



**PREVISÃO DE TRÁFEGO URBANO NO DISTRITO FEDERAL: APLICAÇÃO DE REDES NEURAS
DE PREVISÃO DE TRÁFEGO UTILIZANDO DADOS ESPAÇO-TEMPORAIS**

DISSERTAÇÃO DE MESTRADO EM TRANSPORTES

**FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA**

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**PREVISÃO DE TRÁFEGO URBANO NO DISTRITO FEDERAL: APLICAÇÃO DE REDES NEURAIS
DE PREVISÃO DE TRÁFEGO UTILIZANDO DADOS ESPAÇO-TEMPORAIS**

MAURÍCIO MASSAKI ASANO

**ORIENTADOR: LI WEIGANG
CO-ORIENTADORA: MICHELLE ANDRADE**

DISSERTAÇÃO DE MESTRADO EM TRANSPORTES

**PUBLICAÇÃO: 003/2025
BRASÍLIA/DF: MARÇO/2025**

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**PREVISÃO DE TRÁFEGO URBANO NO DISTRITO FEDERAL: APLICAÇÃO DE REDES NEURAIS
UTILIZANDO DADOS ESPAÇO-TEMPORAIS**

MAURÍCIO MASSAKI ASANO

DISSERTAÇÃO

APROVADA POR:

**LI WEIGANG – PPGT/UNB
(ORIENTADOR)**

**PASTOR WILLY GONZALES TACO - PPGT/UNB
(EXAMINADOR INTERNO)**

**ALEXANDRE DE BARROS BARRETO – GEORGE MASON UNIVERSITY
(EXAMINADOR EXTERNO)**

BRASÍLIA/DF, 28 de MARÇO de 2025.

FICHA CATALOGRÁFICA

ASANO, MAURÍCIO MASSAKI
PREVISÃO DE TRÁFEGO URBANO NO DISTRITO FEDERAL:
APLICAÇÃO DE REDES NEURAIIS UTILIZANDO DADOS
ESPAÇO-TEMPORAIS [Distrito Federal] 2025.
xii, 65p., 210x297mm (ENC/FT/UnB, Mestre, Transportes, 2025).
Dissertação de Mestrado– Universidade de Brasília. Faculdade de
Tecnologia.
Departamento de Engenharia Civil e Ambiental.
1 – Previsão de Tráfego 2 – Gestão de Tráfego
3 – Machine Learning aplicada na área de transportes

REFERÊNCIA BIBLIOGRÁFICA

PREVISÃO DE TRÁFEGO URBANO NO DISTRITO FEDERAL: APLICAÇÃO DE REDES NEURAIIS UTILIZANDO DADOS ESPAÇO-TEMPORAIS. T.DM-002/2024. Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, p. 121.

CESSÃO DE DIREITOS

AUTOR: Maurício Massaki Asano

TÍTULO DA DISSERTAÇÃO: PREVISÃO DE TRÁFEGO URBANO NO DISTRITO FEDERAL: APLICAÇÃO DE REDES NEURAIIS UTILIZANDO DADOS ESPAÇO-TEMPORAIS

GRAU: Mestre

ANO: 2025

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

Maurício Massaki Asano

DEDICATÓRIA

“Se eu vi mais longe, foi por estar sobre ombros de gigantes”

Isaac Newton (1643-1727)

AGRADECIMENTOS

Agradeço acima de tudo a Deus por me permitir escrever um pouco de ciência e contemplar uma pequena parte do entendimento sobre as coisas que acontecem nessa Terra.

Em segundo lugar, a minha família que, com muita dificuldade, colocou-me em uma jornada de estudos e ajudou-me financeiramente, espiritualmente e emocionalmente. Ao meu avô, por não conseguir assistir minha dissertação de mestrado por estar em outro lugar que já não podemos alcançar.

A minha noiva Laís, que me deu força em toda a jornada e me incentivou a não desistir e seguir em frente, além de me ajudar a corrigir erros de gramática na dissertação e na formatação do documento.

Particularmente ao professor Dr. Neantro, por todo incentivo ao longo da minha trajetória no mestrado, ao professor Dr. Li, por todos feedbacks construtivos que deu sobre pesquisa e sobre os modelos de Machine Learning e, por fim, ao professor Dr. Pastor, por todo incentivo, motivação e conselhos. A professora Dr. Michelle, por todas as ponderações colocadas sobre o trabalho e os respectivos conselhos sobre a presente dissertação.

Em terceiro, aos meus professores que seguiram minha jornada no mestrado, e que tiveram bastante paciência e destreza em me guiar a ser um melhor cientista.

Em quarto, a Universidade de Brasília (UnB), a Faculdades de Tecnologia (FT), ao Programa de Pós-Graduação em Transportes (PPGT) e, por fim, a Fundação Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) que me permitiram realizar meu estudo.

Em quinto lugar, aos meus colegas do mestrado que, a partir de conversas e debates, além de elucidar vários pontos sobre a área, deram-me apoio emocional em momentos chaves. Aos meus amigos também que deixaram a jornada mais leve de ser conduzida.

Em sexto lugar, a PTV Group por me disponibilizar o VISSIM para realizar simulações de tráfego e ao grupo Origin por disponibilizar o software Origin para realização de gráficos.

RESUMO

Este estudo tem como objetivo principal o desenvolvimento e a caracterização de um modelo preditivo para o tráfego de curto prazo de um recorte da malha viária do Distrito Federal, parte da DF-025 e total da DF-035, baseado na variável de fluxo veicular. A abordagem adotada fundamenta-se na aquisição de dados por dispositivos de contagem de tráfego que são convertidos em séries temporais históricas, e na integração desses insumos a uma arquitetura baseada em *Graph Convolutional Neural Networks (Graph-CNN)* e *Long Short-Term Memory (LSTM)* de Bogaerts *et al.* (2020) para o processamento e previsão do volume de tráfego. O modelo preditivo foi avaliado utilizando métricas como Erro Médio Absoluto (MAE) e Raiz do Erro Quadrático Médio (RMSE), além disso, os dados foram submetidos à normalização utilizando a técnica *MinMaxScaler*. Os resultados indicam que os períodos de maior fluxo apresentam maior variabilidade nos erros de previsão, enquanto horários de menor movimento possibilitam previsões. A análise das correlações com até uma hora de duração entre trechos revelou previsões promissoras. O estudo contribui para o aprimoramento da gestão de mobilidade urbana, fornecendo um modelo preditivo que pode auxiliar na tomada de decisões estratégicas para otimizar o fluxo viário e reduzir congestionamentos.

Palavras-chave: Previsão de tráfego, aprendizado profundo, Graph-CNN-LSTM, mobilidade urbana, análise espaço-temporal.

ABSTRACT

This study aims to develop and characterize a predictive model for short-term traffic forecasting on a section of the road network in the Federal District, part of DF-025 and the entire DF-035, based on vehicle flow variable. The approach is based on data acquisition through traffic counting devices, which are converted into historical time series, and the integration of these inputs into an architecture based on Graph Convolutional Neural Networks (Graph-CNN) and Long Short-Term Memory (LSTM) from Bogaerts et al. (2020) for processing and forecasting traffic volume. The predictive model was evaluated using metrics such as Mean Absolute Error (MAE) and Root Mean Squared Error (RMSE). Additionally, the data were normalized using the MinMaxScaler technique. The results indicate that periods of higher flow exhibit greater variability in forecast errors, while times of lower traffic allow for more accurate predictions. The analysis of correlations for up to one-hour intervals between road segments revealed promising forecasts. The study contributes to the improvement of urban mobility management, providing a predictive model that can assist in strategic decision-making to optimize traffic flow and reduce congestion.

Keywords: Traffic forecasting, deep learning, Graph-CNN-LSTM, urban mobility, spatiotemporal analysis.

ÍNDICE

1. INTRODUÇÃO	17
1.1. CONTEXTUALIZAÇÃO	17
1.2. PROBLEMA DE PESQUISA	18
1.3. OBJETIVOS	20
1.3.1. Específico	21
1.4. JUSTIFICATIVA	21
1.5. ESTRUTURA DO TRABALHO	23
2. PREVISÃO DE TRÁFEGO	25
2.1. PREVISÃO DO VOLUME DE TRÁFEGO	25
2.2. PARÂMETROS DE TRÁFEGO	28
2.3. FONTES DE DADOS DE TRÁFEGO	30
2.4. ABORDAGENS DE PREVISÃO DE TRÁFEGO	32
2.4.1. Abordagens <i>Naive</i>	32
2.4.2. Abordagens Paramétricas	33
2.4.2.1. Métodos de Regressão Estatística Clássica	34
2.4.3. Abordagens Não Paramétricas	37
2.5. SÉRIE TEMPORAL	37
3. TÉCNICAS DE MACHINE LEARNING	39
3.1. ESTUDOS ABORDADOS	39
3.2. MODELOS EM <i>MACHINE LEARNING</i>	43
3.3. REDES NEURAIS ARTIFICIAIS - (<i>ARTIFICIAL NEURAL NETWORKS</i> - ANN)	46
3.3.1. <i>Perceptron</i>	47
3.3.2. <i>Perceptron</i> Multicamadas (MLP – <i>Multilayer Perceptron</i>)	48
3.4. APRENDIZADO PROFUNDO – (<i>DEEP LEARNING</i> – DL)	51
3.4.1. <i>Convolutional Neural Network</i> (CNN)	51
3.4.2. <i>Recurrent neural network</i> (RNN)	53
3.4.2.1. <i>Long-Short Term Memory</i> (LSTM)	55
3.5. REDE NEURAL BASEADA EM GRAFOS	57
3.5.1. Matriz de Adjacência	58
4. MÉTODO	62
4.1. MÓDULO DE RECEPÇÃO E PRÉ-PROCESSAMENTO DE DADOS	63

4.2. CARACTERÍSTICAS ESPACIAIS E CONSTRUÇÃO DA REDE VIÁRIA	65
4.3. MONTAGEM DAS SÉRIES TEMPORAIS	66
4.4. MODELO PROPOSTO NO ESTUDO	66
4.4.1. Componente 1: CNN-LSTM – Extração de Relações Espaciais	70
4.4.2. Componente 2: LSTM – Extração de Relações Temporais.....	71
4.4.3. Componente 3: Rede Neural <i>Feed-Forward</i> (FFNN) – Integração e Previsão Final	72
4.5. MÉTRICAS UTILIZADAS	73
5. DADOS UTILIZADOS.....	75
5.1. SELEÇÃO DOS LOCAIS PARA COLETA DOS DADOS DE TRÁFEGO	75
5.2. DADOS DE SENSORES E DAS CARACTERÍSTICAS DA VIA	77
5.2.1. Dados Disponíveis.....	78
5.2.2. Visão Preliminar dos Dados de Volume de Tráfego.....	80
5.2.3. Identificação dos veículos.....	82
5.3. PRÉ-PROCESSAMENTO	86
5.3.1. Separação dos dados em dados de treinamento, validação e teste.	87
5.4. HIPERPARÂMETROS DOS MODELOS	90
5.4.1. Tamanho do Lote (<i>Batch Size</i>).....	90
5.4.2. Número de Épocas (Epochs).....	91
5.4.3. Otimização e Função de Perda	91
5.4.4. <i>Lookback</i> (Janela Temporal de Entrada)	92
5.4.5. <i>Forecast</i> (Horizonte de Previsão)	92
5.4.6. Taxa de Aprendizado (<i>Learning Rate</i>).....	92
5.4.7. <i>Dropout</i>	92
6. RESULTADOS ALCANÇADOS	94
6.1. CONSTRUÇÃO DOS MODELOS.....	94
6.2. CONSTRUÇÃO DO GRAFO PARA REPRESENTAÇÃO DAS CORRELAÇÕES ESPAÇO-TEMPORAIS.....	96
6.2.1. Estruturação do Grafo e Definição dos Nós.....	96
6.2.2. Construção da Matriz de Adjacência Dinâmica.....	98
6.3. PREVISÕES DE TRÁFEGO USANDO O GRAPH-LSTM-CNN.....	98
6.3.1. Previsão de Tráfego para o Conjunto de Todos os Dias	99

