cálculo de métricas e visualizações personalizadas.

O *scikit-mobility* (PAPPALARDO et al., 2022) é uma biblioteca Python voltada à análise de mobilidade humana, com ênfase em métricas agregadas, geração de trajetórias sintéticas e avaliação de riscos de privacidade. Apesar de sua robustez analítica, o *scikit-mobility* possui foco em análises exploratórias conduzidas em *notebooks*, e não oferece suporte nativo à integração com interfaces web ou modularização de métricas personalizadas. O *MobMetrics*, por sua vez, propõe uma solução voltada à produção, com ênfase na extensibilidade das métricas e visualizações orientadas à análise comparativa

entre entidades.

O Trackintel ([MARTIN et al., 2023](#)), é uma biblioteca em Python voltada para a análise de dados espaço-temporais de mobilidade individual, sem foco em métricas sociais. Por outro lado, o MobMetrics também realiza a identificação de pontos de parada (*stay points*) e oferece um conjunto mais amplo de métricas e permite a análise de interações entre entidades, como a identificação de contatos. Ambas as ferramentas possuem recursos de visualização.

O MoveMiner ([OLIVEIRA et al., 2025](#)) é uma biblioteca em Python recente e proposta para atacar boa parte dos problemas deste escopo. Esta ferramenta oferece módulos para pré-processamento, processamento e visualização de rastros de mobilidade geoespaciais. Apesar de ser bastante robusta, ter uma boa performance e apresentar muitas possibilidades de análise, o MoveMiner não conta com uma interface web ou um módulo comparativo e classificativo de múltiplos rastros.

Portanto, o presente trabalho se destaca por oferecer uma infraestrutura unificada para o processamento, cálculo e visualização de métricas de rastros, aliando flexibilidade e modularidade, aspectos ainda pouco integrados nas soluções existentes.

3 Desenvolvimento

Neste capítulo, apresentamos o processo de desenvolvimento da ferramenta *MobMetrics*, com foco tanto nos conceitos que fundamentam sua implementação quanto em sua estrutura interna. Inicialmente, evidenciaremos de forma resumida as etapas para construção do *MobMetrics*, e em seguida descreveremos as métricas de mobilidade incorporadas à ferramenta, destacando seus objetivos e formas de cálculo. Após, será detalhada a organização do *MobMetrics*, abordando os módulos que o compõem e o funcionamento do *pipeline* de execuções, de modo a evidenciar como as diferentes etapas se integram para possibilitar a análise sistemática dos rastros de mobilidade.

O desenvolvimento da ferramenta teve início logo após a revisão bibliográfica, com a criação de um projeto em Django e a definição da organização em módulos separados por pastas, o que permitiu estruturar desde o início um ambiente coerente e preparado para futuras extensões por parte de outros usuários. As primeiras implementações concentraram-se no cálculo das métricas de mobilidade, de modo a garantir a consolidação do núcleo funcional da ferramenta. Em seguida, foi elaborada a interface web para configuração dos parâmetros necessários às análises, estabelecendo a camada de interação com o usuário. Posteriormente, realizou-se a integração entre o *front-end* e o *back-end*: o *front-end* assumiu a responsabilidade de coletar parâmetros e exibir os resultados das métricas, enquanto o *back-end* passou a processar esses parâmetros, calcular as métricas e retornar tanto os valores numéricos quanto os resultados gráficos em formato HTML. Por fim, foram programadas funções específicas para organizar e disponibilizar esses resultados ao *front-end*, assegurando a apresentação clara e sistemática das análises realizadas.

A partir disso, será apresentado a seguir uma descrição das métricas implementadas nativamente no *MobMetrics*, apresentando os parâmetros necessários e os respectivos métodos de cálculo. Do ponto de vista funcional, as métricas podem ser classificadas em **Locais**, que analisam o comportamento individual de uma entidade, e **Globais**, voltadas à análise conjunta de múltiplas entidades. Há também métricas **Mistas**, cujo uso pode variar entre contextos individuais ou coletivos, conforme a forma de aplicação. Além disso, algumas métricas não se referem diretamente aos rastros das entidades, mas a métricas pré-calculadas, como é o caso do *Grau de Importância de um Stay Point* (veja Seção 3.0.2).

Tabela 2 – Relação entre métricas e grupos de cálculo

			Cinemáticas			Temporais			Espaciais								Sociais		
Grupos		JAS	SVC	TAS	JT	TT	VTVC	AVC	JD	TD	RG	SP	SPI	TC	TADA	SC	Ctt	Etp	QEtp
Métricas Locais		x	x	x	x	x	x	x	x	x	x	x	-	-	x	x	x	-	x
Métricas Globais		-	x	-	-	-	x	x	-	-	-	-	-	x	-	x	-	-	x

A Tabela 2 apresenta um panorama das métricas implementadas e suas classificações.

