



INSTITUTO
UNIVERSITÁRIO
DE LISBOA

Sistemas Inteligentes para a Gestão de Trânsito em Lisboa: Uma Análise Integrada do Impacto Climático e da Mobilidade

Mariana Ferreira Borges Fernandes

Mestrado em Sistemas Integrados de Apoio à Decisão

Orientador:

Doutor Luís Manuel Nobre de Brito Elvas,
Professor Auxiliar,
Iscte-Instituto Universitário de Lisboa

Orientador:

Doutor João Carlos Amaro Ferreira, Professor Auxiliar
(com Agregação),
Iscte-Instituto Universitário de Lisboa

Setembro, 2025

Departamento de Ciências e Tecnologia da Informação

Sistemas Inteligentes para a Gestão de Trânsito em Lisboa: Uma Análise Integrada do Impacto Climático e da Mobilidade

Mariana Ferreira Borges Fernandes

Mestrado em Sistemas Integrados de Apoio à Decisão

Orientador:

Doutor Luís Manuel Nobre de Brito Elvas,
Professor Auxiliar,
Iscte- Instituto Universitário de Lisboa

Orientador:

Doutor João Carlos Amaro Ferreira, Professor Auxiliar
(com Agregação),
Iscte-Instituto Universitário de Lisboa

Setembro, 2025

Aos que estiveram presentes.

Agradecimento

Agradeço a todos aqueles que, de diferentes formas, me apoiaram e acompanharam ao longo deste percurso. Agradeço também à Câmara Municipal de Lisboa por me ter fornecido os dados e me ter dado a oportunidade de desenvolver este projeto.

Por fim, quero agradecer ao Lourenço e à Madalena pelo apoio e pela amizade desde o primeiro dia. Sem vocês isto não seria possível, somos um!

Resumo

A mobilidade urbana em Lisboa pode ser influenciada por diversos fatores que afetam os fluxos de entrada e saída da cidade. Entre eles destacam-se feriados, greves, interrupções letivas e condições meteorológicas.

O objetivo desta dissertação foi compreender de que forma estes fatores condicionam a mobilidade nos principais eixos rodoviários da cidade. Neste contexto, foi desenvolvido um estado de arte seguindo a metodologia PRISMA, identificando técnicas de análise de dados aplicadas à mobilidade nas cidades inteligentes, concluindo-se que os modelos de inteligência artificial têm bom desempenho na previsão da mobilidade, mas enfrentam limitações práticas.

Para além disso, recorreu-se ao processo CRISP-DM, aplicado a dados de dispositivos móveis anónimos disponibilizados pela Câmara Municipal de Lisboa, complementados com dados meteorológicos do IPMA. Testou-se ainda o modelo Prophet para prever fluxos de mobilidade, acrescentando uma vertente preditiva à análise.

Os resultados evidenciam que a mobilidade em Lisboa apresenta uma estrutura fortemente pendular. Contudo, fatores externos introduzem variações significativas: a precipitação reduz ligeiramente os fluxos e prolonga as horas de ponta; greves provocam redistribuições modais; feriados diminuem drasticamente a mobilidade e eliminam os padrões pendulares; e interrupções letivas geram efeitos mais subtis. O *Prophet* revelou-se inadequado para a previsão da mobilidade sendo que, mesmo após ajustes metodológicos, os erros permaneceram elevados, com valores de MAPE entre os 53% e 258%. Conclui-se que a integração e análise de dados móveis e meteorológicos, permitiu compreender melhor os determinantes da mobilidade urbana, fornecendo informação útil para a tomada de decisão, contribuindo para uma Lisboa mais eficiente.

Palavras-chave: Cidades Inteligentes, Mobilidade Urbana, Trânsito, Inteligência Artificial, Internet das Coisas

Abstract

Urban mobility in Lisbon can be influenced by several factors that affect daily traffic flows into and out of the city. Among these factors are public holidays, strikes, school breaks and weather conditions.

The purpose of this dissertation was to understand the impact of these factors on the city's main road axes. In this context, a state-of-the-art review was developed following the PRISMA methodology, identifying data analysis techniques applied to mobility in smart cities and concluding that artificial intelligence models perform well in forecasting mobility patterns but still face practical limitations.

In addition, the CRISP-DM methodology was applied to anonymous mobile device data provided by the Lisbon City, complemented with meteorological data from IPMA. The Prophet model was tested to forecast mobility flows, adding a predictive dimension to the analysis.

Findings show that mobility in Lisbon has a strongly pendular structure. However, external factors substantially modify this structure: rainfall slightly reduces flows and extends rush hours; strikes generate modal redistributions; public holidays drastically reduce mobility and eliminate pendular patterns; and school breaks produce more subtle effects. The Prophet model proved inadequate for forecasting mobility in Lisbon, as even after methodological adjustments, the errors remained high, with MAPE values ranging from 53% to 258%.

Overall, the integration and analysis of mobile and meteorological data provided a better understanding of the determinants of urban mobility, offering useful information for decision-making and contributing to a more efficient city.

Keywords: Smart Cities, Urban Mobility, Traffic, Artificial Intelligence, Internet of Things (IoT)

Índice

Agradecimento	iii
Resumo	v
Abstract	vii
Índice de Figuras	xi
Índice de Tabelas	xiii
Lista de abreviaturas, acrónimos e siglas	15
CAPÍTULO 1	1
Introdução	1
1.1. Visão Geral	2
1.2. Motivação e Objetivos	2
1.3. Metodologia	4
CAPÍTULO 2	5
Revisão de Literatura	5
2.1. Seleção de Estudos	5
2.2. Estado de Arte	6
2.3. Conclusões do Estado de Arte	10
CAPÍTULO 3	11
CRSIP-DM	11
3.1. Compreensão do Negócio	11
3.2. Compreensão dos Dados	12
3.3. Preparação dos Dados	13
3.4. Modelação e Avaliação	16
3.4.1. Análise Exploratória de Dados	16
3.4.2. Prophet	39
3.5. Implementação	45
CAPÍTULO 4	47
Resultados e Discussão	47
CAPÍTULO 5	51
Conclusões	51
5.1. Conclusões	51
5.2. Contributos e Limitações	52
5.3. Recomendações e Trabalhos futuros	53
Referências Bibliográficas	55
Anexos	57

Índice de Figuras

Figura 1 - Soma das entradas e saídas por eixos.....	16
Figura 2 - Média de entradas por hora e por eixo	17
Figura 3 - Média de saídas por hora e por eixo.....	17
Figura 4 - Média diária de entradas e saídas na cidade por dia da semana.....	18
Figura 5 - Média de entradas e saídas na cidade por dia da semana entre as 8h e as 9h	19
Figura 6 - Média de entradas e saídas na cidade por dia da semana entre as 17h e as 18h	19
Figura 7 - Média diária de entradas e saídas na cidade por estação do ano	20
Figura 8 - Média diária de entradas na cidade por precipitação	20
Figura 9 - Média diária de saídas na cidade por precipitação	21
Figura 10 - Média diária de entradas por eixo e precipitação	21
Figura 11 - Média diária de saídas por eixo e precipitação.....	22
Figura 12 - Média de entradas por hora, eixo e precipitação na A1, A36, A5 e Calçada de Carriche ...	22
Figura 13 - Média de entradas por hora, eixo e precipitação no IC16, IC19, IC2 e Marginal.....	23
Figura 14 - Média de entradas por hora, eixo e precipitação na N117, Ponte 25 de Abril e Ponte Vasco da Gama	23
Figura 15 - Média de saídas por hora, eixo e precipitação na A1, A36, A5 e Calçada de Carriche.....	23
Figura 16 - Média de saídas por hora, eixo e precipitação no IC16, IC19, IC2 e Marginal	24
Figura 17 - Média de saídas por hora, eixo e precipitação na N117, Ponte 25 de Abril e Ponte Vasco da Gama	24
Figura 18 - Média diária de entradas na cidade por greve	25
Figura 19- Média diária de saídas na cidade por greve.....	25
Figura 20 - Média diária de entradas por eixo e greve.....	26
Figura 21 - Média diária de saídas por eixo e greve	26
Figura 22 - Média de entradas diárias por eixo e entidade da greve	27
Figura 23 - Média de saídas diárias por eixo e entidade da greve	27
Figura 24 - Média de entradas por hora, eixo e greve na A1, A36, A5 e Calçada de Carriche.....	28
Figura 25 - Média de entradas por hora, eixo e greve no IC16, IC19, IC2 e Marginal	28
Figura 26 - Média de entradas por hora, eixo e greve na N117, Ponte 25 de Abril e Ponte Vasco da Gama	28
Figura 27 - Média de saídas por hora, eixo e greve na A1, A36, A5 e Calçada de Carriche	29
Figura 28 - Média de saídas por hora, eixo e greve no IC16, IC19, IC2 e Marginal.....	29
Figura 29 - Média de saídas por hora, eixo e greve na N117, Ponte 25 de Abril e Ponte Vasco da Gama	29
Figura 30 - Média diária de entradas na cidade por feriado.....	30
Figura 31 - Média diária de saídas na cidade por feriado	30
Figura 32 - Média diária de entradas na cidade por eixo e feriado	31
Figura 33 - Média diária de saídas da cidade por eixo e feriado.....	31
Figura 34 - Média de entradas por hora, eixo e feriado na A1, A36, A5 e Calçada de Carriche	32
Figura 35 - Média de entradas por hora, eixo e feriado no IC16, IC19, IC2 e Marginal.....	32
Figura 36 - Média de entradas por hora, eixo e feriado na N117, Ponte 25 de Abril e Ponte Vasco da Gama	32
Figura 37 - Média de saídas por hora, eixo e feriado na A1, A36, A5 e Calçada de Carriche.....	33
Figura 38 - Média de saídas por hora, eixo e feriado no IC16, IC19, IC2 e Marginal	33
Figura 39 - Média de saídas por hora, eixo e feriado na N117, Ponte 25 de Abril e Ponte Vasco da Gama	33
Figura 40 - Média diária de entradas na cidade por férias escolares	34
Figura 41 - Média diária de saídas da cidade por férias escolares.....	34
Figura 42 - Média diária de entradas na cidade por eixo e férias escolares.....	35
Figura 43 - Média diária de saídas da cidade por eixo e férias escolares	35

Figura 44 - Média de entradas por hora, eixo e férias escolares na A1, A36, A5 e Calçada de Carriche	36
Figura 45 - Média de entradas por hora, eixo e férias escolares no IC16, IC19, IC2 e Marginal.....	36
Figura 46 - Média de entradas por hora, eixo e férias escolares na N117, Ponte 25 de Abril e Ponte Vasco da Gama.....	37
Figura 47 - Média de saídas por hora, eixo e férias escolares na A1, A36, A5 e Calçada de Carriche..	37
Figura 48 - Média de saídas por hora, eixo e férias escolares no IC16, IC19, IC2 e Marginal	37
Figura 49 - Média de saídas por hora, eixo e férias escolares na N117, Ponte 25 de Abril e Ponte Vasco da Gama	38
Figura 50 - Previsões do Prophet por eixo após tuning	44

Índice de Tabelas

Tabela 1 - Critérios de seleção	5
Tabela 2 - Descrição dos dados do conjunto 1	13
Tabela 3 - Descrição dos dados do conjunto 2.....	13
Tabela 4 - Descrição dos dados finais	15
Tabela 5 - Resultados do Prophet com agregação horária: MAE e MAPE por eixo	39
Tabela 6 - Resultados do Prophet com agregação diária: MAE e MAPE por eixo	40
Tabela 7 - Resultados do Prophet com agregação diária após tuning: MAE e MAPE por eixo	41

Lista de abreviaturas, acrónimos e siglas

ANN - *Artificial Neural Networks*

CNN - *Convolutional Neural Networks*

Fed-NTP - *Federated learning algorithm for Network Traffic Prediction*

GAN - *Generative Adversarial Network*

GNN - *Graph Neural Networks*

IA - *Inteligência Artificial*

IoT - *Internet of Things*

LSTM-GRU - *Long Short Term Memory-Gated Recurrent Units*

mMTC - *Machine-Type Communication*

PRISMA - *Preferred Reporting Items for Systematic Reviews and Meta-Analysis*

SIT - *Sistemas Inteligentes de Transporte*

VANET - *Vehicular Ad-Hoc Network*

LxDataLab - *Lisbon Urban Data Laboratory*

IPMA - *Instituto Português do Mar e da Atmosfera*

MAE - *Mean Absolute Error*

MAPE - *Mean Absolute Percentage Error*

CAPÍTULO 1

Introdução

O conceito de *smart city*, remete para a utilização estratégica de tecnologias digitais e de informação para melhorar a qualidade de vida nas áreas urbanas, ou seja, o desenvolvimento urbano recorre à tecnologia, inovação e integração de sistemas para melhorar a qualidade de vida dos cidadãos. Hoje, as *smart cities* estão equipadas com redes abrangentes de sensores que, por exemplo, monitorizam o trânsito em tempo real e grandes volumes de dados de trânsito [1].