6.3.1.1. Estratégias para Prevenção de <i>Overfitting</i> e <i>Underfitting</i> na Modelagem Preditiva	108
6.3.2. Previsão de Tráfego para o Conjunto de Dias de semana e Dias de finais de semana	110
6.3.3. Discussão	113
6.3.3.1. Breve Descrição sobre as variáveis da infraestrutura viária existente e parâmetros de tráfego	116
7. CONCLUSÃO	118
7.1. LIMITAÇÕES DO ESTUDO	119
7.2. ESTUDOS FUTUROS	120
REFERÊNCIAS BIBLIOGRÁFICAS	124

LISTA DE TABELAS

Tabela 2.1 Fator de equivalência para diferentes tipos de veículos	29
Tabela 3.1 Descrição Geral dos Artigos Sistematizados.....	40
Tabela 3.2 Descrição Geral de Dissertações e Teses Exploradas	41
Tabela 4.1 Apresentação das camadas do processamento da matriz dinâmica.....	71
Tabela 4.2 Apresentação da camada de processamento de tráfego ao longo do tempo.....	72
Tabela 4.3 Apresentação da camada que forma a previsão.....	73
Tabela 5.1 Tabela com os dados enviados pelo DER-DF, volume de tráfego.....	78
Tabela 5.2 Tabela com as características da via.....	79
Tabela 6.1 Treinamento e resultados dos modelos de rede neurais propostos.....	94
Tabela 6.2 Parâmetros encontrados MAE médios para cada equipamento nos horários de pico encontrados nas séries temporais	104
Tabela 6.3 Parâmetros encontrados para os dias de semana em diferentes horizontes de previsão para o Erro Médio Absoluto (MAE)	105
Tabela 6.4 - Parâmetros encontrados para os dias de semana em diferentes horizontes de previsão para Raiz do Erro Quadrático Médio (RMSE).....	106
Tabela 6.5 - Parâmetros encontrados para os dias de semana em diferentes horizontes de previsão para o Erro Quadrático Médio (MSE).....	106
Tabela 6.6 - Parâmetros encontrados para os MAE, RMSE e MSE para dias de semana	111
Tabela 6.7 - Parâmetros encontrados para os MAE, RMSE e MSE para dias de final de semana	111
Tabela 6.8 - Informações dos Bancos de Dados.....	111

LISTA DE FIGURAS

Figura 1.1 Benefícios da previsão de tráfego.....	23
Figura 2.1 Equipamento de Controle de Velocidade	31
Figura 2.2 Abordagens de previsão.....	32
Figura 3.1 MLP com duas camadas escondidas (Hidden).....	49
Figura 3.2 Modelo CNN e suas respectivas camadas	52
Figura 3.3 Arquitetura de uma célula LSTM.....	55
Figura 4.1 Estrutura em passos	62
Figura 4.2 O presente estudo baseia-se no conceito de <i>Spatial Static Flow Dynamic Data</i> , que integra informações espaciais estáticas da malha viária com dados dinâmicos de fluxo de viário e outras informações que podem impactar sobre a previsão de tráfego.....	67
Figura 4.3 Estrutura do modelo proposto por Bogaerts <i>et al.</i> (2020).	69
Figura 4.4 Representação do modelo proposto no trabalho	70
Figura 5.1 Vias e pontos de coleta do estudo.....	76
Figura 5.2 Séries temporais para o equipamento CVS 239	80
Figura 5.3 Séries temporais para o equipamento CVS 240	81
Figura 5.4 Trecho 025EDF0070, suas variações ao longo dos diferentes dias da semana	82
Figura 5.5 Trecho 035EDF0010, suas variações ao longo dos diferentes dias da semana	82
Figura 5.6 Descrição do percentual do tipo de veículo para dia útil. Equipamento: FCL018.....	83
Figura 5.7 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS239.....	83
Figura 5.8 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS240.....	84
Figura 5.9 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS244.....	84
Figura 5.10 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS118...84	
Figura 5.11 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS750....85	
Figura 5.12 Descrição do percentual do tipo de veículo para dia útil. Equipamento: FCL01985	
Figura 5.13 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS625....85	
Figura 5.14 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS119....86	
Figura 5.15 Fluxograma para formação da matriz de adjacência dinâmica.....	89
Figura 5.16 Previsão de Tráfego	90
Figura 6.1 Grafo formado para análise espacial do modelo preditivo e a imagem da disposição real dos sensores.....	97
Figura 6.2 Equipamento CVS118: Sobreposição dos fluxos de tráfego com a unidade de veículo padrão para 15 min (t+1), 30 (t+2) e 120 minutos (t+8). A aproximação se refere ao intervalo de 1 dia.....	100
Figura 6.3 Previsão de Tráfego para o equipamento CVS118.....	101
Figura 6.4 Previsão de Tráfego para o equipamento CVS119.....	101
Figura 6.5 Previsão de Tráfego para o equipamento CVS239.....	102
Figura 6.6 Previsão de Tráfego para o equipamento CVS240.....	102
Figura 6.7 Previsão de Tráfego para o equipamento CVS244.....	102
Figura 6.8 Previsão de Tráfego para o equipamento CVS625.....	103
Figura 6.9 Previsão de Tráfego para o equipamento CVS750.....	103
Figura 6.10 Previsão de Tráfego para o equipamento FCL018	104
Figura 6.11 Previsão de Tráfego para o equipamento FCL019	104
Figura 6.12 Evolução da função de perda ao longo das épocas.....	109
Figura 6.13 Evolução da Função de Perda por Época para Cada Equipamento	110

Figura 6.14 Dados de RMSE para 60 minutos usando STARIMA Fonte: Barros (2022)..... 113
Figura 6.15 Dados de outros modelos GNN Fonte: Luo (2024)..... 115

LISTA DE SÍMBOLOS, NOMENCLATURA E ABREVIACÕES

<i>ACF</i>	<i>Função de Autocorrelação</i>
<i>AdaGrad</i>	<i>Adaptive Gradient Descent</i>
<i>ADAM</i>	<i>Adaptive Moment Estimation</i>
<i>AM</i>	<i>Aprendizado de Máquina</i>
<i>ANN</i>	<i>Artificial Neural Networks</i>
<i>AP</i>	<i>Aprendizado Profundo</i>
<i>AR</i>	<i>Autorregressão</i>
<i>ARIMA</i>	<i>Média Móvel Integrada Autoregressiva</i>
<i>ATIS</i>	<i>Sistemas Avançados de Informação ao Viajante</i>
<i>ATMS</i>	<i>Sistemas Avançados de Gestão de Tráfego</i>
<i>BPTT</i>	<i>Backpropagation Through Time</i>
<i>CFTV</i>	<i>Câmeras de Monitoramento</i>
<i>CNM</i>	<i>Confederação Nacional de Município</i>
<i>CNN</i>	<i>Redes Neurais Convolucionais</i>
<i>CONTRAM</i>	<i>Conselho Nacional de Trânsito</i>
<i>Conv2D</i>	<i>Convolucional 2D</i>
<i>DER</i>	<i>Departamento de Estradas de Rodagem</i>
<i>DETRAN</i>	<i>Departamento de Trânsito</i>
<i>DF</i>	<i>Distrito Federal</i>
<i>DGNN</i>	<i>Graph Transformer, Dynamic Graph Neural Networks</i>
<i>DL</i>	<i>Aprendizado Profundo</i>
<i>DNIT</i>	<i>Departamento Nacional de Infraestrutura de Transportes</i>
<i>EFE Tipo II</i>	<i>Equipamentos de Fiscalização Eletrônica</i>
<i>EPOCHS</i>	<i>Número de Épocas</i>
<i>FFNN</i>	<i>Rede Neural Feed-Forward</i>
<i>GNN</i>	<i>Graph Neural Networks</i>
<i>GPS</i>	<i>Global Positioning System</i>
<i>GPU</i>	<i>Gated Recurrent Units</i>
<i>Graph-CNN</i>	<i>Graph Convolutional Neural Networks</i>
<i>GRU</i>	<i>Gated Recurrent Unit</i>
<i>IA</i>	<i>Inteligência Artificial</i>
<i>SIT</i>	<i>Sistemas Inteligentes de Transporte</i>
<i>KNN</i>	<i>K-Nearest Neighbors</i>
<i>LSTM</i>	<i>Long Short-Term Memory</i>
<i>MAE</i>	<i>Média do Erro Absoluto</i>
<i>MAPE</i>	<i>Erro Percentual Médio Absoluto</i>
<i>MLP</i>	<i>Perceptron Multicamadas</i>
<i>MM</i>	<i>Média Móvel</i>
<i>MPH</i>	<i>Milhas Por Hora</i>
<i>MSE</i>	<i>Erro Quadrático Médio</i>
<i>PACF</i>	<i>Função de Autocorrelação Parcial</i>
<i>PPCub</i>	<i>Plano de Preservação do Conjunto Urbanístico de Brasília</i>
<i>PTCP</i>	<i>Previsão de Tráfego de Curto Prazo</i>
<i>PTLP</i>	<i>Previsão de Tráfego de Longo Prazo</i>

ReLU

RMSE

ST-GCN

SVM

TANH

UCP

Rectified Linear Unit

Root Mean Squared Error

Spatio-Temporal Graph Convolutional Networks

Máquinas de Vetores de Suporte

Função Tangente Hiperbólica

Unidade de Carro de Passeio

1. INTRODUÇÃO

O presente estudo propõe um modelo de previsão de tráfego de curto prazo para a cidade de Brasília, especificamente na DF-025 e DF-035, com foco na estimativa do fluxo em vias urbanas. O principal objetivo é desenvolver um modelo capaz de antecipar variações no volume de veículos. Neste capítulo, serão apresentados a contextualização do problema, a formulação do problema de pesquisa, os objetivos, a hipótese e a justificativa que fundamentam a realização deste estudo.

1.1. CONTEXTUALIZAÇÃO

Os seres humanos possuem um desejo constante ao longo da história pela vaticinação, buscando constantemente antever eventos como uma forma de se precaver diante de possíveis desafios. Nesse processo, inúmeras ferramentas e métodos foram desenvolvidos para prever eventos, abrangendo desde as condições climáticas até o comportamento de mercados, demanda, sistemas de transporte e diversas outras áreas. Contudo, o desafio inerente às ferramentas de previsão reside nas incertezas desses métodos, frequentemente resultando em discrepâncias altas entre as previsões e a realidade (LIU *et al.*, 2017).