Complementarmente, as métricas são organizadas de acordo com o tipo de informação que analisam, sendo agrupadas em quatro categorias principais: **Espaciais**, **Temporais**, **Cinemáticas** e **Sociais**. Essa estrutura visa facilitar a caracterização abrangente dos padrões de mobilidade observados nos rastros.

3.0.1 Métricas Cinemáticas, Temporais, e Transversais

Determinadas métricas compartilham conceitos similares entre diferentes categorias, o que justifica sua apresentação conjunta neste capítulo. No *MobMetrics*, os deslocamentos das entidades são segmentados em duas formas principais: *jornadas* e *viagens*. A partir dessas segmentações, são calculadas métricas associadas ao tempo, à distância percorrida e à velocidade média, permitindo uma análise mais refinada da dinâmica de mobilidade.

- **Métricas de Jornada:** as métricas de Tempo: *Journey Time* [Tempo de Jornada] (**JT**); Distância: *Journey Distance* [Distância da Jornada] (**JD**); e Velocidade Média: *Journey Average Speed* [Velocidade Média da Jornada] (**JAS**) são classificadas, respectivamente, como métricas temporais, espaciais e cinemáticas. Elas representam o tempo total, a distância percorrida e a velocidade média em cada *journey* das entidades.
- **Métricas de Viagem:** as métricas de Tempo: *Travel Time* [Tempo de Viagem] (**TT**); Distância: *Travel Distance* [Distância da Viagem] (**TD**); e Velocidade Média: *Total Average Speed* [Velocidade Média Total] (**TAS**) seguem a mesma classificação (temporal, espacial e cinemática, respectivamente) e representam os mesmos aspectos, mas segmentados por *travel* em vez de *journey*.

É importante destacar que as diferenças conceituais entre jornadas e viagens serão evidenciadas mais a frente neste capítulo. Além disso, três métricas utilizam o conceito estatístico de coeficiente de variação para quantificar a variabilidade de diferentes aspectos do deslocamento:

- ***Speed Variation Coefficient*** [Coeficiente de Variação da Velocidade] (**SVC**) (**CAVALCANTI; SPOHN**,): razão entre o desvio padrão e a média das velocidades observadas ao longo do rastro; útil para identificar variações de ritmo durante o deslocamento.
- ***Angle Variation Coefficient*** [Coeficiente de Variação Angular] (**AVC**): mede a variabilidade na direção de deslocamento da entidade, com base nos ângulos entre pares consecutivos de pontos.

- **Visit Time Variation Coefficient** [Coeficiente de Variação do Tempo de Visita] (**VTVC**): avalia a consistência dos tempos de permanência em diferentes *stay points*, indicando se há padrões regulares ou irregulares de visita.

Apesar da semelhança na fórmula geral (σ/μ), essas métricas têm finalidades distintas e pertencem a categorias diferentes (cinemáticas, espaciais e temporais), refletindo diferentes aspectos do comportamento das entidades.

3.0.2 Espaciais

Esse grupo de métricas foca na distribuição geográfica dos rastros, analisando cobertura e dispersão espacial.

Travel Average Direction Angle [Direção Média do Ângulo da Viagem] (**TADA**)

A métrica **TADA** representa o ângulo médio de deslocamento da entidade ao longo do rastro, medido em relação ao norte geográfico. Para cada par de pontos consecutivos, é calculado o ângulo de direção e, posteriormente, é obtida a média desses valores considerando o círculo trigonométrico.

$$TADA = \frac{\sum_{i=1}^m \theta_i}{m}$$

, onde θ_i é o ângulo de direção entre os pontos i e $i + 1$ ao longo do rastro, e m representa o número total de pares consecutivos de pontos.

Essa métrica é utilizada, por exemplo, no cálculo do Coeficiente de Variação do Ângulo.

Trajectory Correlation [Correlação de Trajetórias] (**TC**)

Esta métrica calcula o grau de similaridade entre trajetórias de um rastro através do método da semelhança dos cossenos. Esta medida pode ser encontrada através da fórmula abaixo:

$$TC = 1 - \sigma (1 - \cos(\mathbf{v}_i, \mathbf{v}_j))$$

$$\forall i < j$$

Em que a correlação de trajetórias é dada por 1 menos o desvio padrão do inverso da similaridade dos cossenos de todos os pares de trajetórias realizadas por uma entidade no rastro.

Stay Points [Pontos de Parada] (SP)

Esta métrica representa locais onde a entidade permaneceu por um período mínimo de tempo (ZHENG et al., 2009). Para identificá-los, dois parâmetros são necessários: *Distance Threshold* [Limiar de Distância] (D_{ths}) e *Time Threshold* [Limiar de Tempo] (T_{ths})

Um *Stay Point* P é um conjunto ordenado de pontos $P = \{p_1, p_2, \dots, p_n\}$ que satisfaz:

$$\forall 1 \leq i \leq n, \|p_1 - p_i\| \leq D_{ths}$$

$$\Delta T_P \geq T_{ths}.$$

Ou seja, todos os pontos de P estão a, no máximo, D_{ths} de p_1 , e o tempo total ΔT_P é igual ou superior a T_{ths} .