Um dos grandes desafios que se colocam às grandes cidades é o congestionamento do trânsito, o qual se traduz numa situação em que o movimento de automóveis se caracteriza por velocidades reduzidas, aumento das filas de veículos e tempos de viagem prolongados [2]. É importante referir que, com o crescimento populacional, a par da expansão urbana [1], os sistemas de viação ficam sobrecarregados, provocando longos tempos de deslocação e maior poluição do ar. A principal causa do congestionamento é o número excessivo de automóveis particulares aliado ao transporte público inadequado e às infraestruturas insuficientes [2]. E neste aspeto, crê-se que as *smart cities* contribuem com soluções inovadoras, como a integração da Internet das Coisas (IoT) para recolha de dados de trânsito em tempo real e a aplicação de algoritmos inteligentes de previsão, como o *K-Nearest Neighbors* otimizado, que permitem antecipar fluxos de trânsito e combater o congestionamento do trânsito nas grandes cidades, como é o caso da cidade de Lisboa, Portugal [2]. Por exemplo, a análise de dados em tempo real, semáforos inteligentes que se adaptam ao volume de carros, sensores e câmeras são algumas das tecnologias que permitem monitorizar o fluxo de carros, diminuindo o congestionamento. De acordo com Magalhães et al. [1], as *smart cities* estão equipadas com redes abrangentes de sensores que monitorizam o trânsito em tempo real e grandes volumes de dados do mesmo, podendo ser utilizados para extrair conhecimento que é útil para municípios e cidadãos. Concomitantemente, as *smart cities* contribuem para um modelo de mobilidade urbana mais sustentável e focado nas pessoas. Isto porque, o grande volume de dados recolhidos através de sensores de monitorização do trânsito em tempo real, oferece novas oportunidades para desenvolver modelos e algoritmos que melhoram os serviços de transporte, através de sistemas de transporte inteligentes, principalmente aqueles que são concebidos para prever o trânsito automóvel [1]. Desta forma, a previsão de trânsito permite antecipar congestionamentos,

apoiar a gestão da rede viária e disponibilizar informação mais fiável aos utilizadores e operadores de transportes públicos, contribuindo assim para uma mobilidade mais eficiente [1].

Portanto, as *smart cities* unem a tecnologia ao planeamento urbano inteligente, apresentando soluções que promovem a transformação dos centros urbanos em espaços eficientes, eliminando um dos principais obstáculos de uma cidade habitável e devidamente gerida: o congestionamento do trânsito. Entre estas soluções destacam-se a previsão de velocidades para informar os utilizadores sobre possíveis atrasos [1], bem como o recurso a algoritmos inteligentes que permitem ajustar rotas alternativas e melhorar a coordenação do transporte público [2].

1.1. Visão Geral

Esta dissertação surge no âmbito de um desafio proposto pelo *Lisbon Urban Data Laboratory (LxDataLab)*, uma iniciativa desenvolvida pelo Centro de Gestão e Inteligência Urbana da Câmara Municipal de Lisboa. O objetivo do *LxDataLab* prende-se com a transformação de dados urbanos em informação que possa ser utilizada para responder aos problemas reais da cidade e, consequentemente, promovam uma gestão urbana mais eficiente e inteligente [3].

Dado este contexto, esta dissertação foca-se na análise dos padrões de mobilidade nos principais eixos de entrada e saída da cidade de Lisboa.

Esta pesquisa procura avaliar os padrões da mobilidade no acesso à cidade, através da análise de dados de mobilidade fornecidos pela Câmara Municipal de Lisboa, complementados com variáveis contextuais, tais como o calendário escolar, os registos de greves dos transportes públicos, feriados e dados meteorológicos disponibilizados pelo Instituto Português do Mar e da Atmosfera (IPMA). Através do uso da análise espacial e exploração estatística, bem como da aplicação do modelo *Prophet*, pretende-se identificar padrões recorrentes, anomalias e comportamentos que fundamentem a definição de estratégias no âmbito da gestão da mobilidade urbana.

1.2. Motivação e Objetivos

Lisboa tem vindo a crescer como um dos principais destinos turísticos da Europa, tendo sido distinguida, em 2023, com o título de “Melhor Destino Cidade da Europa” pelo *World Travel*

Awards [4]. O aumento da população ativa, juntamente com o crescimento do turismo, tem contribuído para uma maior pressão sobre a mobilidade na cidade [5]. Esta pressão pode ser agravada durante eventos pontuais como greves, feriados, ou variações nas condições climáticas, exigindo uma gestão urbana baseada em dados.

Assim, o principal objetivo desta dissertação é contribuir para a compreensão e otimização da mobilidade urbana em Lisboa, através da análise de dados de trânsito, variáveis contextuais e da implementação de um modelo preditivo aplicado aos fluxos de mobilidade. Mais especificamente, procura responder às seguintes perguntas de investigação (PI) e os respetivos objetivos (OBJ):

- PI1 – Quais as técnicas mais proeminentes para a análise de dados de cidades inteligentes?

- ⇒ OBJ1 – Realizar um estado de arte que identifique, compare e sintetize as principais técnicas utilizadas na análise de dados das *smart cities*.

- PI2 - Como é que a precipitação afeta os padrões de mobilidade nos principais eixos de Lisboa?

- ⇒ OBJ2: Analisar a influência da precipitação nos padrões de trânsito urbano em Lisboa, avaliando a sua relação com variações de fluxo.

- PI3 - De que forma eventos pontuais como greves, feriados e interrupções letivas afetam os padrões de mobilidade nos eixos de entrada/saída de Lisboa?

- ⇒ OBJ3: Estudar o impacto de eventos disruptivos na mobilidade urbana, identificando padrões anómalos e redistribuições de trânsito associadas.

- PI4 – Qual o desempenho do *Prophet* na previsão dos fluxos de mobilidade em Lisboa?

- ⇒ OBJ4: Implementar o modelo *Prophet*, avaliar a sua performance e discutir a sua utilidade no contexto da mobilidade em contextos urbanos.

Com isto, o objetivo desta pesquisa não é apenas contribuir para o conhecimento académico sobre a mobilidade urbana, mas também fornecer insights que possam apoiar a formulação de políticas públicas orientadas para a otimização da cidade.

1.3. Metodologia

No âmbito desta dissertação, foi utilizada a metodologia PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analysis*) para o desenvolvimento do Estado de Arte, que pode ser encontrado no capítulo 2.1. Relativamente ao problema em estudo, a metodologia utilizada foi o CRISP-DM (*Cross-Industry Standard Process for Data Mining*) que, de acordo com Schröer et al. [6] é um modelo de referência para a orientação de projetos de *Data Mining* com o objetivo de prover uma metodologia estruturada, independentemente do domínio ou da tecnologia e que se encontra ao longo do capítulo 3.

Este modelo é composto por seis fases: 1) Compreensão do negócio, 2) Compreensão dos dados, 3) Preparação dos dados, 4) Modelação, 5) Avaliação e 6) Implementação.

A escolha desta metodologia prende-se pelo facto de esta oferecer uma estrutura clara e flexível, que permite a sua adaptação a diferentes projetos e facilita o planeamento e execução e pela promoção da correlação entre os objetivos de negócio e a análise dos dados, de modo a assegurar a utilidade prática dos resultados [6].

Revisão de Literatura

2.1. Seleção de Estudos

A metodologia utilizada para a realização deste estado da arte foi a PRISMA, a qual visa ajudar os autores a melhorarem o relato de revisões sistemáticas e meta-análises [7]. Esta destaca-se pelas suas etapas claramente definidas, promovendo o rigor e a transparência nas revisões de literatura [7], [8].

A pesquisa de estudos foi orientada pela definição dos critérios de seleção dos estudos a incorporar na revisão de literatura, ou seja, dos critérios de inclusão (aqueles que devem estar presentes nos artigos) e os critérios de exclusão (aqueles que, quando presentes, inviabilizam a utilização do artigo). Na tabela que se segue, são especificados os critérios de seleção.

Tabela 1 - Critérios de seleção

Critérios de Seleção	Critérios de Inclusão	Critérios de Exclusão
Data de Publicação	Artigos publicados entre 2015 e 2025	Artigos publicados antes de 2015
Idioma	Português e Inglês	Outros idiomas
Acesso	Integral e gratuito	Pago
Assunto	Previsão de trânsito, modelação do fluxo de trânsito, <i>machine learning</i> , análise de dados, cidades inteligentes	Modelação do fluxo aplicada a outras áreas que não a do trânsito

Em seguida, para a pesquisa das evidências empíricas recorreu-se a duas bases de dados – a *Scopus*¹ e a *Web of Science*² – e tendo em conta o tema em estudo, foi formulada uma *Query* Base, a qual foi inserida em cada uma das bases de dados mencionadas: *(TITLE-ABS-KEY ("traffic prediction" OR "traffic flow modeling") AND TITLE-ABS-KEY ("machine learning" OR "data analysis" OR "Artificial Intelligence" OR "Data mining") AND TLITE-ABS-KEY ("smart cities" OR "smartcities" OR "Lisbon")) AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO) + ENGLISH + OPEN ACCESS*.

¹ <https://www.scopus.com>

² <https://www.webofscience.com>

A pesquisa realizou-se em fevereiro de 2025 e inicialmente obteve-se um total de 46 artigos (27 do *Scopus* e 19 da *Web of Science*). Com a remoção de 12 duplicados, obteve-se um total de 34 artigos.

Posteriormente, realizou-se uma análise manual dos 34 artigos, avaliando a pertinência de cada estudo face aos objetivos da dissertação. Foram excluídos artigos que, apesar de se enquadrarem nos termos da *query*, abordavam previsões aplicadas a domínios distintos por exemplo, previsão de energia, redes de comunicações ou sistemas puramente teóricos sem aplicação à mobilidade.

Após esta segunda fase de triagem, permaneceram 16 artigos, que constituem a base do presente estado da arte. Estes artigos foram selecionados por apresentarem contributos diretos para a previsão de trânsito em contextos urbanos, com foco em técnicas de *machine learning*, *deep learning*, integração de dados IoT e abordagens híbridas. As referências completas correspondentes a estes 16 artigos encontram-se listadas no Anexo A - Artigos incluídos na revisão sistemática (PRISMA).

2.2. Estado de Arte

A crescente urbanização, com o maior fluxo de veículos e as preocupações ambientais colocam uma grande pressão sobre os sistemas de mobilidade urbana [9]. Em Lisboa, à semelhança do que acontece noutras grandes metrópoles, a procura por soluções inovadoras para a gestão do trânsito é uma realidade. Estas soluções passam pela *Internet of Things* (IoT, em português, internet das coisas), sistemas inteligentes de transporte (SIT) e modelos avançados de previsão de trânsito.

A IoT permite a interligação de dispositivos físicos, por exemplo, sensores de trânsito, câmeras, semáforos inteligentes, através da internet, compondo um ecossistema urbano interativo e responsivo. Segundo Miao e Liao [9], a aplicação da IoT na previsão do trânsito, permite recolher, continuamente e em tempo real, dados fundamentais como a velocidade média dos veículos, densidade do trânsito e padrões de mobilidade. E é a partir destes dados que são tomadas decisões automáticas, permitindo ajustar os semáforos ou redirecionar fluxos com base em condições dinâmicas.

Hoje também já é possível integrar a IoT com a inteligência artificial (IA) e esta integração tem vindo a instigar a criação de *smart cities*. Moummen et al. [10] explicam que, ao combinar dados de sensores urbanos com algoritmos de aprendizagem automática, consegue-se detetar congestionamentos de forma preditiva e adaptar estratégias de mobilidade em tempo real, o que

promove uma mobilidade mais sustentável e eficiente.