É imperativo compreender que, com o contínuo desenvolvimento econômico e a expansão urbana, o aumento gradual do número de veículos tende a sobrecarregar a infraestrutura de transportes, comprometendo sua capacidade de atender à demanda crescente. Para enfrentar esse desafio, gestores de infraestrutura de transportes têm proposto alternativas, como a ampliação de faixas em rodovias urbanas e a adoção de tecnologias avançadas para o controle eficiente do tráfego. Embora a expansão da infraestrutura possa contribuir para a melhoria do fluxo viário, essa solução nem sempre é viável devido a fatores como a ocupação de áreas adjacentes às vias, os elevados custos de investimento, possíveis restrições relacionadas à legislação vigente e aos impactos socioambientais, que frequentemente inviabilizam sua implementação (FILHO *et al.*, 2020).

Na esfera do tráfego, dispor de informações acerca das projeções relativas ao fluxo veicular ajuda a compreender as condições futuras em vias e áreas específicas. A partir da mensuração de parâmetros específicos, viabiliza-se a tomada de decisão rápida e assertiva por parte dos órgãos de controle de tráfego, potencializando operações que podem amenizar os efeitos de congestionamentos (DIA, 2001). Em outras palavras, ao contar com previsões eficazes sobre os

diversos cenários viários possíveis, torna-se viável adotar medidas que mitiguem os riscos aos motoristas, pedestres e motociclistas e, ao mesmo tempo, aprimoram o sistema de transportes, diminuindo o tempo contido em um congestionamento (KIPP *et al.*, 2022; JUNIOR *et al.*, 2015; MENEGUETE *et al.*, 2018).

Em suma, no curto prazo, a previsão de tráfego tem maior benefício se ofertada ao setor de gestão competente. Segundo Vlahogianni (2004), a previsão de tráfego deve ser estimada a partir das condições de tráfego, traduzidas por parâmetros como fluxos viários, ocupação de estradas, tempo de viagem, velocidade de tráfego, entre outros. Ao considerar essas características, é possível realizar uma estimativa das condições de trânsito vigentes e identificar quais características devem estar presentes em determinado contexto.

As abordagens não paramétricas, como Redes Neurais Artificiais (RNA) e técnicas de Aprendizado de Máquina (AM), destacam-se por sua flexibilidade e eficácia na modelagem de dados complexos e não lineares, em contraste com métodos estatísticos paramétricos tradicionais (BOUKERCHE E WANG; 2020). Enquanto os métodos paramétricos requerem a definição prévia de uma distribuição específica para os dados, as RNA e o AM têm a capacidade de identificar padrões diretamente a partir dos dados, sem pressupor uma estrutura de distribuição subjacente.

Essa característica torna essas abordagens particularmente vantajosas para lidar com cenários de alta variabilidade e incerteza ou onde a estrutura dos dados é desconhecida. Estudos recentes têm demonstrado a aplicabilidade dessas técnicas em previsões de tráfego, especialmente as de curto prazo. Contudo, não há consenso sobre a superioridade de um método específico, uma vez que a escolha depende fortemente do contexto de aplicação, da granularidade espacial e temporal dos dados, bem como do horizonte de previsão considerado (BOUKERCHE E WANG, 2020).

1.2. PROBLEMA DE PESQUISA

A previsão de tráfego de curto prazo tem sido amplamente estudada devido à sua relevância para a gestão de sistemas de transporte urbano. Entretanto, a implementação de modelos que integram múltiplas fontes de dados, como características espaciais e temporais, enfrenta desafios significativos. A indisponibilidade de dados em algumas regiões, muitas vezes devido à ausência

de infraestrutura adequada de monitoramento, limita a capacidade de captura de informações essenciais para alimentar os modelos (NAHELIYA *et al.*, 2024).

Além disso, a falta de padronização entre fontes de dados, como diferenças em formatos, resoluções temporais e escalas espaciais, torna o processo de integração e consolidação das informações extremamente complexo (ZHANG *et al.*, 2017). Esses obstáculos não apenas comprometem a precisão das previsões, mas também aumentam os custos computacionais, especialmente em modelos que dependem de um grande volume de dados para gerar resultados confiáveis (MORI *et al.*, 2015).

Independentemente do horizonte temporal da previsão, seja de curto ou longo prazo, a heterogeneidade do tráfego urbano agrava os desafios preditivos. Essa variabilidade é causada por fatores como condições climáticas, padrões comportamentais dos motoristas e eventos incertos, tornando os modelos menos eficazes em capturar e representar a realidade (BOUKERCHE E WANG, 2020). A integração de dados de diferentes fontes também demanda múltiplos pontos de coleta e uma infraestrutura robusta para processamento e sincronização das informações (NAHELIYA *et al.*, 2024).

Além disso, o comportamento estocástico e não-linear do tráfego urbano representa um desafio intrínseco na modelagem preditiva. Esse comportamento reflete a alta variabilidade e interdependência de fatores externos, exigindo o desenvolvimento de modelos que combinem abordagens diversificadas em cada etapa do processamento de informação (BOUKERCHE E WANG, 2020; ZHANG *et al.*, 2017).

Estudos da literatura científica (KONG *et al.*, 2024; BOGEARTS *et al.*, 2020) indicam que o uso de redes neurais artificiais na previsão de tráfego, viabilizado pela crescente disponibilidade de dados captados por sensores e outras fontes confiáveis, contribui substancialmente para melhorar os resultados preditivos. Essa melhoria não apenas eleva a acurácia dos modelos, mas também aprimora a qualidade das informações fornecidas aos órgãos responsáveis pela gestão de tráfego, otimizando o monitoramento e a regulação dos fluxos viários em áreas específicas.

Desde 2017, com o desenvolvimento da *Graph Neural Network* (GNN), houve avanços significativos na aplicação de redes neurais para a previsão de tráfego, especialmente em comparação com abordagens tradicionais paramétricas e não-paramétricas. Estudos como o de Yu *et al.* (2017) demonstraram que a GNN oferece resultados superiores nas previsões de tráfego, evidenciando seu grande potencial em relação às outras Redes Neurais Artificiais (ANN).

A partir do fato conhecido de que a previsão de tráfego é de fato desafiadora por seu caráter de alta dimensionalidade (JIANG E LUO, 2022), ou seja, do número de variáveis que impactam o tráfego, esta dissertação tem como problema de pesquisa o uso da GNN para previsão de tráfego de curto prazo. Essa informação quando repassada ao órgão pode diminuir o tempo de viagem dos condutores a partir da possibilidade de serem associados a dispositivos de controle de tráfego.

A partir do que fora supracitado, a pergunta dessa pesquisa é:

Os valores preditos por um modelo baseado em *Graph Convolutional Neural Networks* (Graph-CNN) apresentam proximidade satisfatória em relação aos dados reais de tráfego urbano, a ponto de viabilizar sua aplicação em vias conectadas na previsão de curto prazo no Distrito Federal?

1.3. OBJETIVOS

Considerando o conteúdo previamente discutido, este estudo tem como objetivo principal o desenvolvimento e a caracterização de um modelo preditivo para previsão de tráfego de curto prazo na DF-025 e DF-035 usando as variáveis de fluxo veicular e características espaciais da via. A abordagem adotada fundamenta-se na aquisição de dados por sensores, convertidos em séries temporais históricas, e na integração desses insumos a uma arquitetura baseada em *Graph Convolutional Neural Networks* (Graph-CNN) e *Long Short-Term Memory* (LSTM) para o processamento e previsão do volume de tráfego.

O modelo proposto visa prever o fluxo de tráfego em curtos intervalos de tempo (até 2 horas) em vias urbanas, contribuindo para o aprimoramento do gerenciamento viário.

Ressalta-se que este estudo não tem como propósito realizar previsões para toda a rede viária de Brasília, mas sim propor um estudo que, futuramente, possa ser aprimorado e expandido para atender a esse escopo. Sabendo desse propósito, as vias para realização do estudo foram as DF-025 e DF-035, que conectam áreas como Jardim Botânico e São Sebastião à região metropolitana de Brasília.

1.3.1. Específico

- Coletar, organizar e tratar dados de fluxo veicular e características espaciais das vias DF-025 e DF-035, com base em registros históricos obtidos por sensores.
- Modelar as vias selecionadas como grafos espaciais, definindo a estrutura de nós e arestas a partir da topologia viária e conectividade urbana.
- Desenvolver um modelo preditivo híbrido baseado na combinação de *Graph Convolutional Neural Networks (Graph-CNN)* com *Long Short-Term Memory (LSTM)*, adequado para previsão de tráfego de curto prazo com horizontes entre 15 e 120 minutos.
- Treinar e validar o modelo proposto utilizando dados reais de tráfego, por meio da divisão temporal dos dados em conjuntos de treino, validação e teste, com posterior ajuste dos hiperparâmetros relevantes.
- Comparar os valores preditos com os dados reais por meio de métricas estatísticas apropriadas, como erro absoluto médio (MAE), raiz do erro quadrático médio (RMSE) e erro quadrático médio (MSE), a fim de avaliar a acurácia do modelo.
- Analisar a viabilidade da aplicação prática do modelo desenvolvido como ferramenta de apoio à gestão de tráfego urbano, com foco na melhoria da tomada de decisão em tempo real no Distrito Federal.

1.4. JUSTIFICATIVA

No Brasil, assim como em diversos outros países, a gestão do tráfego representa um desafio crescente diante do acelerado aumento da frota de veículos, o qual não tem sido acompanhado pela devida expansão e modernização da infraestrutura de transportes. De acordo com relatório da Confederação Nacional de Municípios (CNM), entre 2012 e 2020, a frota nacional cresceu 35%. No Distrito Federal, esse aumento foi ainda mais expressivo, alcançando 36% no mesmo período. Esses dados evidenciam que os problemas relacionados a congestionamentos e à fluidez do tráfego tendem a se agravar progressivamente.

Além disso, destaca-se problemáticas secundárias como que o trânsito representa uma preocupação significativa para a saúde pública, movimentação das pessoas dentro de regiões altamente densas e urbanizadas e questões climáticas que tem grande interferência pela emissão de gases poluentes (KIM *et al.*, 2024; ZHANG *et al.*, 2017).

Além das problemáticas relacionadas ao trânsito já discutidas, projeta-se um cenário ainda mais desafiador diante do crescimento populacional previsto pelo IBGE e das iniciativas de expansão urbana promovidas pelo próprio governo. Nesse contexto, destaca-se o Plano de Preservação do Conjunto Urbanístico de Brasília (PPCub), que propõe alterações nas normativas de uso e ocupação do solo, prevendo a inserção de aproximadamente 364.750 novos habitantes nas regiões administrativas do Distrito Federal. Esse incremento populacional resultará em um aumento significativo no número de domicílios e, conseqüentemente, na frota de veículos, o que tende a intensificar a sobrecarga sobre a malha viária urbana e os desafios relacionados à gestão do tráfego na capital.

Uma parte considerável dessa mudança no uso do solo ocorrerá em áreas diretamente influenciadas pelo Eixo Leste, que concentra importantes vias como a DF-025 e a DF-035. Essa concentração reforça a necessidade de um planejamento integrado que articule a expansão urbana com as diretrizes de mobilidade e a preservação do conjunto urbanístico tombado de Brasília.

Como mencionado anteriormente, a melhoria e expansão da infraestrutura de transportes são essenciais para otimizar o tráfego e facilitar os deslocamentos. A Figura 1.1 destaca alguns problemas e potencialidades relacionados à previsão de fluxo viário, incluindo a melhoria do fluxo

urbano, o planejamento de cidades inteligentes, a redução da emissão de gases poluentes e a promoção de ruas mais seguras.



Figura 1.1 Benefícios da previsão de tráfego
Fonte: Kashyap, *et al.* (2021).