Stay Point Importance Degree [Grau de Importância de Stay Points] (SPI)

Essa métrica é responsável por calcular o Grau de Importância de um *Stay Point*, levando em consideração métricas relacionadas a esse ponto.

$$SPI = \alpha \cdot (1 - Etp) + \beta \cdot T_{visits} + \gamma \cdot Ctt_{sp}$$

, onde T_{visits} é o tempo total de visitas ao *stay point*, Ctt_{sp} é o número de contatos na região, e Etp representa a entropia associada ao *stay point*.

Os valores de α , β e γ são parâmetros que definem o peso relativo de cada uma das métricas na composição do SPI, respeitando que $\gamma > \alpha > \beta$, sendo assim, esses valores são definidos como 0,4, 0,4 e 0,2, respectivamente. Vale mencionar que estes valores padrões podem mudar a depender da aplicação do usuário, sendo permitido pelo *MobMetrics* a customização desta relação.

Radius of Gyration [Raio de Giro] (RG)

O RG (GONZALEZ; HIDALGO; BARABASI, 2008) é o raio do círculo centrado no ponto médio do rastro que contém a maior parte dos deslocamentos da entidade:

$$RG = \sqrt{\frac{1}{N} \sum_{i=1}^k \|t_i - t_m\|^2}$$

em que $T = \{t_1, t_2, \dots, t_k\}$, t_m é o centro de massa da viagem e N o número de pontos.

Spatial Cover [Cobertura Espacial] (SC)

A cobertura espacial é uma métrica derivada da Entropia por Quadrante, ambos são calculados juntos, onde é contado quantos dos n quadrantes diferentes uma entidade visitou, O valor de n decorre do parâmetro *Quadrant Parts* [Partes do Quadrante] (Q_{parts}) informado pelo usuário, como visto na Figura 2: se cada eixo é dividido em Q_{parts} partes e há 2 eixos (2D), então $n = Q_{parts}^2$.

Ela permite o calculo da cobertura espacial total, contando com todos os rastros e também a cobertura espacial de cada entidade.

3.0.3 Sociais

Esse grupo de métricas busca quantificar interações entre entidades, considerando proximidade, encontros e padrões de co-presença.

Contacts [Contatos] (Ctt)

O cálculo dos Ctts (SILVA et al., 2022) exige o parâmetro *Radius Threshold* [Limiar de Raio] (R_{ths}), definido pelo usuário no momento da submissão (Fig. 2). Considerando R_{ths} , há contato entre duas entidades quando, em um mesmo *timestamp*:

$$\|e_n - e_m\| \leq R_{ths},$$

em que e_m e e_n são pontos de entidades distintas.

Para reduzir o custo computacional da verificação quadrática entre todos os pares, o *MobMetrics* filtra os rastros por *timestamp*, ignorando instantes com apenas uma entidade e evitando comparações desnecessárias.

Essa abordagem detecta apenas contatos instantâneos. Para identificar contatos contínuos, utiliza-se o parâmetro *Contact Time Threshold* [Limiar de Contato] (Ctt_{ths}), que agrupa contatos sucessivos em um mesmo evento caso o intervalo entre eles seja menor ou igual a Ctt_{ths} .

Entropy [Entropia] (Etp)

A Entropia (HRISTOVA et al., 2016), calculada para *stay points*, mede a diversidade de movimentos de um ponto P e baseia-se na entropia de Shannon:

$$Etp = -\log_2(p(P)), \quad p(P) = \frac{V(P)}{V_t},$$

em que $V(P)$ é o número de visitas a P e V_t o total de visitas a todos os *stay points*.

Quadrant Entropy [Entropia por Quadrante] (QEtp)

Derivada da Entropia por *Stay Point*, a QEtp divide o rastro em n quadrantes e calcula a entropia para cada um. O valor de n é igual ao apresentado na métrica Cobertura Espacial.

3.0.4 Métricas Derivadas

Algumas métricas podem ser derivadas de outras já definidas. Por exemplo, Métricas Locais podem ser agregadas por meio da média para compor Métricas Globais. Além disso, certas informações, como o tempo de permanência em *Stay Points* ou o número de jornadas identificadas, embora não sejam métricas no sentido estrito, podem fornecer *insights* relevantes para a análise de mobilidade, esses são fatores encontrados ao calcular outras métricas.




Figura 1 – Fluxo de funcionamento do *MobMetrics*

O *MobMetrics* está organizado conforme apresentado na Figura 1. Para fins de simplificação, apresentamos com maior profundidade as duas partes principais do *MobMetrics*. Assim, as Seções 3.0.5 e 3.0.6 discorrem a nível de interface, indicando o que o usuário

precisa para executar o *MobMetrics* e quais são as visualizações obtidas como resultado. O Capítulo 4 apresenta um estudo exploratório através de um caso de uso.