Estas tecnologias têm vindo a ser utilizadas nos SIT, os quais se caracterizam por utilizar tecnologias digitais e computacionais que permitem melhorar a eficiência, a segurança e a sustentabilidade do transporte. No âmbito da IoT, os SIT tornam-se mais complexos, na medida em que atuam a partir dados atualizados de diversas fontes. O trabalho de Alsubai et al. [11] apresenta uma abordagem híbrida assente em *deep learning* e otimização aritmética para o controlo de congestionamento em ambientes IoT, mostrando um impacto positivo na redução de tempos de espera e poluição do ar, devido à menor emissão de poluentes. Os autores relatam que o modelo híbrido reduziu significativamente o tempo médio de espera em interseções urbanas, demonstrando ganhos de eficiência mensuráveis na gestão do trânsito.

No entanto, os SIT não atuam só com veículos e através do estudo de Fan et al. [12], é possível observar a possibilidade de reutilizar os dados originários de edifícios inteligentes, por exemplo, sensores de presença e temperatura, para prever padrões de trânsito urbano por meio de uma aprendizagem interdomínio (*cross-domain learning*), proporcionando uma visão mais abrangente da dinâmica urbana.

Pode-se dizer que a previsão do trânsito é um dos pilares para uma gestão eficiente do transporte urbano e a utilização de algoritmos de IA, como as redes neurais profundas e os modelos híbridos, têm vindo a ocupar o lugar dos tradicionais métodos de modelação estatística. Ainda assim, autores como Magalhães et al. [1] destacam a relevância de abordagens baseadas em séries temporais, nas quais modelos mais recentes como o Prophet podem ser enquadrados, constituindo alternativas mais leves e de rápida implementação em comparação com modelos de *deep learning*. De acordo com Mehri et al. [13], as comunicações massivas entre máquinas (mMTC - *machine-type communication*) assumem um papel de relevo na previsão do trânsito em redes IoT densamente povoadas, como existem nas grandes cidades. Assim, o estudo mostra que a elevada densidade de dispositivos IoT pode gerar atrasos de comunicação, mas também abre espaço para modelos mais precisos devido ao elevado volume dos dados recolhidos.

Além do mais, a federação de dados, isto é, o uso colaborativo de dados entre múltiplos dispositivos sem necessidade de centralização tem vindo a ganhar cada vez maior relevância. Isso é visível no estudo de Li et al. [14], o qual demonstra como abordagens baseadas em *blockchain* e *federated learning* podem assegurar a privacidade e a integridade dos dados partilhados em ambientes IoT, promovendo a confiança e a escalabilidade nos sistemas de previsão de trânsito. Os autores destacam que estas abordagens são capazes de preservar a privacidade dos cidadãos sem comprometer a exatidão das previsões, ainda que enfrentem desafios relacionados com a escalabilidade e a complexidade computacional.

Também Lee et al. [15] apresentam um sistema de previsão posicionamento de veículos baseado na IA, o que permite antecipar congestionamentos e, simultaneamente, melhorar a segurança e a gestão dos fluxos em tempo real. Neste caso, a integração de algoritmos de IA permitiu aumentar a precisão do posicionamento dos veículos, contribuindo para uma gestão mais segura da rede viária.

De facto, a transformação digital das cidades requer soluções computacionais com capacidade para lidar com grandes volumes de dados dinâmicos, provenientes de sensores, veículos, infraestruturas e dispositivos móveis. E neste cenário, os modelos baseados em IA, como as redes neurais profundas, tornam-se componentes fulcrais para a previsão e gestão eficiente do trânsito [16], [17].

Ora, a aplicação de redes neurais artificiais (ANN - *Artificial Neural Networks*), redes neurais convolucionais (CNN - *Convolutional Neural Networks*), LSTM (*Long Short Term Memory*) e modelos híbridos como o LSTM-GRU (*Long Short Term Memory-Gated Recurrent Units*), vem-se afirmando como uma solução promissora na previsão do trânsito. Segundo Karthika et al. [16], técnicas como *deep learning* ultrapassam os tradicionais métodos de previsão ao oferecerem maior precisão na modelação do trânsito em tempo real. Esta ideia é reforçada por Zafar et al. [17], que no seu estudo mostra que um modelo híbrido LSTM-GRU pode capturar as variações na velocidade do trânsito urbano, mesmo em situações com dados incompletos. Para além disso, o modelo LSTM-GRU demonstrou robustez em cenários com dados heterogêneos, alcançando melhorias de desempenho face a modelos mais isolados.

Outros estudos dão destaque à integração de redes neurais com algoritmos de otimização bioinspirados. A este respeito, importa referir o estudo de Hamza et al. [18], onde é proposto um modelo baseado em *slime mould optimization* integrado com *deep learning*, otimizando a previsão do trânsito em ambientes urbanos complexos. Segundo os autores, esta abordagem não só prevê como propõe estratégias de atuação, como o redirecionamento de fluxos ou sincronização de semáforos. Este tipo de integração bioinspirada alcançou ganhos de eficiência no ajuste dinâmico do trânsito, apesar de ter um maior custo computacional.

Por outro lado, Shen et al. [19] focaram-se na utilização de redes neurais baseadas em grafos (GNN - *Graph Neural Networks*) aplicadas a dados originários da computação *edge* (*edge computing*) em sistemas IoT e concluíram que as GNN apresentam melhor desempenho do que modelos convencionais ao explorar as relações espaciais entre estradas e sensores, embora dependam de infraestruturas *edge* para reduzir o tempo de resposta.

Outras abordagens são apresentadas noutros estudos, como no de Sujakumari e Dassan [20] que estudaram o uso de redes adversariais gerativas (GAN - *Generative Adversarial Network*),

onde as câmaras de videovigilância são integradas com GAN para prever trânsito em tempo real. No entanto, também Mrad et al. [21] apresentam uma solução eficiente com neurais *wavelet*, que facultam previsões de curto prazo com menor consumo computacional, o ideal para a integração em dispositivos de baixos custos em ambientes urbanos inteligentes. Enquanto as GAN são capazes de alcançar elevada capacidade de modelação para cenários complexos, as *wavelet neural networks* constituem uma alternativa mais leve e adequada para dispositivos de baixo custo.

Já Toutouh et al. [22], conceberam o *BiPred*, um algoritmo evolutivo *bilevel*, que permite prever padrões de mobilidade, ideal para aplicações que requerem a otimização de vários objetivos em simultâneo: fluidez do trânsito e redução de emissões. Os resultados indicam que o *BiPred* é capaz de conciliar vários objetivos de forma eficiente, revelando-se adequado para contextos de mobilidade sustentável.

Contudo, é necessário reforçar a ideia de que a implementação de sistemas de trânsito inteligente tem de assegurar a privacidade dos dados e a escalabilidade. E sobre este assunto, Sepasgozar e Pierre [23] apresentam o Fed-NTP (*Federated learning algorithm for Network Traffic Prediction*), um algoritmo federado para a previsão de trânsito em redes de veículos (VANET – *Vehicular Ad-Hoc Network*), impedindo a centralização de dados sensíveis. Estes autores salientam que este tipo de abordagem federada reduz riscos de privacidade, mas pode apresentar dificuldades de sincronização e maior complexidade de coordenação entre dispositivos. Por outro lado, os estudos de Pandey et al. [24] e Malik et al. [25] destacam o papel das redes móveis 5G e do *edge computing* para acelerar os processos de previsão e decisão. A redução do tempo de resposta e o aumento da capacidade de transmissão dos dados permitem que modelos complexos, como GAN e LSTM, sejam executados em tempo real em dispositivos móveis e urbanos. No entanto, os autores em [24] alertam que a dependência do 5G pode constituir uma limitação em cidades onde a cobertura não é homogênea, enquanto em [23], reforçam o custo elevado da implementação dessas infraestruturas.

Concluindo, a utilização de modelos inteligentes para a previsão do trânsito pode transformar, positivamente, a mobilidade urbana em Lisboa. Por exemplo, a técnica GNN pode ser particularmente útil para a cidade, onde dispositivos distribuídos pela cidade podem facultar dados e as decisões necessitam ser céleres e contextuais [19]. A GAN é um tipo de técnica que também pode ser aplicada à cidade, pois permite analisar os principais eixos de entrada e de saída da cidade e onde há grande densidade de trânsito [20]. Assim sendo, a utilização de modelos inteligentes, juntamente com a IoT e a IA pode ser vantajoso para a cidade, pois podem permitir a antecipação de congestionamentos, prever o trânsito e, concomitantemente, ao

possibilitar adaptar o sistema em tempo real tem um impacto direto na redução de emissões de dióxido de carbono (menos tempo parado = menos poluição), melhorar a qualidade do ar, tornando-o mais respirável, melhorar a eficiência no transporte público, por exemplo, através do recurso a redes neurais, que permitem prever atrasos e adaptar horários [11], [21], [24], [25].

Para terminar, interessa acrescentar que com a integração da rede 5G e os sistemas de aprendizagem distribuída, a cidade pode ser um exemplo da implementação de soluções preditivas de trânsito que respeitam a privacidade dos cidadãos, um direito que lhes assiste, e otimizar os recursos de forma sustentável [23].

2.3. Conclusões do Estado de Arte

De uma forma geral, a revisão de literatura mostra que os avanços em IoT e IA têm permitido melhorias significativas na previsão do trânsito, traduzindo-se na redução de congestionamentos, tempos de espera e emissões poluentes. Vários estudos confirmam que os modelos de *deep learning* conseguem superar os modelos tradicionais, assegurando maior precisão e capacidade de adaptação em tempo real [11], [16], [17], [19], [20]. No entanto, apesar destes progressos, permanecem desafios relevantes: a limitação de muitos *datasets*, frequentemente restritos em termos de dimensão ou aplicados a contextos específicos [16], [21], o elevado custo computacional associado a arquiteturas profundas [18], [21], a dependência de infraestruturas avançadas como 5G e *edge computing* [24], [25], bem como as questões de privacidade e de coordenação em sistemas distribuídos [14], [23].

Assim, a aplicação destas soluções em cidades como Lisboa depende não apenas da maturidade tecnológica, mas também da capacidade de fazer face a estas limitações. Neste contexto, modelos estatísticos como o *Prophet* surgem como abordagens complementares, menos exigentes em termos de capacidade computacional e capazes de lidar diretamente com padrões sazonais, oferecendo uma alternativa prática aos métodos de *deep learning* em determinados cenários urbanos [1], [16], [21]. Ainda assim, os trabalhos revistos fornecem uma base sólida para a implementação de sistemas de mobilidade mais eficientes e sustentáveis, que conciliem precisão preditiva, proteção da privacidade e otimização de recursos.

CAPÍTULO 3

CRSIP-DM

3.1. Compreensão do Negócio

Compreender o problema em estudo é o primeiro passo para garantir que toda a análise desenvolvida está alinhada com os objetivos do projeto [6]. No caso desta dissertação, o foco incide sobre a forma como os padrões de mobilidade nos principais eixos rodoviários de acesso à cidade de Lisboa são influenciados por diferentes fatores contextuais, nomeadamente precipitação, feriados, greves e interrupções letivas, que têm impacto direto na circulação e contribuem para o agravamento do congestionamento. Para além da análise descritiva e exploratória, foi também considerado o uso de técnicas de previsão, nomeadamente o modelo *Prophet*, como forma de complementar a compreensão destes fenómenos.

Este enquadramento responde diretamente aos objetivos definidos no 1.2., em particular, ao OBJ2, que consiste na análise da influência das condições meteorológicas nos padrões de mobilidade, e ao OBJ3, que visa estudar o impacto de eventos pontuais na mobilidade urbana. A integração de uma vertente preditiva alinha-se ainda com o OBJ4, dedicado à avaliação da sua capacidade de antecipação de fluxos de trânsito.

Neste sentido, o objetivo principal passa por perceber de que forma os fluxos de trânsito variam ao longo do tempo, e de que forma os eventos externos ou condicionantes específicas interferem com o comportamento do trânsito. Para isso, foram também integradas variáveis complementares, tais como o calendário escolar, os registos de greves e feriados, e dados meteorológicos disponibilizados pelo IPMA, de forma a construir uma visão mais rica e contextualizada da realidade urbana.

A estrutura adotada nesta fase inicial assentou em três etapas:

- I. Recolha e preparação dos dados: os dados foram tratados, limpos e organizados de modo a garantir consistência e qualidade, criando uma base sólida para a análise.
- II. Integração das diferentes fontes de informação: procedeu-se à harmonização dos dados recolhidos, assegurando coerência entre variáveis e facilitando a análise cruzada entre os diferentes fatores de impacto.