Nesse contexto, modelos preditivos desempenham um papel crucial, fornecendo uma valiosa antecipação dos eventos nas diversas vias e informações para gestores de tráfego urbano em frente as intempéries possíveis (FILHO *et al.*, 2020). O conhecimento prévio desses eventos, quando se trata da previsão de curto prazo, é o auxílio à adoção de medidas adequadas que podem ser tomadas por gestores de tráfego em uma melhoria da segurança viária, ponderando riscos a partir das variáveis informadas, respostas rápidas à acidentes e suporte aos Sistemas Inteligentes de Transporte (SIT) (SMITH E DEMETSKY, 1994).

Nesse contexto, é fundamental acolher novas abordagens, como a melhoria contínua nos controles de tráfego e a adoção de modelos preditivos. Tais métodos não apenas oferecem uma antecipação valiosa dos eventos nas diversas vias, mas também possibilitam melhores resultados a partir das previsões e a implementação de medidas adequadas para lidar com diversas situações que podem ocorrer na via (VLAHOGIANNI *et al.*, 2014; LV *et al.*, 2015).

1.5. ESTRUTURA DO TRABALHO

A metodologia do trabalho seguirá 7 capítulos, descritos da seguinte maneira:

Capítulo 1 – Introdução: Apresenta a contextualização do tema, o problema de pesquisa, os objetivos do estudo, a justificativa para a investigação e a organização estrutural da dissertação.

Capítulo 2 – Previsão de Tráfego e Conceitos Fundamentais: Explora as principais terminologias associadas à previsão de tráfego, incluindo parâmetros de tráfego, as abordagens preditivas e conceitos fundamentais de séries temporais.

Capítulo 3 – *Machine Learning*: Introduz a área de Inteligência Artificial e o aprendizado de máquina, abordando conceitos como *perceptron*, *perceptron* multicamadas, aprendizado profundo (*Deep Learning*) e Redes Neurais Artificiais (RNA), destacando os modelos usados e aplicações.

Capítulo 4 – Metodologia: Detalha os procedimentos metodológicos empregados na pesquisa, incluindo o processamento dos dados, a modelagem adotada e as técnicas utilizadas para a previsão de tráfego.

Capítulo 5 – Descrição dos Dados: Apresenta de forma aprofundada o pré-processamento dos dados, a construção das séries temporais, a análise da distribuição percentual dos diferentes tipos de veículos e a definição dos hiperparâmetros do modelo preditivo.

Capítulo 6 – Resultados: Expõe os resultados obtidos pelo modelo preditivo, realiza uma análise crítica dos achados e apresenta uma comparação dos desempenhos observados.

Capítulo 7 – Conclusão: Sintetiza as principais contribuições do estudo, discute as limitações da pesquisa e sugere direções para investigações futuras no campo da previsão de tráfego.

2. PREVISÃO DE TRÁFEGO

Este capítulo apresenta a revisão da literatura sobre previsão de tráfego, abordando os conceitos de previsão do volume de tráfego, parâmetros de tráfego e explicando sobre as abordagens existentes. São discutidos os principais conceitos e parâmetros de tráfego, como velocidade, densidade e volume, além dos equipamentos de contagem de tráfego usado no trabalho. São revisadas diferentes abordagens preditivas como *naive*, paramétrica e não paramétrica. O capítulo também descreve sobre as séries temporais, que, determinam as principais entradas temporais do modelo.

2.1. PREVISÃO DO VOLUME DE TRÁFEGO

A diferença entre a demanda crescente por mobilidade urbana e a capacidade da infraestrutura existente torna-se evidente nos frequentes congestionamentos e nos pontos de conflito em entroncamentos rodoviários, que caracterizam as limitações das vias urbanas em atender às necessidades atuais. Esses eventos criam perdas em vários setores sociais, econômicos e ambientais, assim, as organizações de iniciativa pública e privada devem dedicar esforços para entender e mudar o cenário de tráfego atual em vias urbanas (LANA *et al.*, 2018; STEIN, 2021). As principais mudanças que podem ser aplicadas, de maneira isolada ou conjunta, afim de mitigar tais eventos, são a expansão da rede viária existente, a implantação de políticas públicas na área de transportes, e o gerenciamento do volume de tráfego. (AREM *et al.*, 1997; STEIN, 2021).

Além disso, a previsão de tráfego é conceituada como a projeção do comportamento dos veículos em um sistema de transporte específico, levando em consideração uma variedade de variáveis dinâmicas e características dos usuários, tais como velocidade, densidade, tempo, comportamento do condutor e ocorrência de acidentes (VLAHOGIANNI *et al.*, 2004). A partir dos resultados das previsões em mãos, as autoridades de trânsito podem administrar o fluxo de tráfego, aliviar congestionamentos nas vias e melhorar a eficiência viária urbana (JIA *et al.*, 2025; TEDJOPURNOMO *et al.*, 2021; YANG *et al.*, 2020).

A previsão de tráfego em vias específicas desempenha um papel importante, pois constitui a base para a formulação e implementação de políticas eficientes de gestão de tráfego (SHEN *et al.*, 2024). Esse aspecto é reconhecido como um dos principais desafios enfrentados pelos Sistemas

Inteligentes de Transporte (LUO *et al.*, 2024). Assim, os modelos desenvolvidos têm como objetivo principal analisar os dados coletados e convertê-los em informações estratégicas, essenciais para o aprimoramento e suporte aos ITS.

As previsões de tráfego também desempenham, a partir da implantação dos ITS, um papel fundamental nos Sistemas Avançados de Gestão de Tráfego (ATMS) e nos Sistemas Avançados de Informação ao Viajante (ATIS). Esses sistemas têm como principal objetivo antecipar, com elevado grau de precisão, os parâmetros de tráfego e fornece essas informações aos usuários (BRIGIDA, 2018; VLAHODIANNI *et al.*, 2014).

A previsão de tráfego desempenha um papel fundamental na gestão viária, possibilitando intervenções estratégicas na malha urbana para otimizar o fluxo de veículos e minimizar impactos operacionais (JIANG *et al.*, 2023). Além disso, contribui para o aprimoramento da eficiência e segurança da rede de transportes nos SIT (KIM *et al.*, 2024).

A previsão de tráfego também pode melhorar a conveniência do usuário, permitindo que os viajantes selecionem rotas mais rápidas e garantindo maior eficiência operacional das estradas (KIM *et al.*, 2024). Existem diversas técnicas que podem ser empregadas para a coleta de dados nas vias urbanas, como por exemplo, o uso de câmeras de vigilância, GPS (*Global Positioning System*), dispositivos móveis e detectores de veículos, proporcionando uma abordagem para a aquisição de dados massivos e a realização de previsões de tráfego (BRIGIDA, 2018). Essas estratégias de coleta de dados são essenciais para a eficácia dos modelos de previsão e para a implementação de políticas efetivas de gerenciamento do tráfego.

Na previsão de tráfego são reconhecidos dois horizontes temporais distintos. A previsão de tráfego de curto prazo (PTCPs) abrange um período de até duas horas, enquanto a previsão de tráfego (PTLPs) de longo prazo engloba intervalos que podem se estender por meses ou anos (VLAHOIANNI *et al.*, 2014). A principal diferença entre esses dois tipos de previsão reside no enfoque adotado: a previsão de curto prazo concentra-se na análise de informações em intervalo de tempos reduzidas, visando fornecer estimativas para os próximos momentos do fluxo de tráfego. Por outro lado, as previsões de longo prazo são empregadas no planejamento estratégico de

sistemas e infraestrutura de transportes, permitindo a antecipação de tendências e demandas futuras nas vias de transportes (BRIGIDA, 2018).

Vale destacar que não há um consenso bem definido na literatura sobre o intervalo temporal que caracteriza uma previsão de tráfego como sendo de curto ou longo prazo. Essa definição frequentemente varia de acordo com o contexto do estudo e a aplicação prática. No entanto, previsões de curto prazo geralmente abrangem intervalos que variam de alguns minutos a poucas horas, enquanto previsões de longo prazo podem se estender por dias, semanas ou até períodos mais longos (BOUKERCHE E WANG, 2020).

A principal dificuldade na convergência das previsões de tráfego está associada às flutuações nos parâmetros de tráfego, que apresentam comportamento não determinístico. Fatores como acidentes, congestionamentos em horários de pico, condições climáticas adversas, entre outros, contribuem para essa complexidade.

Boukerche e Wang (2020) destacam que o fluxo de tráfego é influenciado por uma correlação complexa entre fatores naturais, de tráfego e climáticos. Devido à natureza não linear e intrinsecamente complexa dessas interações, a precisão das previsões de tráfego é altamente dependente de variáveis como o regime de tráfego, as condições climáticas e as características específicas das vias urbanas. A Equação 2.1 ilustra um modelo preditivo geral, no qual todas as variáveis de entrada são integradas ao modelo, permitindo que a previsão do parâmetro de tráfego escolhido seja gerada com base nessas entradas:

$$U(X, F, G) \rightarrow \hat{x} \quad (2.1)$$

Os parâmetros acima são, respectivamente:

- X são os dados de entrada;
- F são os fatores climáticos;
- G são as características especiais do lugar da análise;
- \hat{x} é o parâmetro de tráfego previsto.

Jiang *et al.* (2021) classificam as previsões de tráfego com base no horizonte temporal. Na previsão de passo único, apenas o estado do tráfego no próximo instante é estimado. Já na previsão de múltiplos passos, busca-se antecipar as condições do tráfego para vários momentos futuros.

2.2. PARÂMETROS DE TRÁFEGO

Parâmetros de tráfego são grandezas físicas utilizadas para descrever as condições de determinada via em um determinado tempo. Podem ser divididos em dois tipos: interrompida e não interrompida. A corrente não interrompida ocorre quando não há interrupções ao longo do trajeto ocasionadas pela sinalização, existência de cruzamentos, etc. A corrente interrompida é caracterizada pela presença de semáforos, cruzamentos e outros elementos que causam paradas e reduções de velocidade no fluxo de veículos (ROESS *et al.*, 2010; STEFANI; 2021).