3.0.5 Configuração do sistema

O *MobMetrics* precisa que alguns parâmetros sejam configurados para sua correta operação. Os parâmetros são apresentados a seguir.

Formulário de Upload

A Figura 2 ilustra o formulário de submissão e os parâmetros de configuração do *MobMetrics*.

- *Trace File*: arquivo de rastro a ser analisado, no formato *.csv*, contendo as colunas *id*, *x*, *y*, *z* e *time*. *id* refere-se a uma identificação única a qual a entidade em questão está associada. Os parâmetros *x*, *y* e *z* indicam uma coordenada geográfica ou cartesiana da entidade. E, *time* refere-se a uma marca de tempo, esta pode ser em formato *DateTime* ou uma marcação temporal em segundos. Caso as colunas *id* e *z* estejam ausentes, automaticamente será atribuído o identificador 1 para toda o rastro (assumindo tratar-se de uma única entidade) e o valor 0 para a coordenada *z*.
- *Name*: nome definido pelo usuário para salvar o rastro no banco de dados, permitindo diferenciá-lo de outros rastros.
- *Label*: tipo de entidade representada no rastro (por exemplo, carro, pessoa ou celular).
- *Geographical Coordinates*: deve ser marcado se as coordenadas forem geográficas (latitude e longitude). Nesse caso, cálculos de distâncias consideram a curvatura da terra (cálculo de *Haversine* (SCRIPTS, 2002)); caso contrário, é utilizada a distância Euclidiana (ANTON; BIVENS; DAVIS, 2013).

Ressalta-se que esta é uma lista não exaustiva de parâmetros. Outras métricas descritas no Capítulo 3 também requerem parametrizações específicas para sua correta execução.

Pré-Processamento

Esta etapa realiza a formatação dos dados, além de um cálculos de determinadas métricas:

- *Stay Points*: Essa métrica está entre as primeiras etapas de execução no *MobMetrics*, pois seu resultado é utilizado de forma transversal por outras métricas ao longo do

The image shows a web form for MobMetrics. It has several sections:

- Trace File:** A button labeled 'Choose File' and a text box showing 'No file chosen'.
- Name:** A text input field.
- Label:** A text input field.
- Geographical Coordinates:** A checkbox.
- Stay Point Parameters:** A section containing 'Distance Threshold' and 'Time Threshold' text input fields.
- Contact Parameters:** A section containing a 'Radius Threshold' text input field.
- Entropy Parameters:** A section containing a 'Quadrant Divisions' text input field.

 Each input field has a question mark icon to its right.

Figura 2 – Interface gráfica do *MobMetrics* contendo o formulário de submissão do rastro de mobilidade a ser analisado

processamento. O *MobMetrics* se preocupa em evitar *Stay Points* repetidos, assim, ao encontrar um novo *Stay Point*, o sistema busca em um banco de dados outro *Stay Point* que esteja suficientemente próximo e seja referente ao mesmo rastro de mobilidade. Se existir, isto é, a distância entre o ponto central dos dois for menor ou igual ao D_{ths} , entende-se que ambos representam o mesmo local e o “novo” *Stay Point* é registrado como uma *Visita* ao ponto pré-existente.

- ***Travels* e *Journeys*:** Essa distinção conceitual diferencia dois níveis de segmentação do deslocamento, calculados durante a etapa de pré-processamento. As *Travels* representam o trajeto completo percorrido por uma entidade, do primeiro ao último ponto registrado. Já as *Journeys* correspondem aos trechos entre dois *Stay Points* consecutivos, permitindo uma análise mais detalhada dos deslocamentos entre locais de permanência.

Assim, caso o início do rastro de uma entidade não esteja associado a um *Stay Point* e/ou o final também não, o *MobMetrics* considera como *Journey* o trecho entre o ponto inicial e o primeiro *Stay Point*, e/ou entre o último *Stay Point* e o ponto final do rastro.

- **Centro da Trajetória:** Calculado durante a etapa de pré-processamento, corresponde ao ponto médio obtido a partir de todos os pontos do rastro de uma entidade. Esse centro é utilizado como referência no cálculo do RG , servindo como base para medir a dispersão espacial do deslocamento.
- **Perfil de Mobilidade:** Calculado durante o pré-processamento, o perfil de mobi-

lidade corresponde a uma média normalizada, entre 0 e 1, das métricas extraídas para um rastro. Esse valor sintetiza, de forma compacta, o comportamento geral da entidade ao longo do deslocamento.

Calculo das Métricas

Nesta fase, todas as métricas descritas em detalhe no Capítulo 3 são calculadas com base nos dados pré-processados e nos parâmetros fornecidos pelo usuário. Os resultados dessas métricas são então armazenados em estruturas de dados persistentes, por meio dos *Models* do framework *Django*, o que garante sua integridade, reutilização e disponibilidade para visualizações posteriores ou análises adicionais dentro do sistema.