- III. Exploração dos padrões de mobilidade: recorreu-se a técnicas de análise estatística e visual para identificar tendências sazonais, variações significativas e anomalias nos fluxos de trânsito. Nesta etapa, foi também avaliada a pertinência de testar métodos preditivos simples.

Esta fase de compreensão do problema tem, assim, um papel central na definição do rumo da investigação, permitindo gerar conhecimento útil e aplicável à gestão da mobilidade urbana em Lisboa.

3.2. Compreensão dos Dados

Esta fase prende-se com o processo de observação e identificação de potenciais problemas na qualidade e a deteção de padrões ou relações preliminares nos dados, bem como a seleção de subconjuntos que possam evidenciar informações pertinentes [6].

No caso deste trabalho, os dados foram fornecidos pela Câmara Municipal de Lisboa, através de um protocolo estabelecido com a Vodafone, operadora móvel multinacional inglesa. Por razões legais e de privacidade, os dados são anónimos, não sendo possível identificar nenhum indivíduo.

Os dados foram disponibilizados de forma agregada nas grelhas correspondentes aos 11 pontos de acesso à cidade de Lisboa, tendo sido recolhidos com uma frequência de 5 minutos. Para além dos dados acima mencionados, foram também fornecidos dados meteorológicos provenientes do IPMA. Estes dados foram recolhidos por três estações meteorológicas, numa periodicidade horária.

Adicionalmente, para efeitos desta análise, consideraram-se os dados relativos ao período entre Janeiro e Dezembro de 2023, tendo por base duas bases de dados:

- ⇒ Conjunto 1: Contém informações do número de dispositivos móveis que entraram e saíram da cidade de Lisboa pelos 11 principais eixos viários num período de 5 minutos.

Tabela 2 - Descrição dos dados do conjunto 1

ID	Nome da Variável	Descrição	Tipo de dados
1	Id_eixo_viario	ID do Eixo Viário	Numérico
2	Eixo	Designação do Eixo	Texto
3	Datetime	Data da recolha	Data/Hora
4	C12	Número de dispositivos que entram num determinado eixo no período de 5 minutos	Numérico
5	C13	Número de dispositivos que saem de um determinado eixo no período de 5 minutos	Numérico

⇒ Conjunto 2: Contém informações meteorológicas de três estações, com uma periodicidade horária.

Tabela 3 - Descrição dos dados do conjunto 2

ID	Nome da Variável	Descrição	Tipo de dados
1	fecha	Data da última leitura	Data/Hora
2	estacion	N.º da estação - 01200535 - Lisboa Geofísico, 01200579- Lisboa Gago Coutinho, 01210762 - Lisboa Tapada da Ajuda	Texto
3	humidade	Humidade relativa média do ar	Numérico, Percentagem (%)
4	iddireccvento	Direção média do vento - 0 a 9	Numérico, ° - Graus
5	intensidadeventokm	Intensidade média do vento	Numérico, Quilómetro por hora (Km/h)
6	pressao	Pressão atmosférica	Numérico, Hectopascal (hPa)
7	radiacao	Radiação solar	Numérico, Watt por metro 2 - W/m2
8	temperatura	Temperatura	Numérico, Graus Celsius (°C)
9	precacumulada	Precipitação acumulada	Numérico, Milímetro (mm)
10	position	Coordenadas e tipo de entidade geográfica (ponto, linha ou polígono)	Numérico

3.3. Preparação dos Dados

No que concerne à base de dados da mobilidade verificou-se a inexistência de valores nulos e

foram eliminadas linhas duplicadas. A partir da coluna *Datetime*, foram criadas as variáveis *Data*, *Hora* e *HourNum*, que representa a hora em formato inteiro (0-23). De seguida, a base de dados foi enriquecida com variáveis contextuais relevantes: dia da semana, feriados, estações do ano, férias escolares, greves de transporte e coordenadas geográficas de cada um dos 11 eixos.

Na base de dados meteorológica, os ficheiros correspondentes ao primeiro e segundo semestre de 2023 foram concatenados removendo-se, também, linhas duplicadas e nulos. Para cada parâmetro meteorológico, foram definidos intervalos plausíveis:

- Humidade (0–100%);
- Temperatura (-20 °C a 45 °C);
- Pressão (800–1200 hPa);
- Intensidade do vento (≥ 0);
- Precipitação acumulada (≥ 0);
- Radiação (≥ 0);
- Direção do vento (0–9).

Os valores fora dos intervalos foram substituídos por valores nulos e, em seguida, alvo de *forward fill*, com exceção da Pressão, onde o elevado volume de valores nulos (cerca de 58%) desaconselhou a imputação. Para além disto, todas as variáveis numéricas foram arredondadas a duas casas decimais.

Para juntar ambas as fontes de dados, foi criada uma tabela auxiliar com as coordenadas das estações meteorológicas e aplicado o cálculo da distância de *Haversine*, uma fórmula que permite calcular a distância do arco máximo entre dois pontos numa esfera, através das respetivas latitudes e longitudes, considerando a curvatura da Terra [26]. Esta fórmula foi escolhida por ser o método padrão para medir distâncias entre dois pontos na superfície da Terra, considerando a sua curvatura e evitando distorções. Assim, cada eixo foi associado à estação meteorológica mais próxima, tendo a estação Lisboa Geofísico sido excluída por não corresponder a nenhum eixo.

Após a integração dos dados, estes foram agregados a nível horário, resultando numa linha por eixo, por hora e por dia. Esta decisão foi suportada pela comparação de matrizes de correlação em granularidade de 5 minutos e de 1 hora, onde os resultados mostraram padrões idênticos entre as variáveis da mobilidade, meteorologia e contexto, mostrando que a agregação horária era suficiente e mais eficiente para análise e integração.

A base de dados final resultou num ficheiro robusto e enriquecido, adequado ao estudo dos

padrões de mobilidade nos principais eixos viários de Lisboa.

Tabela 4 - Descrição dos dados finais

ID	Nome da Variável	Descrição	Tipo de Dados
1	Eixo	Designação do Eixo	Texto
2	Id_Eixo	ID do Eixo Viário	Numérico
3	Data	Data da recolha	Data
4	Hora	Hora da recolha	Hora
5	Entradas	Número de dispositivos que entram num determinado eixo no período de 5 minutos	Numérico
6	Saídas	Número de dispositivos que saem de um determinado eixo no período de 5 minutos	Numérico
7	Dia da Semana	Dia da semana	Texto
8	Feriado	Identifica se é, ou não feriado num determinado dia	Booleano
9	Nome Feriado	Nome do feriado	Texto
10	Estação Ano	Estação do ano	Texto
11	Latitude	Latitude	Numérico
12	Longitude	Longitude	Numérico
13	Férias Escolares	Identifica se é, ou não, férias escolares num determinado dia	Booleano
14	Férias Nome	Nome das férias escolares	Texto
15	Estação Meteorológica	N.º da estação - 01200579, 01210762	Numérico
16	Nome Estação	Nome da estação - Lisboa Gago Coutinho, Lisboa Tapada da Ajuda	Texto
17	Dist_km	Distância do eixo à estação meteorológica	Numérico
18	Temperatura	Temperatura	Numérico, Graus Celsius (°C)
19	Humidade	Humidade relativa média do ar	Numérico, Percentagem (%)
20	Pressão	Pressão atmosférica	Numérico, Hectopascal (hPa)
21	Radiação	Radiação solar	Numérico, Watt por metro 2 - W/m2
22	Intensidade Vento (Km/h)	Intensidade média do vento	Numérico, Quilómetro por hora (Km/h)

23	Precipitação Acumulada (mm)	Precipitação acumulada	Numérico, Milímetro (mm)
24	Direção Vento	Direção média do vento - 0 a 9	Numérico, ° - Graus
25	Entidade greve	Nome da entidade de greve	Texto
26	Greve	Identifica se é, ou não, greve num determinado dia	Booleano

Por fim, aquando da importação no *PowerBI* e para finalidades analíticas, foram criadas medidas de modo a calcular a média diária, o desvio padrão, erro padrão e intervalos de confiança a 95% (IC95) de entradas e saídas.

3.4. Modelação e Avaliação

Nesta secção irão ser apresentadas as análises desenvolvidas no decorrer deste trabalho, tendo como objetivo a resposta às perguntas de investigação inicialmente desenvolvidas.

3.4.1. Análise Exploratória de Dados

I. Padrões Gerais de Mobilidade

a) Qual a importância de cada eixo no acesso à cidade?




Figura 1 - Soma das entradas e saídas por eixos

Relativamente ao fluxo de entradas e de saídas por eixo no ano de 2023, a figura 1 expõe uma hierarquia da importância relativa de cada eixo no contexto do acesso à cidade. O IC19 apresenta-se como o eixo com maior volume acumulado, seguido pelo IC2 (Sacavém), A1, A5 e Ponte 25 de Abril, mostrando uma forte ligação entre a Margem Sul e Oeste a Lisboa. Por outro lado, os eixos IC16, N117 (Cabos d'Ávila), Calçada de Carriche e A36 (Túnel do Grilo), apesar de manterem relevância enquanto pontos de acesso à cidade, apresentam valores mais baixos. Já a Ponte Vasco da Gama e a Marginal constituem os eixos com menor volume de entradas e saídas, apresentando um menor peso na rede de acessos à cidade.

b) Qual o comportamento de cada eixo ao longo do dia?




Figura 2 - Média de entradas por hora e por eixo




Figura 3 - Média de saídas por hora e por eixo

Os padrões de entradas e saídas em Lisboa por eixo, parecem demonstrar uma estrutura pendular, marcada pelos movimentos casa-trabalho. De manhã observa-se o pico de entradas entre as 8h e as 9h, onde o IC19, IC2 (Sacavém), A1 e A5 concentram os maiores fluxos. Nas saídas, esta janela horária também apresenta um crescimento, ainda que menos acentuado, refletindo as deslocações de quem sai cedo da cidade. Durante o pico da tarde, entre as 17h e as 18h, o comportamento inverte-se, as saídas atingem o pico máximo, com a maior intensidade nos mesmos eixos, enquanto as entradas mantêm valores elevados, mesmo que ligeiramente mais diluídos. Entre as horas de ponta, tanto as entradas como as saídas da cidade estabilizam em volumes intermédios, apesar de se manter uma utilização mais constante dos principais eixos.

Já os eixos com menos peso (IC16, N117, A36, Calçada de Carriche), mostram volumes mais baixos, mas funcionam como rotas alternativas de elevada importância, especialmente em períodos de saturação dos grandes eixos. A Marginal e a Ponte Vasco da Gama registam valores médios mais reduzidos, evidenciando o seu papel mais periférico ou complementar na rede de acessos.

c) Como evoluem os padrões de mobilidade em cada dia da semana?




Figura 4 - Média diária de entradas e saídas na cidade por dia da semana

A figura 4 apresenta a média diária de entradas e saídas na cidade por dia da semana e é acompanhada pelos respetivos intervalos de confiança a 95% (IC95), que traduzem a variabilidade dos dados. Podemos observar um padrão semanal com valores mais elevados

entre segunda e sexta-feira, próximos de 1 milhão de movimentos diários e uma redução significativa ao fim de semana. Relativamente à variabilidade, os IC95 são ligeiramente mais estreitos a meio da semana, sugerindo uma maior estabilidade e mais alargados à segunda-feira e ao domingo, refletindo padrões de mobilidade menos regulares nesses dias.




Figura 5 - Média de entradas e saídas na cidade por dia da semana entre as 8h e as 9h




Figura 6 - Média de entradas e saídas na cidade por dia da semana entre as 17h e as 18h

Relativamente à evolução dos períodos de ponta durante a semana, no período compreendido entre as 8h e as 9h da manhã, Lisboa regista um predomínio de entradas relativamente às saídas onde, nos dias úteis, as entradas rondam valores entre 73 e 80 mil, enquanto ao sábado e domingo o padrão altera-se e o volume global de trânsito cai significativamente, revelando deslocações menos relacionadas à rotina laboral. Já no período entre as 17h e as 18h da tarde, observa-se o movimento inverso, onde as saídas superam as entradas em todos os dias úteis, com valores mais elevados entre terça e sexta-feira. Aos

sábados, o volume de entradas e saídas fica mais próximo, sugerindo uma mobilidade mais equilibrada e ligada a atividades de lazer. Já ao domingo, as entradas voltam a dominar.

d) Qual a evolução da mobilidade entre as estações do ano?