A velocidade do tráfego refere-se à rapidez com que os veículos se deslocam em uma via. Ela é geralmente medida em quilômetros por hora (km/h) ou milhas por hora (mph). Como há um grande número de veículos presentes na via, a velocidade média de todos os veículos no tempo (u_t) é dada a partir de uma média aritmética das velocidades instantâneas dos veículos passando por uma seção em um dado espaço, a Equação 2.2 representa a velocidade de tráfego (ROESS *et al.*, 2010; STEFANI; 2021).

$$u_t = \frac{1}{n} \sum_i^n u_i \quad (2.2)$$

Velocidade comumente utilizada no estudo dos fenômenos de tráfego é a velocidade medida no espaço (u_s). Essa velocidade considera a média harmônica das velocidades de todos os veículos que transitaram pelo trecho considerado no respectivo intervalo de tempo, é dada pela Equação 2.3:

$$u_s = \frac{n}{\frac{1}{n} \sum_i^n u_i} \quad (2.3)$$

A densidade do tráfego é a quantidade de veículos presentes (n) em uma unidade de comprimento de uma via (ΔL), geralmente expressa em veículos por quilômetro (veículos/km) ou veículos por milha (veículos/milha). A densidade indica a ocupação da via e está diretamente relacionada ao fluxo e à velocidade. Altas densidades podem indicar congestionamentos, enquanto baixas densidades podem indicar um fluxo livre. A densidade de tráfego é representada pela Equação 2.4:

$$k = \frac{n}{\Delta L} \quad (2.4)$$

O volume de tráfego é a quantidade de veículos (n) que passam por um ponto específico em uma via durante um determinado período de tempo (Δt), geralmente medido em veículos por hora (veículos/hora). Este parâmetro é importante para o dimensionamento e a gestão da infraestrutura viária, permitindo planejar a capacidade necessária para acomodar diferentes níveis de demanda. A Equação 2.5 representa a quantidade de veículos por tempo, ou seja, a definição de volume de tráfego:

$$Q = \frac{n}{\Delta t}, \Delta t > 0 \quad (2.5)$$

Por fim, a composição do volume de tráfego veicular é definida pelo Conselho Nacional de Trânsito (CONTRAM) como o volume de tráfego correspondente em termos de unidades de carros de passeio (BRASIL, 2014). O órgão estabelece que a partir das diferenças de desempenho de cada tipo de veículo seja estabelecido um parâmetro chamado unidade de carro de passeio (UCP) para vias urbanas e rodovias, sendo o valor de referência o valor do automóvel. Na Tabela 2.1 são apresentados os fatores de equivalência utilizados:

Tabela 2.1 Fator de equivalência para diferentes tipos de veículos

Tipo	Equivalência
Automóvel	1,00
Moto	0,33
Ônibus	2,00
Caminhão (2 eixos)	2,00

É importante destacar que a transformação do fator de equivalência é um procedimento aplicado ao conjunto de dados para segregá-los em Unidades de Capacidade de Pista (UCP). Embora a contagem de tráfego seja usada vários estudos da área de ciência da computação, muitos trabalhos não adotam a abordagem baseada em UCP, conforme apontado por Boucherke e Wang (2020). No contexto da engenharia de transportes, a contagem de tráfego pode ser realizada, porém, sua aplicação isolada não é suficiente para análises de densidade e ocupação da via. Esses parâmetros são fundamentais para avaliar a saturação e a eficiência operacional da infraestrutura viária, sendo elementos essenciais na determinação do nível de serviço da via (HCM, 2010).

2.3. FONTES DE DADOS DE TRÁFEGO

A obtenção de dados de tráfego é essencial para o desenvolvimento de modelos capazes de compreender a dinâmica veicular em diferentes contextos (STEFANI, 2021). A busca por dados de alta qualidade e volume é uma prioridade para pesquisadores, pois possibilita uma análise dos padrões de mobilidade no local de estudo. Com os avanços na tecnologia de transmissão de informações e na evolução dos sensores, o setor de transportes tem se beneficiado de uma crescente disponibilidade de dados em tempo real, que contribuem significativamente para o aprimoramento de sistemas de transporte (LEDUC, 2008; STEFANI, 2021). Abaixo, na Figura 2.1, observa-se um dos equipamentos de controle de velocidade utilizados no estudo. Esse dispositivo é responsável pela captação contínua de dados de fluxo veicular, permitindo o registro da intensidade de tráfego:



Figura 2.1 Equipamento de Controle de Velocidade

Fonte: Google Maps

Apesar de sua utilidade, esses sensores apresentam limitações específicas para a previsão de velocidades. Um dos principais desafios é a alteração no comportamento dos usuários frente aos equipamentos de monitoramento, uma vez que os veículos tendem a reduzir a velocidade abaixo do limite estipulado ao se aproximarem desses dispositivos, distorcendo os dados de velocidade (OLIVEIRA *et al.*, 2015; TEODORO *et al.*, 2015).

Então, para esse estudo, a previsão de velocidade não seria possível, pois a velocidade pontual não representaria a velocidade usual do usuário daquela malha viária ou via específica. Assim, para instituição desse estudo, apenas a previsão de curto prazo de fluxo viário foi abordada. Na parte de dados, os equipamentos de tráfego serão descritos de forma melhor.

2.4. ABORDAGENS DE PREVISÃO DE TRÁFEGO

Os primeiros modelos de previsão de tráfego surgiram nos anos de 1979, com os trabalhos de Ahmed e Cook (1979) sobre previsão de curto prazo, e Lingras e Adamo (1996) sobre previsão de longo prazo. Após esses marcos iniciais, a área experimentou um crescimento exponencial, resultando em uma ampla variedade de metodologias aplicadas, com a utilização de múltiplos algoritmos e formulações (BRIGIDA, 2018).

Atualmente, existem diversos modelos de predição de tráfego em uso, cada um com características distintas que atendem a diferentes demandas. Entre os mais destacados estão as abordagens do tipo *naive*, paramétricas e não paramétricas (BARROS *et al.*, 2022). A Figura 2.2 representa as abordagens para previsão de tráfego e suas principais diferenças:

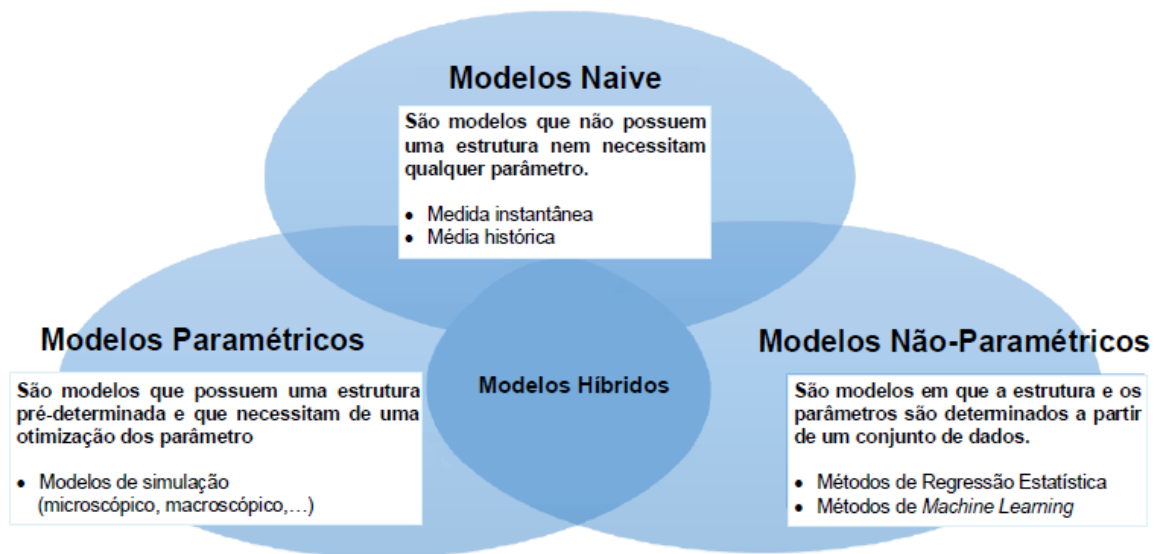


Figura 2.2 Abordagens de previsão
Fonte: Brigida (2018).

2.4.1. Abordagens *Naive*

As abordagens *naive*, também conhecidas como ingênuas, baseiam-se em métodos simples que utilizam dados e relações físicas diretas para estimar informações de tráfego. Essa simplicidade permite lidar tanto com dados discretos quanto contínuos, sem a necessidade de pressupor

distribuições normais de erros. Uma das principais vantagens dessas abordagens é a facilidade de implementação, já que sua independência em relação a distribuições normais reduz a complexidade computacional. Além disso, elas se mostram eficazes para trabalhar com diferentes tipos de dados, oferecendo uma solução ágil para previsões iniciais.

Contudo, essas metodologias apresentam limitações, como a incapacidade de capturar a dinâmica complexa do tráfego, o que pode comprometer a precisão e a utilidade das previsões em aplicações mais exigentes. Para previsões de curto prazo, é comum utilizar o método de Medida Instantânea, enquanto para previsões de longo prazo, é adotado o método de Médias Históricas. Essa segmentação permite uma adaptação mais eficaz às necessidades específicas de previsão de diferentes horizontes temporais (BRIGIDA, 2018).

2.4.2. Abordagens Paramétricas

As abordagens paramétricas exigem ajustes em parâmetros com uma base teórica robusta (KIM *et al.*, 2024). Quando se tem conhecimento das variáveis de tráfego e dos padrões que ocorrem na via, pode-se afirmar que os coeficientes filtrados proporcionam uma boa acurácia nos resultados. Comparados aos modelos não paramétricos, os métodos paramétricos necessitam de uma menor quantidade de dados para operar de forma eficaz (RASHIDI E MOHAMMADIAN, 2011).

A abordagem paramétrica utiliza uma relação funcional entre suas variáveis explicativas e a variável resposta. Nesse contexto, a seleção das variáveis de entrada e a estimativa dos coeficientes são os principais desafios do modelo (KIM *et al.*, 2024), sendo necessária o ajuste dos parâmetros para que se encontre um resultado satisfatório para a previsão. Além disso, o tratamento correto dos dados, bem como a extensão do modelo básico para incorporar hipóteses adicionais. Essa abordagem é menos complexa, quando comparados com abordagens não paramétricas, que necessitam de dados de qualidade e quantidade para que seus resultados sejam satisfatórios (SICHEL *et al.*, 1991; COCHRAN *et al.*, 1995; RASHIDI E MOHAMMADIAN, 2011).

As abordagens paramétricas para previsão de curto prazo, tanto no campo dos transportes quanto em outras áreas, apresentam limitações significativas, especialmente no que se refere à generalização dos coeficientes estimados. Em geral, esses coeficientes são ajustados para contextos

específicos, como uma determinada via rodoviária ou urbana, tornando sua aplicabilidade restrita a cenários locais. Como consequência, essas abordagens enfrentam dificuldades ao serem empregadas em redes de larga escala, onde a complexidade do sistema impede uma adaptação eficaz dos modelos paramétricos às variações espaciais e temporais do tráfego (ZHANG E RICE, 2003; KIM *et al.*, 2024).

Além disso, a precisão das previsões paramétricas pode ser comprometida pela irregularidade inerente ao fluxo de tráfego, que frequentemente apresenta padrões não lineares e mudanças abruptas devido a fatores como congestionamentos, acidentes e variações sazonais. Tais desafios resultam em desvios entre os valores previstos e os observados na realidade (NAHELIYA & REDHU, 2024). Embora essa limitação não seja exclusiva das abordagens paramétricas, mas sim um desafio presente na maioria dos modelos de previsão, os métodos paramétricos tendem a ser mais sensíveis a essas flutuações, uma vez que pressupõem uma estrutura fixa e dependem de relações funcionais predefinidas entre variáveis. Dessa forma, quando expostos a cenários de alta variabilidade e dinamicidade, esses modelos podem apresentar dificuldades em capturar mudanças inesperadas e padrões emergentes, resultando numa grande redução na acurácia das previsões (ZEMA *et al.*, 2020).

Entre os principais métodos paramétricos utilizados para previsão de tráfego, destacam-se a Simulação, Modelos de Séries Temporais, Cadeias de Markov e Filtros de Kalman, que têm sido amplamente explorados na literatura para diferentes contextos de modelagem e predição (LANA *et al.*, 2018; BARROS *et al.*, 2022).

2.4.2.1. Métodos de Regressão Estatística Clássica

Os métodos de regressão linear estatística são os primeiros modelos aplicados sobre séries temporais afim de prever resultados. Os modelos baseados em regressão, de modo geral, estudam relações entre uma variável dependente com várias variáveis independentes, a partir dessa relação múltipla, tenta-se encontrar uma função que se ajuste ao conjunto de dados (BOUCKERCHE E WANG, 2020).