3.0.6 Visualizações

Para possibilitar a análise dos rastros, o *MobMetrics* dispõe de visualizações. Os elementos visuais são organizados em diferentes categorias, conforme a natureza dos dados apresentados.

- **Visualizações do Rastro Bruto:** Essas visualizações são responsáveis por exibir os rastros das entidades individualmente, bem como em comparação com outras entidades presentes no mesmo arquivo, quando aplicável.

O objetivo principal é permitir a inspeção visual dos deslocamentos e *Stay Points* ao longo do tempo.

- **Visualizações de Métricas:** Essas visualizações têm como foco a análise quantitativa dos rastros a partir das métricas calculadas. Tais visualizações podem ser utilizadas para comparar comportamentos entre entidades, identificar padrões estatísticos e avaliar desvios em relação a referências.
- **Visualizações Sociais:** Este grupo contempla visualizações voltadas à análise das interações entre entidades, permitindo investigar aspectos de contato, proximidade e comportamento coletivo ao longo do tempo e do espaço.
- **Visualizações Comparativas:** As visualizações comparativas utilizam técnicas de redução de dimensionalidade e agrupamento para representar relações entre entidades com base em múltiplas métricas. São especialmente úteis para explorar a estrutura dos dados e detectar padrões não triviais.

4 Resultados

De modo geral, analisar conjuntos de dados requer um processamento inicial para posterior avaliação através de indicadores e gráficos. Dessa forma, aqui apresentamos um caso de uso do *MobMetrics*, aplicando a ferramenta sobre rastros de três fontes diferentes: i) um conjunto de amostras do *Microsoft GeoLife* (ZHENG; XIE; MA, 2010) classificados pela natureza do movimento (carro, táxi, ônibus e caminhar); ii) uma coleção de dados de GPS públicos coletados a partir do *OpenStreetMap*, também classificados pelo tipo de movimento; iii) uma amostra do conjunto de dados de ônibus da cidade do Rio de Janeiro, obtidos a partir do *Kaggle*. Portanto, a ferramenta será aplicada para a obtenção de *insights* sobre dados veiculares (tanto carros pessoais quanto táxis), dados de transporte público (ônibus) e dados de pessoas caminhando em centros urbanos.

Sendo assim, todos os rastros apresentam localidades diferentes, no entanto, a diferença da dimensão original de cada conjunto fez com que as amostras precisassem ser geradas de tal forma que a quantidade de informação fosse compatível, ou seja, o número de pontos presente em cada conjunto de dados ser semelhante. Para isso, cada um dos *datasets* apresenta um intervalo de tempo de duas semanas, e reflete o movimento de 20 entidades distintas, bem como um grão de amostragem temporal semelhante.

Tabela 3 – Valores dos parâmetros utilizados para o estudo de caso.

Parâmetros	GL e OSM (Caminhar)	GL e OSM (Carros)	GL e OSM (Ônibus)	RJBus (Ônibus)
D_{ths}	20 m	25 m	30 m	35 m
T_{ths}	160 s	180 s	180 s	180 s
CR_{ths}	18 m	24 m	30 m	34 m
Q_{div}	20	20	20	20


A Tabela 3 apresenta os valores utilizados nos parâmetros de configuração mencionados na Seção 3.0.5. Os rastros de mesma natureza foram agrupados em parâmetros iguais, com exceção do *dataset* de ônibus da cidade do Rio de Janeiro. Dessa forma, além de uma amostragem balanceada, as configurações de extração das medidas também foram equilibradas, de modo a evidenciar as diferenças inerentes aos movimentos das entidades. A partir disso, o *MobMetrics* foi utilizado para analisar os rastros sobre dois aspectos diferentes: i) uma visão geral das diferentes frotas de ônibus presentes no conjunto de dados do Rio de Janeiro e ii) uma visão comparativa e classificativa de diferentes rastros de acordo com as características próprias da natureza de cada meio de locomoção.

4.0.1 Visão Geral do RJBus


Para apresentar uma visão geral do *dataset* de ônibus do Rio de Janeiro, temos indicado na Figura 3 uma sequência de gráficos gerados a partir de eixos cuidadosamente




(a) Rastro completo



(b) Relação espacial



(c) Relação espaço-social



(d) Relação temporal

Figura 3 – Visão geral do rastreo *RJBus*.

escolhidos. Na Figura 3a, apresentamos uma visão do mapa do Rio de Janeiro com todas as entidades de linhas de ônibus distribuídas por todas as rotas percorridas, em que cada linha individual é separada por uma cor. Esta visão é a primeira que é gerada após os cálculos das métricas, e sua exibição no início do *dashboard* de resultados permite ao usuário ter uma visão geral de como as entidades estão distribuídas no mapa, também podendo ser utilizada como referência geográfica de alguns resultados numéricos obtidos a partir das métricas e gráficos puramente analíticos.