Figura 7 - Média diária de entradas e saídas na cidade por estação do ano

A distribuição sazonal da mobilidade revela-se consistente ao longo do ano, sendo que o Outono se destaca como a estação com a maior intensidade de movimentos diários, ultrapassando ligeiramente 1 milhão de entradas diárias e o Inverno é a estação que apresenta os valores mais baixos, situando-se em torno de 870 mil entradas e saídas diárias. Os intervalos de confiança a 95% confirmam que estas diferenças são estatisticamente relevantes, apesar de moderadas.

II. Impacto da precipitação na mobilidade




Figura 8 - Média diária de entradas na cidade por precipitação




Figura 9 - Média diária de saídas na cidade por precipitação

A análise da média diária de entradas e saídas na cidade mostra que a precipitação está associada a uma ligeira redução da mobilidade. Esta redução, apesar de não ser muito expressiva, é consistente em ambos os fluxos e é comprovada pelos IC95, que mostram uma sobreposição parcial, mas que ainda assim, indicam uma menor tendência da mobilidade em dias de precipitação. Este efeito sugere que a precipitação pode desincentivar algumas deslocamentos, especialmente se estas não forem essenciais.




Figura 10 - Média diária de entradas por eixo e precipitação




Figura 11 - Média diária de saídas por eixo e precipitação

As figuras 10 e 11 mostram as médias de entradas e saídas diárias por eixo em caso de precipitação e em caso de ausência da mesma, mostrando que a precipitação não altera de forma substancial os volumes de entrada e saída. No entanto, em alguns eixos, a precipitação está associada a ligeiros acréscimos de trânsito, visíveis tanto nas entradas como nas saídas. Em contrapartida, na Ponte 25 de Abril regista-se uma redução clara em dias de precipitação, sugerindo que esta pode levar a uma redistribuição de trânsito para a Ponte Vasco da Gama, ainda que neste eixo o efeito não seja tão evidente. Também na Marginal se verifica uma diminuição consistente em dias chuvosos que poderá estar relacionada com a menor procura deste eixo no que toca a deslocações não essenciais.




Figura 12 - Média de entradas por hora, eixo e precipitação na A1, A36, A5 e Calçada de Carriche




Figura 13 - Média de entradas por hora, eixo e precipitação no IC16, IC19, IC2 e Marginal




Figura 14 - Média de entradas por hora, eixo e precipitação na N117, Ponte 25 de Abril e Ponte Vasco da Gama




Figura 15 - Média de saídas por hora, eixo e precipitação na A1, A36, A5 e Calçada de Carriche




Figura 16 - Média de saídas por hora, eixo e precipitação no IC16, IC19, IC2 e Marginal




Figura 17 - Média de saídas por hora, eixo e precipitação na N117, Ponte 25 de Abril e Ponte Vasco da Gama

A análise dos perfis horários por eixo mostra que a precipitação não altera de forma significativa o período em que as horas de ponta ocorrem, que permanecem consistentes nos dois períodos habituais: entre as 8h e as 9h da parte da manhã e entre as 17h e 18h na parte da tarde. Na maioria dos eixos, os picos registam-se nos mesmos intervalos de tempo, apenas variando a intensidade do trânsito. No entanto, na maioria dos eixos, a precipitação contribui para um ligeiro alargamento das horas de ponta, mantendo os volumes de trânsito elevado durante mais tempo. Este aumento pode traduzir um ajuste de rotinas de acordo com as condições meteorológicas, levando os indivíduos a antecipar a saída de casa em dias de chuva, de forma a assegurar a chegada aos seus compromissos de forma pontual e/ou também à redução das velocidades médias e à consequente dispersão do fluxo ao longo destes períodos.

III. Impacto das greves dos transportes na mobilidade




Figura 18 - Média diária de entradas na cidade por greve




Figura 19- Média diária de saídas na cidade por greve

As figuras 18 e 19 indicam que há uma ligeira redução da mobilidade durante os períodos de paralisação dos transportes públicos, ainda que moderada. Os intervalos de confiança a 95% apresentam alguma sobreposição, indicando que a variação não é muito expressiva estatisticamente. Ainda assim, análise sugere que há uma tendência de redução da mobilidade nos dias de greve, mesmo que não elimine a procura de deslocações.




Figura 20 - Média diária de entradas por eixo e greve




Figura 21 - Média diária de saídas por eixo e greve

A análise da média de entradas e saídas por eixo evidencia que os dias de greve estão associados uma redução geral dos fluxos de mobilidade na cidade na grande parte dos eixos. No entanto, tanto na Ponte Vasco da Gama como na Marginal, o volume de entradas e saídas é superior em dias de greve, sugerindo um efeito de redistribuição modal onde, perante a redução da oferta de transporte público, parte dos utilizadores opta pelo seu transporte individual e recorre a estes eixos como alternativa. Assim, podemos ver que as greves não resultam apenas numa quebra de mobilidade, mas também numa reorganização da mesma, com maior pressão sobre alguns eixos alternativos.




Figura 22 - Média de entradas diárias por eixo e entidade da greve




Figura 23 - Média de saídas diárias por eixo e entidade da greve

As figuras 22 e 23 mostram que o impacto das greves se traduz essencialmente numa redistribuição espacial e modal dos fluxos. Uma vez que os dados em análise correspondem a registos de dispositivos móveis, os utilizadores continuam a entrar e a sair de Lisboa em dias de greve, mas recorrem a meios de transporte alternativos, nomeadamente ao automóvel.

As greves do Metropolitano de Lisboa são as que apresentam maior efeito, traduzindo-se em acréscimos significativos de trânsito rodoviário em praticamente todos os eixos. As greves da CP refletem-se sobretudo nos eixos servidos pelas linhas ferroviárias de Sintra e do Norte, com destaque para o IC19 e o IC2 (Sacavém), onde se observam aumentos de trânsito. Já as greves da Fertagus não só não revelam acréscimos nos volumes de trânsito, como revelam reduções, que sugere que os utilizadores reduzem as deslocações não essenciais. Por fim, as

greves da Carris apresentam efeitos pouco expressivos nos principais eixos.




Figura 24 - Média de entradas por hora, eixo e greve na A1, A36, A5 e Calçada de Carriche




Figura 25 - Média de entradas por hora, eixo e greve no IC16, IC19, IC2 e Marginal




Figura 26 - Média de entradas por hora, eixo e greve na N117, Ponte 25 de Abril e Ponte Vasco da Gama




Figura 27 - Média de saídas por hora, eixo e greve na A1, A36, A5 e Calçada de Carriche




Figura 28 - Média de saídas por hora, eixo e greve no IC16, IC19, IC2 e Marginal




Figura 29 - Média de saídas por hora, eixo e greve na N117, Ponte 25 de Abril e Ponte Vasco da Gama

Relativamente ao impacto que as greves dos transportes têm nos perfis horários de cada eixo, podemos ver que em praticamente todos os eixos, tanto nas entradas como nas saídas, os períodos habituais de maior intensidade, das 8h às 9h da parte da manhã e das 17h às 18h da parte da tarde, se mantêm, observando apenas uma ligeira redução dos fluxos nos dias de greve. Por outro lado, a Marginal tem o comportamento inverso, em que durante as greves se registam maiores volumes de trânsito que reflete a anteriormente mencionada transferência de fluxos dos transportes públicos para o automóvel.

IV. Impacto dos feriados nos padrões de mobilidade




Figura 30 - Média diária de entradas na cidade por feriado




Figura 31 - Média diária de saídas na cidade por feriado

A análise das entradas e saídas da cidade nos dias de feriado revela uma redução bastante expressiva quando comparada com dias normais. Enquanto em dias sem feriado a média diária de entradas e saídas na cidade se situa em cerca de 950mil, nos dias de feriado este valor baixa

em cerca de 200mil. Os intervalos de confiança a 95% mostram pouca sobreposição entre os dois grupos, indicando que esta redução de trânsito é estatisticamente relevante. Estes resultados refletem o efeito da quebra das atividades laborais e escolares nos feriados, que se traduz na redução significativa da mobilidade.




Figura 32 - Média diária de entradas na cidade por eixo e feriado




Figura 33 - Média diária de saídas da cidade por eixo e feriado

No que concerne às entradas e saídas por eixo, podemos observar uma redução significativa em todos os eixos. Esta diferença é especialmente visível nos eixos de maior intensidade, onde as entradas e saídas em dias de feriado representam cerca de metade do volume observado em dias normais. No eixo com menor procura, a Marginal, a redução também se verifica, ainda que de forma menos acentuada. Assim, esta análise confirma que os feriados estão associados a uma redução significativa da mobilidade, evidenciando assim uma forte relação entre a

mobilidade e a rotina semanal.




Figura 34 - Média de entradas por hora, eixo e feriado na A1, A36, A5 e Calçada de Carriche




Figura 35 - Média de entradas por hora, eixo e feriado no IC16, IC19, IC2 e Marginal




Figura 36 - Média de entradas por hora, eixo e feriado na N117, Ponte 25 de Abril e Ponte Vasco da Gama




Figura 37 - Média de saídas por hora, eixo e feriado na A1, A36, A5 e Calçada de Carriche




Figura 38 - Média de saídas por hora, eixo e feriado no IC16, IC19, IC2 e Marginal




Figura 39 - Média de saídas por hora, eixo e feriado na N117, Ponte 25 de Abril e Ponte Vasco da Gama

Quanto aos perfis horários em dias de feriado, temos diferenças claras face aos dias normais. Enquanto em dias normais existem claramente dois picos, as horas de ponta das 8h e das 17, associados aos movimentos pendulares de entrada e saída na cidade, nos feriados este não é o padrão. Tanto nas entradas como nas saídas, os fluxos apresentam uma menor intensidade e uma distribuição mais diluída ao longo do dia, sem a concentração típica nas horas de ponta. Ainda assim, nos eixos da Ponte Vasco da Gama, Ponte 25 de Abril e IC19, existe uma intensificação da mobilidade no período entre o final da manhã e o início da tarde, muito provavelmente ligada a deslocações de lazer.

V. Impacto das férias escolares na mobilidade




Figura 40 - Média diária de entradas na cidade por férias escolares




Figura 41 - Média diária de saídas da cidade por férias escolares

As figuras 40 e 41 mostram uma ligeira redução da mobilidade em período de férias escolares, tanto nas entradas como nas saídas da cidade. Os intervalos de confiança a 95% revelam uma sobreposição parcial, sugerindo que a diferença, apesar de estar presente, não é tão acentuada como, por exemplo, nos feriados. Assim, tudo indica que as férias escolares atenuam ligeiramente a intensidade da mobilidade, particularmente devido à ausência das deslocações associadas à atividade escolar e académica, mas sem provocar uma queda expressiva.




Figura 42 - Média diária de entradas na cidade por eixo e férias escolares




Figura 43 - Média diária de saídas da cidade por eixo e férias escolares

A análise da média diária de entradas e saídas por eixo viário mostra que o IC2 (Sacavém), a Marginal e a Calçada de Carriche registam uma quebra clara de trânsito, refletindo o peso das deslocações escolares nas rotinas pendulares. A exceção encontra-se na Ponte Vasco da Gama, onde se verifica um aumento do volume de trânsito durante períodos não letivos. Isto sugere que a ponte assume um papel distinto, captando especialmente deslocações de lazer.




Figura 44 - Média de entradas por hora, eixo e férias escolares na A1, A36, A5 e Calçada de Carriche




Figura 45 - Média de entradas por hora, eixo e férias escolares no IC16, IC19, IC2 e Marginal




Figura 46 - Média de entradas por hora, eixo e férias escolares na N117, Ponte 25 de Abril e Ponte Vasco da Gama




Figura 47 - Média de saídas por hora, eixo e férias escolares na A1, A36, A5 e Calçada de Carriche




Figura 48 - Média de saídas por hora, eixo e férias escolares no IC16, IC19, IC2 e Marginal




Figura 49 - Média de saídas por hora, eixo e férias escolares na N117, Ponte 25 de Abril e Ponte Vasco da Gama

A análise dos perfis horários de entradas e saídas da cidade durante períodos marcados pelas férias escolares revela que os padrões de mobilidade se mantêm semelhantes aos registados fora desse período, mantendo a ocorrência das horas de ponta habituais. No entanto, a intensidade do trânsito tende a ser ligeiramente inferior durante as férias, resultando numa menor pressão dos principais eixos de acesso. Este efeito é especialmente visível no IC2 (Sacavém), na Marginal e na Calçada de Carriche, onde os valores caem de maneira mais significativa. Já na Ponte Vasco da Gama, os volumes parecem aumentar nos períodos de férias, no entanto, são mais diluídos ao longo do dia e menos concentrados, que reforça a ideia de viagens ocasionais e de lazer, que são mais frequentes nesse período.