Os métodos de regressão, como a Média Móvel Integrada Autoregressiva (ARIMA), sua variante sazonal (SARIMA) e o modelo KARIMA, são utilizados para previsão de séries temporais em diversas áreas, incluindo o setor de transportes. Esses modelos são empregados na estimativa de parâmetros como volume médio de tráfego e velocidade média, podendo ser aplicados tanto a um ponto específico da via quanto a uma rede de transporte mais ampla. No entanto, sua aplicação é mais comum em análises direcionadas a vias específicas, pois, quando utilizados em redes de larga escala, tendem a apresentar maiores erros nos parâmetros estimados devido à complexidade e variabilidade inerente ao tráfego (NAGY *et al.*, 2018; ZEMA *et al.*, 2020).

Porém, esses métodos apresentam limitações ao seu uso, principalmente em relação as características específicas sobre como os dados estão dispostos. Também, não captam as relações temporais mais complexas e, concomitantemente, não levam em conta as dependências especiais na previsão de tráfego (LUO *et al.*, 2024; NAGY *et al.*, 2018). Modelos como STARIMA resolvem esse problema ao analisar as dependências espaço-temporais (OLIMPIO, 2022).

Entre eles, os modelos Autorregressivos Integrados de Médias Móveis (ARIMA) são utilizados na previsão de tráfego devido à sua capacidade de modelar e prever séries temporais com padrões estruturais bem definidos. O modelo ARIMA combina três componentes principais: autorregressão (AR), diferenciação (I) e média móvel (MA), permitindo capturar a relação entre valores passados da série, eliminar tendências não estacionárias e ajustar previsões com base em erros passados (IBM, 2024; NAGY *et al.*, 2018).

A ideia central do ARIMA é transformar séries temporais não estacionárias em séries estacionárias por meio de diferenças sucessivas. Após esse processo de suavização, a série resultante é modelada usando o ARIMA e, em seguida, a série original é recuperada através de uma transformação inversa (ZHANG *et al.*, 2021). Esse modelo é altamente vantajoso para a previsão de séries temporais univariadas, sendo representado matematicamente pela Equação 2.6:

$$\phi(B)(1 - B)^d y_t = \theta(B)\epsilon_t \quad (2.6)$$

Cada parâmetro representa:

- y_t é o valor da série temporal no tempo t ;
- B é o operador de defasagem;
- $\phi(B)$ é o polinômio autorregressivo de ordem p ;
- $\theta(B)$ é o polinômio de média móvel de ordem q ;
- ϵ_t é o erro aleatório do tempo t

O modelo autorregressivo (AR) funciona ao utilizar valores passados de uma série temporal para prever valores futuros, assumindo que há uma relação linear entre os dados ao longo do tempo. A premissa básica é que o comportamento passado da série contenha informações suficientes para estimar seu comportamento futuro. Isso significa que, em um modelo AR de ordem p (AR(p)), os valores futuros são calculados como uma combinação linear ponderada dos últimos p valores observados, além de um termo de erro aleatório que captura variações imprevisíveis para estimar os coeficientes $\phi_1\phi_2\phi_p$. Um modelo autorregressivo (AR) prediz um valor futuro com base em uma combinação linear de valores passados, conforme a Equação 2.7:

$$y_t = C + \phi_1 y_{\{t-1\}} + \phi_2 y_{\{t-2\}} + \dots + \phi_p y_{\{t-p\}} + \epsilon_t \quad (2.7)$$

onde ϵ_t representa ruído branco. Esse modelo é denotado como AR(p), onde p indica a ordem do modelo (IBM, 2024).

Já um modelo de média móvel (MA) utiliza erros passados para corrigir previsões futuras, conforme descrito na Equação 2.8:

$$y_t = C + \epsilon_t + \theta_1 \epsilon_{\{t-1\}} + \theta_2 \epsilon_{\{t-2\}} + \dots + \theta_q \epsilon_{\{t-q\}} \quad (2.8)$$

Onde θ_q representa os coeficientes de média móvel e q define a ordem do modelo (IBM, 2024).

O modelo ARIMA (p,d,q) combina os componentes AR e MA, incorporando um termo de diferenciação d para tornar a série estacionária. Para determinar os valores de p e q , utiliza-se a

Função de Autocorrelação (ACF) e a Função de Autocorrelação Parcial (PACF) (BOUKERCHE & WANG, 2020).

Muitos estudos utilizam o ARIMA como um modelo de comparação, visto que é um ótimo modelo para modelos estocásticos.

2.4.3. Abordagens Não Paramétricas

Ao contrário da abordagem paramétrica, as abordagens não paramétricas não realizam suposições explícitas (KIM *et al.*, 2024). As abordagens não paramétricas podem, a partir dos dados, capturar padrões estabelecidos e, assim, produzem seus resultados, ou seja, a abordagem, não paramétrica determina sua estrutura e os seus coeficientes tanto do conjunto de dados disponíveis e quanto a partir um modelo instituído pelo usuário (BRIGIDA *et al.*, 2018; KIM *et al.*, 2024; HINSBERGEN *et al.*, 2007).

A principal desvantagem dos modelos não paramétricos é o próprio treinamento ou previsão do modelo, podendo ser uma tarefa computacionalmente intensa quando comparada com modelos paramétricos, uma vez que grandes quantidades de dados precisam ser processadas (NAGY *et al.*, 2018). Outra desvantagem é a necessidade de dados de qualidade e em grande quantidade (BOUCHERCKE E WANG, 2020)

2.5. SÉRIE TEMPORAL

Uma série temporal é uma sequência de observações registradas em ordem cronológica, onde cada valor é associado a um instante específico no tempo. Entre os principais desafios na análise de séries temporais, destaca-se a previsão de valores futuros, que consiste no uso de observações passadas em um instante t para estimar seu valor em um tempo $(t + n)$. Esse processo é fundamental em diversas aplicações, como previsão de demanda, modelagem de tráfego e análise financeira.

Além disso, as séries temporais podem ser classificadas com base na natureza dos seus dados, considerando aspectos como tendência, sazonalidade, estacionalidade e presença de ruído (BOX *et al.*, 2015). Em séries temporais contínuas os dados são observados continuamente ao longo do

tempo, enquanto séries temporais discretas os dados são observados em intervalos de tempo específicos e discretos. Brigida (2018) cita que uma série temporal pode ser descrita a partir de sua decomposição, analisando suas características:

As séries temporais apresentam diferentes padrões que ajudam a caracterizar seus comportamentos ao longo do tempo. Entre os principais componentes, destacam-se:

- **Variação de tendência:** Refere-se a mudanças graduais e de longo prazo nos padrões dos dados ao longo do tempo. No contexto do tráfego, essas variações podem indicar crescimento, declínio ou estabilização do fluxo de veículos e são influenciadas por fatores como condições climáticas, mudanças na infraestrutura viária e padrões sazonais de deslocamento.
- **Mudança periódica (Sazonalidade):** Representa padrões cíclicos e previsíveis, que se repetem em intervalos regulares, como diários, semanais, mensais ou anuais. No tráfego, isso pode incluir aumentos nos horários de pico, variações nos dias úteis e fins de semana, ou mudanças sazonais, como aumento de fluxo em períodos de férias.
- **Variação aleatória:** Refere-se a oscilações imprevisíveis nos dados, causadas por fatores externos inesperados (também chamados como eventos incertos), como sinistros, eventos climáticos extremos ou manifestações. Essas variações não seguem um padrão definido e podem ocorrer de forma abrupta, tornando a previsão, muitas vezes, imprecisa.

As séries temporais também podem ser classificadas de acordo com a quantidade de variáveis observadas ao longo do tempo:

- **Univariada:** Contém apenas uma variável sendo analisada ao longo do tempo, ou seja, cada ponto da série representa uma única observação.
- **Multivariada:** Inclui múltiplas variáveis observadas simultaneamente ao longo do tempo, permitindo a análise das interações entre diferentes fatores que influenciam a série.

3. TÉCNICAS DE MACHINE LEARNING

Este capítulo tem como objetivo apresentar a fundamentação teórica sobre *Machine Learning*, iniciando com a revisão dos artigos, dissertações e teses que serviram de base para a formulação do método desta dissertação. Em seguida, é feita uma abordagem resumida sobre os principais modelos de *Machine Learning*, com destaque para as Redes Neurais Artificiais (RNA) e, por fim, para o Aprendizado Profundo (AP);

3.1. ESTUDOS ABORDADOS

Na fase inicial de fundamentação teórica, priorizou-se a identificação de metodologias capazes de prever tráfego em malhas viárias, superando abordagens limitadas a segmentos isolados. Para isso, conduziu-se uma revisão sistemática no *Google Scholar*, utilizando os descritores "*short-time flow prediction*" e "*traffic network forecasting*", combinados com filtros temporais e critérios de relevância. Dentre as técnicas analisadas, destacaram-se modelos híbridos que integram teoria de grafos e redes neurais profundas, validadas em estudos recentes (2020-2025). A escolha por essa abordagem justifica-se por sua capacidade dual:

1. Modelagem espacial: Grafos codificam topologias viárias, representando intersecções como nós e vias como arestas, o que permite capturar dependências espaciais multidirecionais.
2. Aprendizado temporal: Redes neurais recorrentes ou transformadores processam padrões dinâmicos de fluxo, incorporando sazonalidades e eventos episódicos.

A sinergia entre essas estruturas mostrou-se superior a modelos tradicionais (ARIMA, SVMs) em cenários de alta dimensionalidade, conforme evidenciado por métricas de desempenho (KONG *et al.*, 2024; BOGERIN *et al.*, 2020; YU *et al.*, 2020). Adicionalmente, a escalabilidade desses sistemas para grandes redes urbanas consolidou sua adoção como arcabouço teórico desta pesquisa. As Tabelas 3.1 e 3.2 representam os principais trabalhos consultados para a realização do modelo proposto nessa dissertação.