A Figura 3b apresenta uma visão descritiva dos rastros, combinando uma visualização espacial com a análise de métricas extraídas para cada entidade (ônibus). A subfigura que mostra o *scatterplot* tridimensional (Cobertura Espacial $\times$ Distância Média das Jornadas $\times$ Número de Jornadas) revela padrões relevantes sobre o comportamento operacional dos ônibus monitorados. Observa-se uma concentração significativa de entidades com jornadas médias curtas (entre 2.000 e 8.000 metros), sugerindo a predominância de linhas de menor extensão, possivelmente voltadas a trajetos locais ou alimentadores de terminais.

Em relação à Cobertura Espacial, embora haja uma distribuição relativamente uniforme ao longo do eixo, nota-se uma leve concentração de ônibus com menor alcance territorial, o que pode refletir restrições geográficas ou operacionais. No que diz respeito ao Número de Jornadas, destaca-se que os veículos com maior volume de jornadas tendem a operar em rotas com menor cobertura espacial, o que pode indicar um uso mais intensivo de linhas curtas em regiões centrais ou de alta demanda. Por outro lado, as entidades que apresentam maior cobertura espacial, em geral, realizaram um número reduzido de jornadas, indicando linhas de longa distância ou itinerários intermunicipais, menos frequentes ao longo do dia. Ressalta-se, ainda, a presença de *outliers* com distâncias médias superiores a 15.000 metros, e um caso extremo em torno de 30.000 metros, que, no entanto, realizaram pouquíssimas jornadas, o que reforça a hipótese de se tratarem de rotas atípicas, testes operacionais ou linhas especiais com baixa recorrência.

Na Figura 3c, temos uma visão restrita a um grupo pequeno de linhas de ônibus, que foram selecionadas manualmente através de alguns parâmetros de configuração do *MobMetrics* (específicos para a seção de *analytics*) dado o critério de maior número de *stay-points* visitados. Esta visualização foi construída de tal modo que, no eixo y, temos o número total de contatos realizados pelo ônibus, distribuídos ao longo da dimensão x. Além disso, no eixo das cores, temos indicados o número de vezes que cada linha visitou um ponto de interesse no mapa. O *insight* que este mapa traz está de acordo com o comportamento esperado de que, quanto mais vezes uma entidade passa por um *stay-point*, maiores as chances de acontecerem contatos, principalmente se considerarmos a possibilidade dos *stay-points* representarem algumas estações de integração (trocas de linhas) da cidade. Dessa forma, o gráfico de barras indica que existe uma relação diretamente proporcional entre o número de contatos e o número de vezes que uma linha passa por um ponto de interesse detectado.

Por fim, a última Figura 3d apresenta um *boxplot* referente ao Tempo Médio de Jornada (em segundos) para cada entidade presente na amostra do rastro RJBus. A distribuição observada evidencia uma forte assimetria positiva, com a maioria dos ônibus operando em jornadas médias de até 3.000 segundos (equivalente a 50 minutos), o que sugere a predominância de rotas de curta ou média duração no conjunto analisado. A mediana, situada em torno de 650 segundos (aproximadamente 11 minutos), indica que pelo menos metade das entidades realizaram viagens significativamente curtas, compatíveis com deslocamentos em áreas urbanas densas ou trajetos circulares. A parte inferior do *boxplot* é bastante curta, refletindo uma baixa variabilidade entre os menores tempos médios, enquanto a parte superior se estende até valores próximos a 4.000 segundos, sugerindo maior dispersão entre as entidades com jornadas mais longas. Os *outliers* identificados, especialmente os que ultrapassam os 4.000, 6.000 e até 12.000 segundos, indicam a presença de linhas atípicas, possivelmente rotas de longa distância, intermunicipais, ou com baixa frequência de operação. Esses casos extremos, apesar de minoritários, ressaltam

a diversidade operacional do sistema de transporte analisado e reforçam a importância de considerar a distribuição completa ao interpretar métricas agregadas como o tempo médio de jornada.

4.0.2 Visão Comparativa e Classificativa

Agora, iremos discorrer sobre uma avaliação comparativa e classificativa dos rastros mencionados no início desta seção. O objetivo desta análise é agrupar os *traces* com base nos meios de locomoção, a partir das propriedades fundamentais de cada movimento (destacadas por meio das métricas). Dessa forma, nas Figuras 4a e 4b, podemos observar dois *scatterplots* gerados para uma coleção de conjuntos diferentes de rastros, nomeados para indicar tanto o *dataset* de origem quanto o tipo de deslocamento envolvido, além disso, implementamos na ferramenta uma forma de colorir os pontos de acordo com o tipo de locomoção presente nas *labels* dadas a cada conjunto de dados. Com base nisso, a metodologia utilizada para compor estes gráficos foi que, a partir do *front-end* do *MobMetrics*, foram selecionados dois conjuntos de métricas para construir cada uma das duas componentes presentes no gráfico (variemos essas componentes do 4a para o 4b).