Os gráficos desenvolvidos em *PowerBI* não se limitaram a ilustrar os resultados, mas assumiram um papel central na análise ao organizar a informação de forma clara e acessível.

Estas visualizações permitiram evidenciar padrões pendulares, oscilações sazonais e diferenças entre eixos, bem como destacar anomalias relevantes que poderiam passar despercebidas numa análise puramente estatística. Ao transformar grandes volumes de dados em representações visuais, os gráficos contribuíram para uma interpretação mais aprofundada e facilitaram a comunicação dos resultados, reforçando não só a compreensão da complexidade da mobilidade urbana como também a utilidade prática da análise, enquanto suporte para a tomada de melhores decisões.

3.4.2. Prophet

Nesta subsecção serão apresentadas as previsões obtidas pelo modelo *Prophet*, com o objetivo de avaliar o seu desempenho. O *Prophet* é um modelo de previsão de séries temporais desenvolvido pelo Facebook/Meta, que combina tendências lineares e não lineares com sazonalidades múltiplas e efeitos de calendário, o que o torna adequado para contextos urbanos caracterizados por forte estrutura pendular e elevada influência de feriados [27].

Para a sua implementação, os dados foram divididos em treino (80%) e teste (20%), assegurando a validação dos resultados. Para além disso, foram testadas duas configurações:

- i) *Prophet* simples, considerando apenas as componentes sazonais diária, semanal e anual; e
- ii) *Prophet* com *regressors*, no qual foram integradas as variáveis contextuais: feriados, greves, férias escolares e precipitação.

O *Prophet* foi inicialmente aplicado aos dados com uma granularidade horária, com o objetivo de prever as entradas por eixo e os resultados, apresentados na tabela 5, evidenciam que em diversos eixos os valores do erro médio absoluto (MAE) e relativos (MAPE) foram demasiado elevados, indicando que o modelo, na sua parametrização inicial, não conseguiu ajustar-se adequadamente às oscilações horárias. Para além disso, a inclusão de *regressors* não se traduziu, em todos, os casos, numa melhoria do desempenho, verificando-se inclusive aumentos no erro em alguns eixos.

Tabela 5 - Resultados do Prophet com agregação horária: MAE e MAPE por eixo

Eixo	MAE Simples	MAPE Simples (%)	MAE com <i>Regressors</i>	MAPE com <i>Regressors</i> (%)
A1	50536.57	1571.57	57850.40	1797.72
A36 (Túnel do grilo)	1274.69	97.48	29315.50	1861.31
IC16	3811.46	154.18	3909.98	158.49
N117 (Cabos Ávila)	3772.07	218.99	3668.44	212.77
Ponte 25 de Abril	5811.59	355.81	4989.45	303.80
IC19	5585.15	155.15	4958.04	138.49
Calçada de Carriche	1556.92	113.95	2406.23	188.98
A5	6153.82	296.02	6625.71	320.46
Ponte Vasco da Gama	22273.98	14183.24	1828.68	1088.25
IC2 (Sacavém)	4541.17	127.18	4829.39	135.74
Marginal	289207.02	104835.91	329618.57	119619.11

Tendo em conta estes resultados, conclui-se que o *Prophet*, nesta configuração, não foi capaz de capturar de forma satisfatória as variações de trânsito. Este desempenho pode ser explicado pelo facto do modelo não se adequar tão bem a séries temporais com granularidades mais finas, como dados com uma granularidade horária [27], [28]. Tal comportamento resulta da elevada variabilidade e do ruído característicos dos dados horários de trânsito urbano. As oscilações entre horas de ponta e períodos de menor movimento, bem como a presença de observações com valores muito baixos, amplificam os valores do MAE e do MAPE e dificultam a deteção de padrões consistentes.

Por este motivo, optou-se por testar novamente o modelo com dados agregados a nível diário, de modo a avaliar se uma resolução temporal mais adequada é possível melhorar o desempenho preditivo.

Inicialmente, o modelo foi testado com uma agregação diária na sua configuração *default* e os resultados obtidos foram os seguintes:

Tabela 6 - Resultados do Prophet com agregação diária: MAE e MAPE por eixo

Eixo	MAE Simples	MAPE Simples (%)	MAE com <i>Regressors</i>	MAPE com <i>Regressors</i> (%)
A1	118894.98	144.77	42589.42	69.57
A36 (Túnel do grilo)	21364.83	61.92	22212.52	63.01
IC16	36747.81	66.51	38285.13	70.17
N117 (Cabos Ávila)	36421.27	92.08	37290.35	93.41
Ponte 25 de Abril	58951.91	102.95	58325.96	102.42
IC19	55479.12	74.45	56969.38	76.36
Calçada de Carriche	22286.80	56.39	23519.49	58.93
A5	50837.27	87.35	54049.20	92.09
Ponte Vasco da Gama	28770.42	130.13	29836.81	137.35
IC2 (Sacavém)	38803.41	60.04	39667.19	58.52
Marginal	22475.38	298.54	71001.56	1071.23

Verifica-se que, apesar do modelo aplicado aos dados com uma agregação diária demonstrar uma melhoria significativa e capacidade para reproduzir a estrutura global da série, os erros absolutos (MAE) e relativos (MAPE) permanecem elevados em vários eixos.

Assim, foi realizado um *tuning* dos principais hiperparâmetros do *Prophet* (*hyperparameter tuning*), com o intuito de avaliar potenciais ganhos de *performance*. Testaram-se combinações discretas de *changepoint_prior_scale* $\in \{0.01, 0.1, 0.5\}$ e *seasonality_prior_scale* $\in \{1.0, 5.0,$

10.0}, selecionando-se, para cada eixo, a configuração que produziu o menor MAPE no conjunto de teste. Os resultados após *tuning* encontram-se na seguinte tabela:

Tabela 7 - Resultados do Prophet com agregação diária após *tuning*: MAE e MAPE por eixo


Eixo	MAE Simples	MAPE Simples (%)	MAE com <i>Regressors</i>	MAPE com <i>Regressors</i> (%)
A1	37097.94	62.13	37026.01	61.16
A36 (Túnel do grilo)	21912.98	64.09	22423.61	62.73
IC16	35075.61	64.61	37066.58	67.66
N117 (Cabos Ávila)	34554.02	89.49	36981.14	92.58
Ponte 25 de Abril	58319.56	101.71	58653.95	103.05
IC19	51579.49	70.22	56851.59	77.07
Calçada de Carriche	22400.76	54.40	23743.85	59.44
A5	50565.44	87.33	52325.18	89.56
Ponte Vasco da Gama	24891.65	111.07	28604.34	126.59
IC2 (Sacavém)	34126.38	53.49	39684.26	58.68
Marginal	21182.29	258.21	26031.01	315.81





Observa-se uma melhoria significativa em alguns eixos: na A1, por exemplo, o MAE reduziu de 118894.98 (simples, *default*) para 37097.94 (simples, *tuned*), enquanto no modelo com *regressors* passou de 42 589,42 para 37 026,01. Em termos relativos, o MAPE diminuiu de 144,77% para 62,13% no modelo simples e de 69,57% para 61,16% no modelo com *regressors*, o que indica que o *tuning* permitiu um ajuste mais eficaz da tendência e da sazonalidade neste eixo. Outro caso relevante é a Marginal, onde o MAE baixou de 22 475,38 para 21 182,29 no modelo simples e de 71 001,56 para 26 031,01 no modelo com *regressors*, acompanhado por uma descida do MAPE de 298,54% para 258,21% e de 1071,23% para 315,81%, respetivamente, revelando que o *Prophet* continua incapaz de reproduzir a elevada variabilidade deste eixo, mesmo após o ajuste de hiperparâmetros.

Apesar destas melhorias, em vários eixos os ganhos foram marginais e a inclusão de variáveis externas não trouxe benefícios consistentes em relação ao modelo simples, sugerindo que a principal contribuição do *tuning* incidiu no ajuste da tendência e da sazonalidade. Ainda assim, estes resultados evidenciam que as limitações do *Prophet* decorrem sobretudo da complexidade e natureza dinâmica dos dados de trânsito, e não apenas da parametrização do modelo. O comportamento do trânsito urbano é fortemente não linear e influenciado por múltiplos fatores externos, o que dificulta a sua representação através de uma estrutura aditiva

com sazonalidades fixas, conduzindo a erros mais elevados em eixos com variações mais abruptas.

Para além das tabelas comparativas, optou-se por representar graficamente os resultados, de forma a ilustrar a capacidade do *Prophet* em reproduzir a evolução dos fluxos de entrada. Para cada eixo, os modelos foram reajustados com a totalidade dos dados e projetados para a primeira semana de 2024. Nas figuras seguintes apresenta-se, a preto, a série real correspondente a dezembro de 2023, e a continuação em laranja e azul corresponde às previsões do *Prophet* simples e do *Prophet* com *regressors*, respetivamente.








Figura 50 - Previsões do Prophet por eixo após *tuning*

A análise gráfica dos resultados complementa as tabelas apresentadas no sentido em que, em alguns eixos, as previsões acompanham de forma satisfatória a trajetória dos valores reais observados em dezembro, sugerindo que o modelo conseguiu captar a tendência e a sazonalidade predominantes.

No caso da A1, por exemplo, as curvas previstas prolongam, de forma coerente, a evolução real, confirmando a redução dos erros após o tuning. Da mesma forma que, na Marginal, apesar dos valores de erro absoluto continuem elevados, a inclusão de *regressors* permitiu uma aproximação mais consistente à série real.

No entanto, em alguns eixos subsistem desvios significativos entre valores observados e previstos, o que indica que, apesar do ajuste dos hiperparâmetros, o *Prophet* mantém limitações na capacidade de reproduzir oscilações mais abruptas. Ainda assim, importa destacar que o modelo evidenciou utilidade na deteção de tendências gerais e de variações semanais, permitindo identificar períodos de maior e menor trânsito, mesmo que sem elevada precisão.

De modo a concluir, o desempenho do *Prophet* decorre essencialmente das características do fenómeno estudado, que é fortemente irregular, não linear e condicionado por fatores externos de difícil modelação. O modelo mostrou-se adequado para identificar padrões sazonais e tendências, mas revelou dificuldades em acompanhar as variações abruptas e a imprevisibilidade associada ao trânsito urbano. Assim, as limitações observadas resultam menos de insuficiências técnicas do modelo e mais da complexidade inerente à dinâmica do trânsito em Lisboa, marcada por múltiplas interações, variação intra-diária e forte influência de fatores exógenos.

Desta forma, os gráficos reforçam que, apesar do modelo ser eficaz para captar a tendência e a sazonalidade global, a sua aplicação em contextos de mobilidade urbana, caracterizados por elevada variabilidade e forte influência de fatores externos, pode não ser a mais adequada, uma vez que não garante previsões suficientemente fiáveis para apoiar a análise operacional destes sistemas.

3.5. Implementação

Esta fase consiste na transformação dos resultados da análise em valor prático, ou seja, levar o conhecimento obtido para além do ambiente experimental. No entanto, esta fase pode envolver relatórios, artigos ou *dashboards* [6]. Neste sentido, a implementação consistiu na sistematização dos resultados obtidos, na criação de *dashboards* em *PowerBI* e na elaboração

desta dissertação. Adicionalmente, foi também implementado o modelo *Prophet*, permitindo integrar uma vertente preditiva no processo analítico e avaliar a sua utilidade no contexto da mobilidade urbana. Assim, o presente trabalho funciona como prova de conceito ao demonstrar o potencial dos sistemas de apoio à decisão baseados em dados para gerar *insights* relevantes sobre os padrões da mobilidade urbana em Lisboa.

CAPÍTULO 4

Resultados e Discussão

Este capítulo apresenta e discute os resultados obtidos, organizados de acordo com as perguntas de investigação (PI) e objetivos (OBJ) definidos anteriormente.

Primeiramente, no âmbito da PI1, “Quais as técnicas mais proeminentes para a análise de dados de cidades inteligentes?”, a revisão da literatura apresentada no Capítulo 2 permitiu identificar o papel central da IoT e da inteligência artificial na previsão de trânsito urbano, destacando a relevância de modelos baseados em *deep learning* (como LSTM, GRU, CNN e GNN). Essa análise demonstrou que tais técnicas superam os métodos estatísticos tradicionais, enquanto revelaram desafios relacionados com a necessidade de grandes volumes de dados, a complexidade computacional e a proteção da privacidade. Esta revisão constituiu a base conceptual necessária para sustentar a análise empírica desenvolvida nos pontos seguintes.