Tabela 3.1 Descrição Geral dos Artigos Sistematizados

Referência	Variáveis Dependentes	Técnica(s) utilizada(s)	Dado(s)	Área de Estudo
Li <i>et al.</i> (2021)	Fluxo veicular (veh/h) e Velocidade média (km/h)	<i>(Spatio-Temporal Graph Convolutional Networks) + LSTM</i>	(California Highway System)	Previsão de tráfego em redes urbanas
Luo <i>et al.</i> (2020)	Volume de tráfego (u), Congestionamento (nível)	<i>Graph Transformer + Attention Mechanisms</i>	Dados de GPS (NYC Taxi e Uber)	Previsão em redes de larga escala (megacidades)
Shao <i>et al.</i> (2022)	Fluxo em tempo real Tempo de viagem (s)	<i>Decoupled Spatial-Temporal Framework (DSTF)</i>	METR-LA (Los Angeles) PEMS	Previsão multietapa em cenários dinâmicos
Bogaerts <i>et al.</i> (2020)	Velocidade médias e contagem de tráfego(km/h)	<i>Graph-CNN-LSTM</i>	Dados de sensores e GPS	Previsão em redes metropolitanas
Zhao <i>et al.</i> (2019)	Fluxo de tráfego (veh/h)	<i>T-GCN (Temporal Graph Convolutional Network)</i>	Dados de sensores urbanos	Previsão de tráfego urbano
Peregrino <i>et al.</i> (2021)	Fluxo de passageiros	<i>GMEL (Graph-based Machine Learning)</i>	Dados de mobilidade urbana (cidades brasileiras)	Planejamento de cenários de transporte
Rico <i>et al.</i> (2021)	Fluxo de tráfego	<i>GNNs (Graph Neural Networks)</i>	Dados de sensores de tráfego	Revisão de técnicas de previsão de tráfego com GNNs
Kong <i>et al.</i> (2024)	Fluxo de tráfego	<i>Trafficexplainer</i>	Dados de tráfego	Revisão de técnicas de previsão de tráfego com GNN
Yu <i>et al.</i> (2020)	Volume de tráfego (u), Congestionamento (nível)	<i>Graph Transformer + Attention Mechanisms</i>	Dados de GPS (NYC Taxi e Uber)	Previsão em redes de larga escala (megacidades)

Tabela 3.2 Descrição Geral de Dissertações e Teses Exploradas

Referência	Variáveis Dependentes	Técnica(s) utilizada(s)	Dado(s)	Área de Estudo
Olímpio (2022) - Tese	Fluxo veicular (veh/h) e Velocidade média (km/h)	STARIMA	Dados de Tráfego de São Paulo	Modelo de Previsão de Parâmetros de Tráfegos em Redes e Visualização em Display
Stefani (2021) - Dissertação	Fluxo veicular (veh/h) e Velocidade média (km/h)	Rede Bayesiana	Dados de Tráfego de São Paulo	Modelo de previsão de velocidade em trechos
Fábio (2022) - Dissertação	Fluxo em tempo real (veh/5min) Tempo semafórico (s)	RNA	Dados de Trechos do Distrito Federal	Previsão para acoplamento em semáforos
Brígida (2018) - Dissertação	Fluxo Viário (unidade)	<i>K-means</i> , MA	Dados de sensores (Chicago Loop)	Tráfego urbano com dados esparsos
Barbosa (2019) - Tese	Acidentes	MVPLN	Dados de acidentes	Previsão de acidentes no Distrito Federal

No contexto desta revisão, a Tabela 3.1 sistematiza os principais artigos analisados, destacando técnicas aplicadas à previsão do tráfego, como *Spatio-Temporal Graph Convolutional Networks (ST-GCN)*, *Graph Transformer*, *Dynamic Graph Neural Networks (DGNNs)* e *Graph-CNN-LSTM*. Essas abordagens modelam variáveis, incluindo fluxo veicular, velocidade média e tempo de viagem. Por exemplo, Li *et al.* (2021) empregam *ST-GCN* em conjunto com *LSTM* para modelar padrões de tráfego no sistema viário da Califórnia, enquanto Yu *et al.* (2020) propõem um *Graph Transformer* com mecanismos de atenção, voltado para redes de transporte de larga escala em megacidades como Nova York.

Além dos artigos, a Tabela 3.2 sintetiza dissertações e teses que forneceram suporte conceitual e metodológico para a formulação da descrição de dados e do capítulo de resultados desta pesquisa. Destacam-se, nesse contexto, os trabalhos de Barros (2022), que utiliza o modelo STARIMA para previsão de tráfego em São Paulo usando matrizes de adjacência estática, e de Stefani (2021), que explora redes bayesianas para estimativa de velocidade a partir de sensores do tipo laço indutivo.

Com base na literatura revisada, o modelo de Bogaerts *et al.* (2020) foi escolhido como referência metodológica para este estudo. Essa decisão fundamenta-se em sua estrutura, capaz de capturar relações espaço-temporais e a sua simplicidade quando comparado aos outros modelos propostos. A arquitetura *Graph-CNN-LSTM* proposta por Bogaerts *et al.* (2020) combina uma rede convolucional em grafos (*Graph-CNN*), responsável por capturar dependências espaciais, com uma *Long Short-Term Memory (LSTM)*, que modela padrões temporais. Essa configuração demonstrou desempenho competitivo ao ser aplicada a redes metropolitanas em cidades como Xi'an e Chengdu, utilizando dados de sensores e GPS.

A previsão de tráfego tem sido bastante estudada com o uso de redes neurais de grafos (GNNs), permitindo a modelagem conjunta das dependências espaciais e temporais presentes nos dados de tráfego. Modelos como o TraffExplainer (KONG *et al.*, 2024), a Rede Convolucional Espacial-Temporal em Grafos (STGCN) (Li *et al.*, 2021) e o T-GCN (ZHAO *et al.*, 2019) apresentam um funcionamento semelhante ao proposto por Bogaerts *et al.* (2020), pois todos empregam camadas

de redes neurais para capturar relações temporais ao longo do tempo, enquanto as camadas convolucionais são responsáveis pelo processamento das informações espaciais.

Complementarmente, Zhang *et al.* (2022) introduziram uma estratégia de aprendizado por transferência baseada em GCN para a previsão de tráfego em larga escala. Nesse contexto, os autores desenvolveram a Rede Convolucional Espacial-Temporal em Grafos baseada em Mecanismo de Atenção (STA-GCN), aliada a uma estratégia de aprendizado por transferência regional para otimizar a reutilização do conhecimento. A avaliação experimental em dois conjuntos de dados reais demonstrou que o STA-GCN apresenta desempenho satisfatório para previsões de curto prazo. No contexto da modelagem de eventos críticos, Yu *et al.* (2020) ressaltam a necessidade de estratégias robustas para a previsão de incidentes em vias arteriais, evidenciando a importância de modelos que consigam capturar padrões de tráfego anômalos.

Além das questões metodológicas, a viabilidade computacional dos modelos também é um fator crítico na escolha da abordagem preditiva. Modelos como o *Hierarchical GAT*, desenvolvido por Zhao *et al.* (2023), exigem unidades de processamento gráfico (GPUs) especializadas, o que pode dificultar sua implementação em instituições com restrições computacionais. Em contraposição, a arquitetura Graph-CNN-LSTM apresenta menor custo computacional, ampliando sua aplicabilidade. Essa característica está alinhada às conclusões de Peregrino *et al.* (2021), que destacam a importância de modelos acessíveis para o planejamento do transporte urbano, garantindo previsões precisas sem comprometer a viabilidade operacional.

3.2. MODELOS EM MACHINE LEARNING

Os modelos de *Machine Learning* têm crescido continuamente, especialmente na previsão de tráfego. Esse crescimento é impulsionado pelo avanço da ciência de dados, particularmente pela programação orientada a objetos e pela capacidade de obter, armazenar e processar grandes volumes de dados provenientes de diversos pontos de uma rede de transportes (BRIGIDA *et al.*, 2018; VLADIOGIONNI *et al.*, 2014).

Assim, os modelos de *Machine Learning* têm se consolidado como uma abordagem explorada na literatura para a previsão de tráfego, equiparando-se em relevância às abordagens paramétricas

(VLADIOGIONNI *et al.*, 2014). O avanço das técnicas de ciência de dados, aliado à crescente disponibilidade de dados não estruturados e ao desenvolvimento do *Big Data*, tem impulsionado a adaptação e aprimoramento contínuo dos modelos preditivos, tornando-os cada vez mais eficazes na análise e previsão do fluxo de tráfego (BRIGIDA *et al.*, 2018).

Entretanto, os modelos de *Machine Learning* enfrentam algumas limitações significativas. Uma delas é a dependência de *hardware* para o processamento dos dados, exigindo um grande uso de memória RAM para a análise. Além das limitações computacionais, esses métodos, assim como os métodos não paramétricos, têm dificuldade em prever resultados em situações de eventos incertos na rede de transportes, como acidentes, condições climáticas adversas e obras na via. Esses eventos introduzem variabilidade significativa nos dados, dificultando a previsão do tráfego. Atualmente, os métodos mais populares para previsão de tráfego são os métodos de regressão estatística e os modelos de redes neurais artificiais. (BOUCHERCHE E WANG, 2020; BRIGIDA, 2018).

No campo do *Machine Learning*, as técnicas de aprendizado podem ser classificadas em duas categorias principais: aprendizado supervisionado e aprendizado não supervisionado. O aprendizado supervisionado é uma técnica em que o modelo é treinado usando um conjunto de dados rotulados. Isso significa que cada exemplo no conjunto de dados de treinamento é acompanhado por um rótulo ou resposta correta. O objetivo do modelo é aprender a mapear as entradas para as saídas corretas com base nesses exemplos rotulados (BISHOP, 2006; HASTIE, TIBSHIRANI E FRIEDMAN, 2009). O aprendizado supervisionado pode ser dividido em dois tipos principais:

- Classificação: O objetivo é prever uma categoria ou classe para as entradas. Por exemplo, a classificação de e-mails como "*spam*" ou "*não spam*" (BISHOP, 2006).
- Regressão: O objetivo é prever um valor contínuo. Por exemplo, prever o preço de uma casa com base em características como localização, tamanho e número de quartos (SEBER E LEE, 2012).

Exemplos de algoritmos de aprendizado supervisionado são a Regressão Linear (SEBER E LEE, 2012), Máquinas de Vetores de Suporte (SVM) (CORTES E VAPNIK, 1995), Árvores de Decisão

(BREIMAN *et al.*, 1984), Redes Neurais (MCCULLOCH *et al.*, 1943; ROSENBLATT, 1958; RUMELHART *et al.*, 1986) e *K-Nearest Neighbors* (KNN) (Cover E Hart, 1967).

O aprendizado não supervisionado é uma técnica em que o modelo é treinado usando um conjunto de dados que não possui rótulos. O objetivo é identificar padrões ou estruturas ocultas nos dados (HASTIE, TIBSHIRANI E FRIEDMAN, 2009). Como não há rótulos fornecidos, o método deve encontrar relações e agrupamentos dentro dos dados de forma autônoma, baseando-se exclusivamente nas similaridades ou características inerentes. Essa abordagem é especialmente útil em situações em que a categorização prévia dos dados não é possível ou quando o objetivo é explorar informações desconhecidas. Pode-se dizer que o aprendizado não supervisionado pode ser separado em dois tipos:

- *Clustering* (Agrupamento): O objetivo é agrupar dados em *clusters* ou grupos com base em similaridades. Por exemplo, segmentar clientes em diferentes grupos com base em seu comportamento de compra (KAUFMAN E ROUSSEEUW, 2009).
- Associação: O objetivo é encontrar regras de associação entre variáveis em grandes bancos de dados. Por exemplo, identificar que os clientes que compram pão também tendem a comprar manteiga (AGRAWAL, IMIELIŃSKI E SWAMI, 1993).

Exemplos de algoritmos de aprendizado não supervisionado são *K-Means* (MACQUEEN, 1967), Análise de Componentes Principais (PCA) (JOLLIFFE, 2002), Algoritmo Apriori (AGRAWAL & SRIKANT, 1994), Análise de Agrupamento Hierárquico (JOHNSON, 1967) e Mapas Auto-organizáveis (KOHONEN, 1990).

Em um pequeno parêntese, deve-se lembrar que, para este trabalho, trata-se de um treinamento supervisionado de regressão, onde a variável alvo será o UCP. Esse tipo de abordagem envolve o aprendizado a partir de um conjunto de dados rotulado, no qual o modelo é treinado para mapear variáveis predictoras a um valor numérico contínuo da variável alvo. A escolha do treinamento supervisionado justifica-se pelo fato de que há dados históricos disponíveis para a construção do modelo, permitindo que ele aprenda padrões e relações entre as variáveis de entrada e o UCP. Além

disso, a natureza do problema exige a previsão de um valor quantitativo, tornando os métodos de regressão mais adequados para a tarefa.