A Figura 4a evidencia padrões distintos de mobilidade ao combinar métricas espaciais e sociais para diferentes tipos de deslocamento. No eixo y, que agrega métricas relacionadas à distância percorrida e ao raio médio de giro, observa-se uma clara separação entre os rastros veiculares (carros, táxis e ônibus) e os rastros de indivíduos caminhando. Essa separação indica que, em geral, veículos percorrem trajetos significativamente mais longos e apresentam movimentos menos angulosos, refletindo deslocamentos contínuos em vias estruturadas. Em contraste, os rastros de caminhada tendem a cobrir distâncias menores e com maior variabilidade direcional, resultando em menores valores nesta componente. Já o eixo x, composto por métricas sociais como o número e a duração total de contatos, revela nuances mais sutis. Nota-se uma leve separação entre os rastros de carros particulares e os demais veículos, sugerindo que automóveis tendem a compartilhar mais tempo em proximidade com outras entidades do mesmo tipo, possivelmente devido a congestionamentos ou rotas sobrepostas. Por outro lado, ônibus e táxis se agruparam mais fortemente nesse eixo, indicando comportamentos de contato mais homogêneos e, possivelmente, operacionais. Observa-se que, os rastros de caminhada posicionaram-se próximos aos ônibus e táxis em termos de interação social, revelando que, apesar da diferença espacial, os indivíduos a pé compartilham ambientes de mobilidade com níveis similares de contato ou proximidade temporal com outras entidades.

Na Figura 4b, a análise combinada de componentes topológicas (eixo y) e de deslocamento (eixo x) permite uma nova perspectiva sobre a diferenciação dos rastros. No eixo y, que reúne métricas relacionadas à estrutura topológica dos trajetos, como o número de *stay-points* e o grau de entropia dos quadrantes explorados, observamos que os




Figura 4 – Visão comparativa.

rastros de ônibus se destacam com os maiores valores, posicionando-se na parte superior do gráfico. Esse comportamento sugere uma maior diversidade espacial e presença em pontos de parada bem definidos, características típicas de linhas de transporte coletivo. Rastros de carros e táxis aparecem agrupados mais abaixo, com valores topológicos moderados, refletindo trajetos contínuos e menos estruturados. Os rastros de caminhada, por sua vez, posicionam-se entre essas duas categorias, ligeiramente acima dos veículos particulares, indicando que, embora os deslocamentos a pé explorem diferentes áreas do espaço urbano, tendem a gerar padrões topológicos menos complexos do que os percorridos por ônibus. No eixo x, que agrega métricas relacionadas ao deslocamento, como velocidade média, tempo médio de jornada e cobertura espacial, a separação entre os modos de transporte é mais acentuada. Os rastros de caminhada ocupam a extremidade esquerda, com os menores valores, refletindo deslocamentos mais lentos, curtos e localizados. Em seguida, aparecem os ônibus, com valores intermediários, e, por fim, os veículos particulares (carros e táxis) na extremidade direita do gráfico, indicando maior velocidade, alcance espacial e tempo médio de jornada. Esse arranjo sugere que as métricas selecionadas para essa visualização foram eficazes em capturar tanto a estrutura quanto a dinâmica dos diferentes modos de transporte.




Figura 5 – Classificação por K-Means

A Figura 5 demonstra a capacidade do *MobMetrics* de realizar agrupamentos de forma automática, sem intervenção do usuário na escolha das componentes. Para isso, foi fixado um subconjunto de métricas previamente selecionadas com base em seu potencial discriminativo entre os tipos de locomoção, e então aplicado o algoritmo *K-Means* sobre esses dados. As duas principais componentes extraídas automaticamente foram utilizadas para gerar o *scatterplot*, no qual os pontos foram coloridos com base nos agrupamentos identificados pelo próprio algoritmo. O resultado obtido evidencia a eficácia da abordagem: os rastros foram majoritariamente classificados em três grupos distintos, correspondentes a ônibus, caminhadas e veículos particulares (carros e táxis).

5 Conclusão

Neste trabalho, apresentamos o *MobMetrics*, uma ferramenta de código aberto para processamento e análise de rastros de mobilidade. A proposta visa suprir a ausência de soluções unificadas e extensíveis voltadas para a extração de métricas espaciais e temporais a partir de dados de localização. O *MobMetrics* diferencia-se por oferecer uma arquitetura modular, que permite tanto o uso direto de métricas pré-implementadas quanto a inclusão de novas métricas por meio de um modelo extensível e bem documentado.

O sistema já contempla uma ampla gama de métricas fundamentais para o estudo de mobilidade, incluindo velocidade, distância, direção, pontos de parada e contatos entre entidades. Além disso, disponibiliza uma interface de visualização interativa que facilita a exploração dos dados e dos resultados obtidos.

Como trabalhos futuros, destacamos três principais direções de desenvolvimento: suporte a múltiplos formatos de entrada, adição de novas métricas e novas visualizações.