No âmbito da PI2, “Como é que a precipitação afeta os padrões de mobilidade nos principais eixos de Lisboa?”, de acordo com a análise de dados que foi conduzida no Capítulo 3, em dias de chuva observa-se uma ligeira diminuição no número de entradas e saídas da cidade que, apesar de não refletir uma quebra acentuada nos fluxos, reflete um desincentivo às deslocações não essenciais. No entanto, os fluxos não estão distribuídos de forma homogênea pelos diferentes eixos viários: enquanto na Ponte 25 de Abril e na Marginal há uma diminuição mais clara dos fluxos, no IC19 e IC2 (Sacavém) há um ligeiro aumento de trânsito. Assim, para além de apenas uma redução da mobilidade, a precipitação provoca, sobretudo, uma redistribuição espacial da mobilidade.

No que respeita ao perfil temporal, os períodos de maior intensidade de trânsito mantêm-se concentrados nas horas de ponta da manhã, entre as 8h e as 9h, e da tarde, entre as 17h e as 18h. No entanto, em dias de chuva, esses picos tendem a prolongar-se por mais tempo, resultando em períodos de trânsito mais extensos. Este fenómeno poderá estar associado a alterações comportamentais dos utilizadores, tais como sair de casa mais cedo ou a diminuição da velocidade de circulação, que alastra os volumes de trânsito ao longo do tempo.

Importa ainda referir que, neste estudo, a variável “precipitação” foi considerada de forma binária (presença ou ausência de precipitação). Esta simplificação, embora adequada para uma análise inicial, poderá não captar diferenças entre níveis de intensidade, uma vez que episódios de chuva ligeira e de chuva intensa tendem a afetar a mobilidade de forma distinta. A consideração futura de variáveis contínuas ou categorizadas por intensidade poderá, assim, melhorar a sensibilidade da análise e a interpretação dos seus efeitos sobre os fluxos de trânsito.

Relativamente à PI3, “De que forma eventos pontuais como greves, feriados e interrupções letivas afetam os padrões de mobilidade nos eixos de entrada/saída de Lisboa?”, os resultados apresentados no Capítulo 3 mostram que os eventos pontuais, como greves, feriados e interrupções letivas, afetam a mobilidade em Lisboa de maneiras distintas. No caso das greves, o impacto não se revela apenas numa quebra nos volumes da mobilidade, mas essencialmente numa redistribuição espacial e modal dos fluxos. Isto significa que os utilizadores continuam a realizar as suas deslocações, mas alteram os meios de transporte e os percursos escolhidos. As greves do Metropolitano de Lisboa têm o efeito mais expressivo, aumentando significativamente o trânsito rodoviário em praticamente todos os eixos. Já as greves da CP refletem-se principalmente no IC19 e no IC2 (Sacavém), acompanhando as linhas de Sintra e do Norte. As greves da Fertagus não provocam aumentos no volume da mobilidade, pelo contrário, sugerindo que os utilizadores optam por adiar deslocações não essenciais. Já as greves da Carris têm efeitos menos relevantes. Ainda assim, os picos horários da manhã (8h – 9h) e da tarde (17h – 18h) mantêm-se. No entanto, a Marginal apresenta-se como um caso particular, em que tende a receber um maior volume de trânsito em dias de greve, funcionando como via alternativa para quem troca o transporte público pelo seu veículo individual.

Nos feriados, verifica-se uma redução expressiva da mobilidade na qual, em média, entram e saem cerca de 200 mil utilizadores a menos comparativamente a dias normais. Esta quebra é transversal a todos os eixos e estatisticamente significativa. Os perfis horários de cada eixo também sofrem alterações, no sentido em que deixam de existir os picos pendulares típicos e a mobilidade distribui-se de forma mais consistente ao longo do dia. No entanto, observa-se uma intensificação do trânsito entre o final da manhã e o início da tarde, associada a deslocações de lazer e não a deslocações laborais.

Por fim, as interrupções letivas apresentam um efeito mais moderado, no qual se regista uma ligeira diminuição do trânsito, especialmente nos eixos onde as deslocações escolares têm maior peso, nomeadamente no IC2 (Sacavém), na Marginal e na Calçada de Carriche. A exceção é a Ponte Vasco da Gama, onde se vê um aumento da mobilidade durante os períodos de férias, mais uma vez associado a deslocações de lazer. No entanto, apesar da ligeira variação de intensidade, a estrutura pendular dos fluxos mantém-se, com os mesmos horários de ponta, mas com menos pressão nos principais eixos.

De modo a concluir, no que concerne à PI4, ‘Qual o desempenho do modelo *Prophet* na previsão dos fluxos de mobilidade em Lisboa?’, verificou-se que, apesar da melhoria obtida com a agregação diária e com o *tuning* dos hiperparâmetros, os erros permaneceram elevados para os vários eixos, não permitindo considerar as previsões satisfatórias. Este resultado é

consistente com a literatura, onde modelos estatísticos como o *Prophet* são considerados menos adequados para lidar com a elevada variabilidade dos padrões urbanos, em comparação com arquiteturas de *deep learning*. Ainda assim, a análise gráfica mostrou que o modelo conseguiu prolongar a tendência global da série e identificar variações entre dias, evidenciando alguma utilidade exploratória. A principal vantagem do *Prophet* continua a residir na sua simplicidade de implementação e baixo custo computacional, podendo ser relevante em cenários exploratórios ou quando os recursos disponíveis são limitados. Neste sentido, conclui-se que apesar do *Prophet* não apresentar previsões suficientemente robustas para aplicações práticas, pode contribuir para a compreensão dos padrões temporais e complementar outras abordagens de modelação mais adequadas à complexidade da mobilidade urbana.

Por fim, estes resultados reforçam que sistemas de decisão em *smart cities* exigem modelos capazes de conjugar precisão e resposta em tempo real. O *Prophet* pode assumir um papel complementar em análises preliminares, mas para a gestão operacional da mobilidade urbana os modelos de *deep learning* revelam-se mais adequados, destacando-se na literatura pela sua capacidade de lidar com a variabilidade e a complexidade dos contextos urbanos.

CAPÍTULO 5

Conclusões

5.1. Conclusões

Através da análise desenvolvida foi possível responder aos objetivos inicialmente definidos, que consistiam em identificar as técnicas de análise de dados em *smart cities* (OBJ1), avaliar a influência da precipitação na mobilidade em Lisboa (OBJ2), analisar o impacto de eventos disruptivos, como greves, feriados e interrupções letivas, nos principais eixos viários da cidade (OBJ3) e avaliar o desempenho do *Prophet* na previsão da mobilidade urbana em Lisboa (OBJ4). A revisão de literatura mostrou que técnicas de análise de dados, em particular os modelos de *deep learning* e os sistemas baseados em IoT, constituem a base metodológica mais adequada para apoiar estudos de mobilidade urbana. Verificou-se que a mobilidade em Lisboa apresenta uma estrutura fortemente pendular, com dois períodos de maior intensidade: a hora de ponta da manhã, entre as 8h e as 9h, e a hora de ponta da tarde, entre as 17h e as 18h.

Os resultados revelaram ainda que fatores externos desempenham um papel decisivo na variação e intensidade do trânsito. No caso da precipitação, observou-se uma diminuição ligeira dos fluxos e no prolongamento das horas de ponta. Relativamente aos eventos pontuais, as greves tiveram um impacto distinto consoante a entidade a que a greve diz respeito. As greves do Metropolitano são as que mais originam aumentos significativos em todos os acessos à cidade, enquanto as da Carris mostraram poucos efeitos. Nos feriados registam-se reduções muito significativas da mobilidade e o desaparecimento dos padrões pendulares, sendo o trânsito concentrado em deslocações de lazer. Por outro lado, as interrupções letivas revelaram um efeito mais moderado, com diminuições de volume nos eixos associados às rotinas escolares.

No que respeita ao OBJ4, verificou-se que o *Prophet*, mesmo após a agregação diária dos dados e o *tuning* de hiperparâmetros, não alcançou resultados satisfatórios, uma vez que os erros permaneceram elevados nos vários eixos, limitando a sua utilidade prática neste estudo. No entanto, a aplicação do modelo demonstrou capacidade para prolongar a tendência global das séries e evidenciar variações entre dias, o que revela algum potencial enquanto ferramenta exploratória, nomeadamente na identificação de padrões temporais mais gerais.

Assim, o *Prophet* pode ser considerado um modelo de utilidade limitada, mas com algum valor exploratório, especialmente quando usado em conjunto com abordagens mais robustas. Esta constatação reforça as limitações mencionadas no estado da arte quanto ao uso de modelos

estatísticos em contextos urbanos e sublinha a relevância dos modelos de *deep learning* como alternativas mais fidedignas [1], [16], [21].

5.2. Contributos e Limitações

O presente trabalho contribui para o conhecimento da mobilidade urbana em Lisboa ao demonstrar de que forma fatores externos, nomeadamente a precipitação, greves dos transportes, feriados e interrupções letivas, afetam os padrões de entrada e saída da cidade de Lisboa. A utilização de dados de dispositivos móveis permitiu uma análise de elevada granularidade, oferecendo uma perspetiva inovadora sobre os fluxos de trânsito. Para além do contributo académico, esta dissertação fornece insights que podem apoiar a definição de políticas públicas e a gestão eficiente da mobilidade, especialmente no que concerne ao planeamento de respostas a eventos disruptivos ou na adaptação de estratégias de transporte em dias de maior pressão viária. Adicionalmente, foi também conduzida uma abordagem complementar com a aplicação do modelo *Prophet*, que representou um contributo metodológico ao permitir testar uma abordagem preditiva sobre os fluxos de mobilidade.

Para além da realidade de Lisboa, a metodologia seguida neste estudo é passível de ser replicada noutras cidades com características semelhantes, permitindo comparar dinâmicas de mobilidade, identificar padrões de comportamento e avaliar o impacto de fatores externos em contextos distintos. Esta possibilidade de transferência reforça a utilidade prática do trabalho, ao demonstrar que análises baseadas em dados de mobilidade e variáveis contextuais podem apoiar decisões mais informadas e orientadas por evidência.

No entanto, este estudo também se deparou com algumas limitações. A dependência de dados provenientes de uma única operadora móvel pode introduzir enviesamentos na representatividade da amostra, apesar da sua dimensão e relevância. Acresce o facto de poder haver utilizadores que, estando com o dispositivo desligado da rede móvel, não são captados pelos registos, o que poderá afetar a precisão dos fluxos observados. A análise focou-se ainda em variáveis contextuais específicas, não incluindo outros fatores que também podem influenciar a mobilidade, tais como obras rodoviárias, acidentes ou eventos culturais e desportivos. Para além disso, o elevado volume e peso dos dados representaram um desafio na fase de limpeza e preparação dos dados, condicionando a eficiência do processo. Do ponto de vista metodológico, a implementação do *Prophet* revelou-se também uma limitação uma vez que, apesar do *tuning* efetuado, os resultados não foram suficientemente robustos para apoiar a gestão prática da mobilidade urbana.

Do ponto de vista pessoal e metodológico, o desenvolvimento desta dissertação proporcionou aprendizagens profundas sobre todo o ciclo analítico, desde a preparação dos dados até à modelação e validação dos resultados. O maior desafio residiu na integração e limpeza da informação, um processo exigente que evidenciou a importância de garantir qualidade e consistência antes de avançar para a análise. Este percurso permitiu-me compreender a relevância de equilibrar tempo, foco e complexidade, reconhecendo que soluções mais simples e bem estruturadas podem ser tão eficazes quanto abordagens tecnicamente mais ambiciosas. Se tivesse de recomençar este trabalho, teria simplificado alguns procedimentos de preparação de dados e explorado com mais profundidade a vertente preditiva, mantendo o foco e a coerência metodológica.

De uma forma geral, o projeto demonstrou também o papel que a análise de dados pode desempenhar na gestão urbana. A principal contribuição prática deste trabalho está na criação de uma base que permite tomar decisões mais informadas e proativas, como por exemplo, antecipar períodos de maior trânsito, planear medidas preventivas e otimizar recursos de transporte. Ao integrar diferentes dimensões da mobilidade, o estudo reforça o potencial dos sistemas de apoio à decisão como instrumentos essenciais para uma gestão urbana mais eficiente, sustentável e orientada por evidência.

Apesar destas limitações, considera-se que os resultados obtidos oferecem contributos relevantes tanto para a investigação científica como para a gestão da mobilidade em Lisboa.

5.3. Recomendações e Trabalhos futuros

Com base nos resultados obtidos, é pertinente avançar com algumas recomendações com utilidade para a gestão da mobilidade urbana em Lisboa. Primeiramente, existe uma necessidade de reforçar a integração de diferentes fontes de dados, desde transportes públicos a sensores de trânsito, de modo a melhorar o acompanhamento dos fluxos de trânsito e apoiar decisões mais informadas. Depois, recomenda-se também que os decisores considerem medidas capazes de responder a variações inesperadas, como greves ou condições meteorológicas adversas, assegurando alternativas eficazes para os utilizadores.

Analiticamente, seria igualmente relevante realizar uma comparação entre diferentes períodos temporais, por exemplo, entre 2023 e 2024 de forma a identificar alterações nos padrões de mobilidade, avaliar o impacto de medidas implementadas e detetar possíveis mudanças estruturais no comportamento dos utilizadores. Essa análise longitudinal acrescentaria uma perspetiva evolutiva à investigação, permitindo compreender se as

tendências observadas são pontuais ou sustentadas ao longo do tempo.

No que concerne ao plano científico, futuros trabalhos poderão beneficiar de dados provenientes de diversas operadoras móveis, de modo a aumentar a representatividade. A inclusão de variáveis demográficas, como faixas etárias, seria igualmente relevante para melhor compreender as diferenças de mobilidade entre grupos populacionais. Para além disso, a análise de outros fatores contextuais, ou o refinamento de variáveis já existentes, como a precipitação, que neste estudo foi tratada de forma binária (Sim/Não), permitiria um retrato mais completo da mobilidade na cidade. A distinção entre diferentes níveis de intensidade da precipitação permitiria captar de forma mais precisa o impacto das condições meteorológicas nos fluxos de trânsito, diferenciando, por exemplo, entre chuva ligeira e intensa.

Já na vertente metodológica, seria importante aprofundar a componente preditiva do estudo, explorando modelos mais avançados e comparando o seu desempenho com o *Prophet*. A aplicação do modelo neste trabalho demonstrou que o *Prophet* foi útil para identificar tendências e sazonalidades, mas revelou sensibilidade ao ruído e à irregularidade dos dados. Assim, abordagens baseadas em *deep learning*, como LSTM, GRU, CNN ou GNN, poderão oferecer maior capacidade de adaptação a padrões não lineares e variabilidade temporal. Também seria relevante testar modelos estatísticos clássicos, como ARIMA ou SARIMA, que poderiam servir como linha de base para comparação. Ainda assim, poderá ser relevante considerar abordagens híbridas, que integrem o *Prophet* e técnicas de *deep learning*, de forma a explorar o seu potencial como complemento a modelos mais avançados. Esta abordagem seria particularmente útil em contextos de mobilidade, onde a compreensão dos fatores que influenciam o trânsito é tão importante quanto a precisão das previsões.

Referências Bibliográficas

- [1] R. P. Magalhaes *et al.*, «Speed prediction in large and dynamic traffic sensor networks», *Inf. Syst.*, vol. 98, 2021, doi: 10.1016/j.is.2019.101444.
- [2] S. T. Mrudula *et al.*, «Internet of things and optimized knn based intelligent transportation system for traffic flow prediction in smart cities», *Meas. Sens.*, vol. 35, 2024, doi: 10.1016/j.measen.2024.101297.
- [3] «LxDataLab», LISBOA ABERTA. Acedido: 29 de setembro de 2025. [Online]. Disponível em: <https://lisboaaberta.cm-lisboa.pt/index.php/pt/lx-data-lab/apresentacao>
- [4] «Europe's Leading City Destination 2023», World Travel Awards. Acedido: 29 de setembro de 2025. [Online]. Disponível em: <https://www.worldtravelawards.com/award-europes-leading-city-destination-2023>
- [5] Y. Chang, S. J. Jo, Y.-T. Lee, e Y. Lee, «Population Density or Populations Size. Which Factor Determines Urban Traffic Congestion?», *Sustainability*, vol. 13, p. 4280, abr. 2021, doi: 10.3390/su13084280.
- [6] C. Schröer, F. Kruse, e J. Marx Gómez, «A Systematic Literature Review on Applying CRISP-DM Process Model», *Procedia Comput. Sci.*, vol. 181, pp. 526–534, jan. 2021, doi: 10.1016/j.procs.2021.01.199.
- [7] T. Galvao, T. Andrade Pansani, e D. Harrad, «Principais itens para relatar Revisões sistemáticas e Meta-análises: A recomendação PRISMA», *Epidemiol Serv Saude*, vol. 24, jun. 2015, doi: 10.5123/S1679-49742015000200017.
- [8] B. Tedja, M. Musadieg, A. Kusumawati, e E. Yulianto, «Systematic literature review using PRISMA: exploring the influence of service quality and perceived value on satisfaction and intention to continue relationship», *Future Bus. J.*, vol. 10, abr. 2024, doi: 10.1186/s43093-024-00326-4.
- [9] Z. Miao e Q. Liao, «IoT-Based Traffic Prediction for Smart Cities», *IEEE ACCESS*, vol. 13, pp. 52369–52384, 2025, doi: 10.1109/ACCESS.2025.3552276.
- [10] I. Moumen, J. Abouchabaka, e N. Rafalia, «Enhancing urban mobility: integration of IoT road traffic data and artificial intelligence in smart city environment», *Indones. J. Electr. Eng. Comput. Sci.*, vol. 32, n.º 2, pp. 985–993, 2023, doi: 10.11591/ijeecs.v32.i2.pp985-993.
- [11] S. Alsubai, A. K. Dutta, e A. R. W. Sait, «Hybrid deep learning-based traffic congestion control in IoT environment using enhanced arithmetic optimization technique», *Alex. Eng. J.*, vol. 105, pp. 331–340, 2024, doi: 10.1016/j.aej.2024.06.072.
- [12] X. Fan *et al.*, «BuildSenSys: Reusing Building Sensing Data for Traffic Prediction with Cross-Domain Learning», *IEEE Trans. Mob. Comput.*, vol. 20, n.º 6, pp. 2154–2171, 2021, doi: 10.1109/TMC.2020.2976936.
- [13] H. Mehri, H. Mehrpouyan, e H. Chen, «RACH Traffic Prediction in Massive Machine Type Communications», *IEEE Trans. Mach. Learn. Commun. Netw.*, vol. 3, pp. 315–331, 2025, doi: 10.1109/TMLCN.2025.3542760.

- [14] X. Li, Y. Hu, L. Zeng, Y. An, J. Yang, e X. Xiao, «Blockchain-based federated learning approaches in internet of things applications», *Secur. Priv.*, vol. 7, n.º 6, nov. 2024, doi: 10.1002/spy2.435.
- [15] W.-C. Lee, Y.-B. Jeon, S.-S. Han, e C.-S. Jeong, «Position Prediction in Space System for Vehicles Using Artificial Intelligence», *Symmetry*, vol. 14, n.º 6, 2022, doi: 10.3390/sym14061151.
- [16] B. Karthika, N. Umamaheswari, e R. Venkatesh, «A research of traffic prediction using deep learning techniques», *Int. J. Innov. Technol. Explor. Eng.*, vol. 8, n.º 9 Special Issue 2, pp. 725–728, 2019, doi: 10.35940/ijitee.I1151.0789S219.
- [17] N. Zafar, I. U. Haq, J.-U.-R. Chughtai, e O. Shafiq, «Applying Hybrid Lstm-Gru Model Based on Heterogeneous Data Sources for Traffic Speed Prediction in Urban Areas», *Sensors*, vol. 22, n.º 9, 2022, doi: 10.3390/s22093348.
- [18] M. A. Hamza *et al.*, «Intelligent Slime Mould Optimization with Deep Learning Enabled Traffic Prediction in Smart Cities», *Comput. Mater. Contin.*, vol. 73, n.º 3, pp. 6563–6577, 2022, doi: 10.32604/cmc.2022.031541.
- [19] T. Shen, L. Zhang, R. Geng, S. Li, e B. Sun, «Traffic prediction for diverse edge IoT data using graph network», *J. Cloud Comput.*, vol. 13, n.º 1, 2024, doi: 10.1186/s13677-023-00543-2.
- [20] P. Devadhas Sujakumari e P. Dassan, «Generative Adversarial Networks (GAN) and HDFS-Based Realtime Traffic Forecasting System Using CCTV Surveillance», *Symmetry*, vol. 15, n.º 4, 2023, doi: 10.3390/sym15040779.
- [21] S. Mrad, R. Mraih, e A. S. Murthy, «Efficient implementation of a wavelet neural network model for short-term traffic flow prediction: Sensitivity analysis», *Int. J. Transp. Sci. Technol.*, 2024, doi: 10.1016/j.ijtst.2024.02.004.
- [22] J. Toutouh, J. Arellano, e E. Alba, «Bipred: A bilevel evolutionary algorithm for prediction in smart mobility», *Sensors*, vol. 18, n.º 12, 2018, doi: 10.3390/S18124123.
- [23] S. S. Sepasgozar e S. Pierre, «Fed-NTP: A Federated Learning Algorithm for Network Traffic Prediction in VANET», *IEEE Access*, vol. 10, pp. 119607–119616, 2022, doi: 10.1109/ACCESS.2022.3221970.
- [24] C. Pandey, V. Tiwari, A. Imoize, C. Li, C. Lee, e D. Roy, «5GT-GAN: Enhancing Data Augmentation for 5G-Enabled Mobile Edge Computing in Smart Cities», *IEEE ACCESS*, vol. 11, pp. 120983–120996, 2023, doi: 10.1109/ACCESS.2023.3328170.
- [25] S. Malik, M. A. Khan, H. El-Sayed, J. Khan, e O. Ullah, «Implanting Intelligence in 5G Mobile Networks—A Practical Approach», *Electron. Switz.*, vol. 11, n.º 23, 2022, doi: 10.3390/electronics11233933.
- [26] R. Azdy e F. Darnis, «Use of Haversine Formula in Finding Distance Between Temporary Shelter and Waste End Processing Sites», *J. Phys. Conf. Ser.*, vol. 1500, p. 012104, abr. 2020, doi: 10.1088/1742-6596/1500/1/012104.
- [27] S. J. Taylor e B. Letham, «Forecasting at Scale», *Am. Stat.*, vol. 72, n.º 1, pp. 37–45, jan. 2018, doi: 10.1080/00031305.2017.1380080.
- [28] «Non-Daily Data», Prophet. Acedido: 29 de setembro de 2025. [Online]. Disponível em: http://facebook.github.io/prophet/docs/non-daily_data.html

Anexos

Anexo A – Artigos incluídos na revisão sistemática (PRISMA)

Referência	Autores e Ano	Modelo / Abordagem Principal
[9]	Miao & Liao (2025)	IoT + <i>Machine Learning</i>
[10]	Moumen et al. (2023)	Integração IoT + IA
[11]	Alsubai et al. (2024)	<i>Deep Learning</i> híbrido + Otimização aritmética
[12]	Fan et al. (2021)	<i>Cross-domain learning</i> (transferência entre domínios)
[13]	Mehri et al. (2025)	Aprendizagem automática em redes IoT (RACH)
[14]	Li et al. (2024)	<i>Federated Learning</i> + <i>Blockchain</i>
[15]	Lee et al. (2022)	IA aplicada à previsão de posição veicular
[16]	Karthika et al. (2019)	<i>Deep Learning</i> (LSTM e CNN)
[17]	Zafar et al. (2022)	Modelo híbrido LSTM-GRU
[18]	Hamza et al. (2022)	<i>Deep Learning</i> + Otimização bio-inspirada
[19]	Shen et al. (2024)	<i>Graph Neural Networks</i> (GNN)
[20]	Sujakumari & Dassan (2023)	<i>Generative Adversarial Networks</i> (GAN)
[21]	Mrad et al. (2024)	<i>Wavelet Neural Networks</i> (WNN)
[22]	Toutouh et al. (2018)	Algoritmo evolutivo <i>bilevel</i> (BiPred)
[23]	Sepasgozar & Pierre (2022)	<i>Federated Learning</i> em VANETs (Fed-NTP)
[24]	Pandey et al. (2023)	5GT-GAN (<i>Deep Learning</i> + 5G Edge Computing)
[25]	Malik et al. (2022)	Sistemas inteligentes em redes 5G