Referências

- ANTON, H.; BIVENS, I. C.; DAVIS, S. *Cálculo com Geometria Analítica*. 9. ed. São Paulo: LTC, 2013. ISBN 9788521621226. Citado na página 26.
- ASCHEENBRUCK, N. et al. Bonnmotion: a mobility scenario generation and analysis tool. In: *Proceedings of the 3rd international ICST conference on simulation tools and techniques*. [S.l.: s.n.], 2010. p. 1–10. Citado na página 17.
- CAVALCANTI, E. R.; SPOHN, M. A. Aplicando métricas de mobilidade na classificação de rastros de movimento em manets. Citado na página 21.
- FOUNDATION, D. S. *Django Web Framework*. 2024. <<https://www.djangoproject.com/>>. Acessado em mai. 2025. Citado na página 15.
- GONZALEZ, M. C.; HIDALGO, C. A.; BARABASI, A.-L. Understanding individual human mobility patterns. *nature*, Nature Publishing Group UK London, v. 453, n. 7196, p. 779–782, 2008. Citado na página 23.
- GRASER, A. Movingpandas: efficient structures for movement data in python. *GIForum*, v. 1, p. 54–68, 2019. Citado na página 18.
- HRISTOVA, D. et al. Measuring urban social diversity using interconnected geo-social networks. In: *Proceedings of the 25th international conference on world wide web*. [S.l.: s.n.], 2016. p. 21–30. Citado na página 24.
- MARTIN, H. et al. Trackintel: An open-source python library for human mobility analysis. *Computers, Environment and Urban Systems*, Elsevier, v. 101, p. 101938, 2023. Citado na página 19.
- MONTJOYE, Y.-A. D.; ROCHER, L.; PENTLAND, A. S. bandicoot: A python toolbox for mobile phone metadata. *Journal of Machine Learning Research*, v. 17, n. 175, p. 1–5, 2016. Citado na página 17.
- OLIVEIRA, E. et al. Moveminer: A scalable and modular library for mining trajectory data. In: *GeoInfoBR 2025 – Proceedings of the GeoInfo Brasil*. : , 2025. p. . Citado na página 19.
- PAPPALARDO, L. et al. Scikit-mobility: A python library for the analysis, generation, and risk assessment of mobility data. *Journal of Statistical Software*, v. 103, p. 1–38, 2022. Citado na página 18.
- PRAJISHA, C.; VASUDEVAN, A. MSecTrust: A Mobility-Aware Secure Trust-Based Routing Protocol for RPL Based Internet of Things. *Journal of Network and Systems Management*, Springer, v. 33, n. 2, p. 40, 2025. Citado na página 15.
- PRAMANIK, P. K. D.; PAL, S.; CHOUDHURY, P. Mobile crowd computing: potential, architecture, requirements, challenges, and applications. *The Journal of Supercomputing*, Springer, v. 80, n. 2, p. 2223–2318, 2024. Citado na página 15.

- RETTORE, P. H. et al. Military IoT from Management to Perception: Challenges and Opportunities Across Layers. *IEEE Internet of Things Magazine*, IEEE, v. 8, n. 2, p. 25–31, 2025. Citado na página 15.
- SCRIPTS, M. T. *Haversine Formula*. 2002. <<https://www.movable-type.co.uk/scripts/latlong.html>>. Acessado em 15 de maio de 2025. Citado na página 26.
- SILVA, L. N. et al. Mobvis: A framework for analysis and visualization of mobility traces. In: *2022 IEEE Symposium on Computers and Communications (ISCC)*. [S.l.: s.n.], 2022. p. 1–6. Citado 2 vezes nas páginas 18 e 24.
- SOUZA, F. R. de et al. Mocha: A tool for mobility characterization. In: *Proceedings of the 21st ACM International Conference on Modeling, Analysis and Simulation of Wireless and Mobile Systems*. [S.l.: s.n.], 2018. p. 281–288. Citado na página 18.
- ULLAH, I. et al. Ubiquitous computation in internet of vehicles for human-centric transport systems. *Computers in Human Behavior*, Elsevier, v. 161, p. 108394, 2024. Citado na página 15.
- ZHENG, Y.; XIE, X.; MA, W.-Y. Geolife: A collaborative social networking service among user, location and trajectory. *IEEE Data Eng. Bull.*, v. 33, n. 2, p. 32–39, 2010. Citado na página 29.
- ZHENG, Y. et al. Mining interesting locations and travel sequences from gps trajectories. In: *Proceedings of the 18th international conference on World wide web*. [S.l.: s.n.], 2009. p. 791–800. Citado na página 23.
- ZISSNER, P. et al. Road traffic density estimation based on heterogeneous data fusion. In: IEEE. *2022 IEEE Symposium on Computers and Communications (ISCC)*. [S.l.], 2022. p. 1–6. Citado na página 15.