3.3. REDES NEURAIIS ARTIFICIAIS - (*ARTIFICIAL NEURAL NETWORKS* - ANN)

As Redes Neurais Artificiais (RNA) emergiram como uma revolução na modelagem computacional a partir do trabalho seminal de McCulloch e Pitts (1943), que propuseram um modelo matemático inspirado em neurônios biológicos para simular processos decisórios binários. Esse marco teórico pavimentou o caminho para o *Perceptron* que introduziu a capacidade de aprendizado supervisionado por meio do ajuste iterativo de pesos sinápticos, permitindo às RNA aproximar funções não lineares complexas (HAYKIN, 2009). Essa flexibilidade tornou-as particularmente úteis em problemas de previsão de tráfego, onde relações entre variáveis como fluxo veicular, condições climáticas e eventos urbanos são intrinsecamente não lineares e multidimensionais (TACO, 2003).

No contexto do tráfego urbano, as RNA ganharam relevância com a ascensão do *Big Data*, que possibilitou a integração de fontes heterogêneas, como sensores de infraestrutura, dados de GPS, imagens de satélite e registros climáticos (BRÍGIDA, 2018; ZHANG *et al.*, 2017). Sua capacidade de aprendizado indutivo — inferir padrões diretamente dos dados, sem exigir equações empíricas pré-definidas — as torna ideais para modelar sistemas dinâmicos como redes viárias, onde fatores como acidentes, obras e variações sazonais exigem adaptabilidade contínua (JIA *et al.*, 2025). Além disso, características como tolerância a ruídos e memória associativa permitem que essas redes mantenham robustez mesmo diante de dados incompletos ou inconsistentes, comum em cenários urbanos de médio porte com infraestrutura de coleta limitada (ZHAO *et al.*, 2023).

Entretanto, desafios significativos no uso das RNA persistem. O treinamento eficaz de RNA depende criticamente de grandes volumes de dados históricos, e a escassez ou desbalanceamento amostral pode levar a modelos com baixa generalização, incapazes de prever cenários atípicos como congestionamentos repentinos (ZECHIN *et al.*, 2022). Outra limitação é a complexidade empírica na definição da arquitetura da rede, como a escolha do número de neurônios e camadas, que tradicionalmente depende de tentativa e erro, podendo resultar em superdimensionamento computacional ou subajuste (GOODFELLOW *et al.*, 2016). Para mitigar esses problemas, técnicas

como regularização e *dropout* têm sido empregadas para reduzir sobreajuste (*overfitting*), enquanto abordagens híbridas — como a combinação de abordagens paramétricas com não-paramétricas — ampliam a capacidade de capturar dependências temporais de longo prazo (BOUKERCHE E WANG, 2020).

Nesta pesquisa, as RNA são adotadas como base para previsão de fluxo viário, seguindo a premissa de Taco (2003) de que elas simplificam a modelagem ao evitar a formalização explícita de todas as variáveis intervenientes.

3.3.1. *Perceptron*

Antes de abordar redes neurais, é fundamental compreender a unidade básica que constitui toda a sua estrutura: o *perceptron*. O *perceptron*, formulado por Warren S. McCulloch e Walter Pitts (1940), representa um modelo computacional inspirado no funcionamento dos neurônios biológicos. Essa estrutura é composta por um conjunto de entradas ponderadas, uma função de ativação e uma saída, sendo capaz de processar informações e realizar classificações lineares.

O modelo do *perceptron* consiste em múltiplas conexões que recebem sinais de entrada ($x_{\{1\}}, x_{\{2\}}, \dots, x_{\{n\}}$), cada uma associada a um peso ($w_{\{1\}}, w_{\{2\}}, \dots, w_{\{n\}}$). Então, a partir da combinação linear dos sinais de entrada e pesos é somada a um termo de viés (b), resultando em um valor que passa por uma função de ativação, responsável pelo valor de saída do *perceptron*. Matematicamente, a saída (y) pode ser representada a partir da seguinte Equação 3.1:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (3.1)$$

A Equação 3.1. representa o funcionamento básico de um neurônio artificial dentro de uma rede neural. Esse modelo matemático descreve como os dados de entrada são processados e combinados para gerar uma saída.

A função de ativação $f(\cdot)$ pode assumir diferentes formas, um exemplo, é a função degrau (Equação 3.2):

$$f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.2)$$

A escolha da função de ativação impacta diretamente a escala das saídas, que podem variar em diferentes intervalos, influenciando o comportamento e a capacidade de aprendizado da rede.

O *perceptron*, embora seja um modelo simples, constitui a base para o desenvolvimento de redes neurais mais complexas. Ele funciona como um classificador binário, sendo capaz de distinguir padrões linearmente separáveis. Apesar de suas limitações, sua formulação estabeleceu os princípios fundamentais para o avanço das redes neurais artificiais modernas, contribuindo significativamente para a evolução de arquiteturas mais complexas.

3.3.2. *Perceptron* Multicamadas (MLP – *Multilayer Perceptron*)

O *Perceptron* Multicamadas (MLP) é um modelo de rede neural artificial composto por múltiplas camadas de neurônios dispostas sequencialmente. Ele é um dos principais modelos de aprendizado profundo e é utilizado para tarefas de previsão e classificação.

A arquitetura do MLP é composta por três tipos principais de camadas:

- Camada de Entrada: Responsável por receber o vetor de entrada x , composto por dados de tráfego, variáveis espaço-temporais e informações climáticas coletadas.
- Camadas ocultas: aplicam transformações lineares seguidas por funções de ativação não lineares, permitindo ao modelo capturar relações nos dados.
- Camada de Saída: Responsável por gerar a previsão final do modelo.




Figura 3.1 MLP com duas camadas escondidas (Hidden)
 Fonte: Chan (2023).

O treinamento de um *Perceptron* Multicamadas (MLP - *Multi-Layer Perceptron*) ocorre por meio do algoritmo de retropropagação do erro, que ajusta os parâmetros da rede neural para minimizar a discrepância entre a saída prevista e a saída real. Esse processo inicia-se com a propagação direta (*forward pass*), onde os dados de entrada percorrem a rede passando pelas camadas ocultas até alcançar a camada de saída, gerando uma previsão. Em seguida, é calculado o erro da previsão com base em uma função de custo, geralmente o erro quadrático médio (*MSE - Mean Squared Error*). A retropropagação (*backpropagation*), então, computa o gradiente desse erro em relação a cada peso e viés da rede, propagando essa informação no sentido inverso, da saída para a entrada, utilizando o Teorema da Cadeia para atualizar os gradientes de cada camada.

Para otimizar os parâmetros da rede, utiliza-se a descida do gradiente, um método iterativo que ajusta os pesos (W) e vieses (b) na direção oposta ao gradiente da função de custo, ou seja, no sentido que reduz o erro da previsão. Esse ajuste ocorre com base em uma taxa de aprendizado (α), que define a magnitude das atualizações dos parâmetros a cada iteração. Esse processo de ajuste contínuo permite que a rede aprenda padrões complexos nos dados e melhore suas previsões ao longo das épocas de treinamento, convergindo para uma solução que minimiza o erro e aumenta a precisão do modelo.

No MLP, há outras funções de ativação. Entre elas estão a função sigmoide, função tangente hiperbólica e a função ReLU descrita pelas Equações 3.3, 3.4 e 3.5:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.3)$$

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.4)$$

$$f(x) = \text{ReLU}(x) = \max(0, x) \quad (3.5)$$

A função sigmoide apresenta um intervalo de saída entre [0,1], sendo utilizada em problemas de classificação binária, enquanto a função tangente hiperbólica (tanh) opera no intervalo [-1,1], proporcionando uma saída centralizada que pode acelerar a convergência do modelo. Já a função ReLU (*Rectified Linear Unit*), utilizada neste trabalho como função de ativação das camadas, retorna 0 para entradas negativas e mantém o próprio valor de x para entradas positivas, introduzindo não linearidade no modelo.

Na estrutura do MLP, as camadas são classificadas conforme sua função dentro da rede:

- Camada Oculta (*Hidden Layer*): Refere-se a qualquer camada intermediária situada entre a camada de entrada e a camada de saída de uma rede neural artificial. As camadas ocultas podem assumir diferentes arquiteturas, incluindo camadas densas (*fully connected*), convolucionais ou recorrentes, dependendo do tipo de problema a ser resolvido. Essas camadas são responsáveis por capturar padrões complexos nos dados, contribuindo para a capacidade preditiva do modelo.
- Camada Densa (*Dense Layer*): Trata-se de um tipo específico de camada oculta, onde cada neurônio está conectado a todos os neurônios da camada anterior. Também denominada camada totalmente conectada (*fully connected layer*), essa estrutura é muito utilizada em redes neurais artificiais profundas. Embora todas as camadas densas sejam camadas ocultas, nem todas as camadas ocultas são densas, visto que a rede pode incluir camadas especializadas, como convolucionais e recorrentes, que operam de maneira distinta no processamento da informação.

3.4. APRENDIZADO PROFUNDO – (*DEEP LEARNING* – DL)

O *Deep Learning* é um subcampo da inteligência artificial que utiliza redes neurais artificiais profundas para processar e aprender padrões a partir de grandes volumes de dados. Diferente de abordagens tradicionais de aprendizado de máquina, que frequentemente exigem a engenharia manual de *features*—ou seja, a seleção e extração de características relevantes para o modelo—, o *Deep Learning* automatiza esse processo, aprendendo representações hierárquicas dos dados ao longo de suas múltiplas camadas. Isso significa que as primeiras camadas da rede podem capturar padrões mais simples, como bordas em imagens ou tendências básicas em séries temporais, enquanto camadas mais profundas aprendem conceitos mais complexos e abstratos, como a identificação de objetos inteiros ou padrões avançados de tráfego urbano (BOUKERCHE E WANG, 2020). Essa capacidade de aprendizado automático e em diferentes níveis torna o *Deep Learning* uma ferramenta adequada para tarefas como reconhecimento de imagens, processamento de linguagem natural e previsão de tráfego, permitindo que os modelos se adaptem e generalizem melhor sem a necessidade de intervenção manual extensiva.

Nesta seção, serão exploradas duas arquiteturas fundamentais: as Redes Neurais Convolucionais (CNN), utilizadas para processamento de dados espaciais, e as Redes Neurais Recorrentes (RNN), projetadas para sequências temporais, como padrões de fluxo veicular. Dentro das RNN, abordaremos variantes avançadas como *Long Short-Term Memory* (LSTM) e *Gated Recurrent Units* (GRU), que resolvem o problema do desaparecimento de gradientes (*vanishing gradients*) ao incorporar mecanismos de portões (*gates*) para controlar o fluxo de informações em intervalos de tempo prolongados. Essas técnicas serão contextualizadas em aplicações de previsão de tráfego, análise de padrões dinâmicos e integração espaço-temporal, fundamentais para o modelo proposto nessa dissertação.

3.4.1. *Convolutional Neural Network* (CNN)

As Redes Neurais Convolucionais (CNN) tornaram-se uma ferramenta importante no campo do *Machine Learning*, sendo utilizadas em tarefas como reconhecimento de imagens e processamento de sinais (ENAMOTO, 2021). Sua principal vantagem é a capacidade de identificar padrões e

características importantes nos dados, tornando-as altamente eficientes para análise visual e interpretação de informações espaciais.

Devido a essa capacidade de captar padrões complexos em grandes volumes de dados, as CNN foram adaptadas para resolver problemas em outras áreas, incluindo a previsão de tráfego. Isso porque, além de reconhecer padrões visuais, essas redes também podem analisar dados espaciais e temporais, permitindo prever fluxos de tráfego com maior precisão (MA *et al.*, 2017).

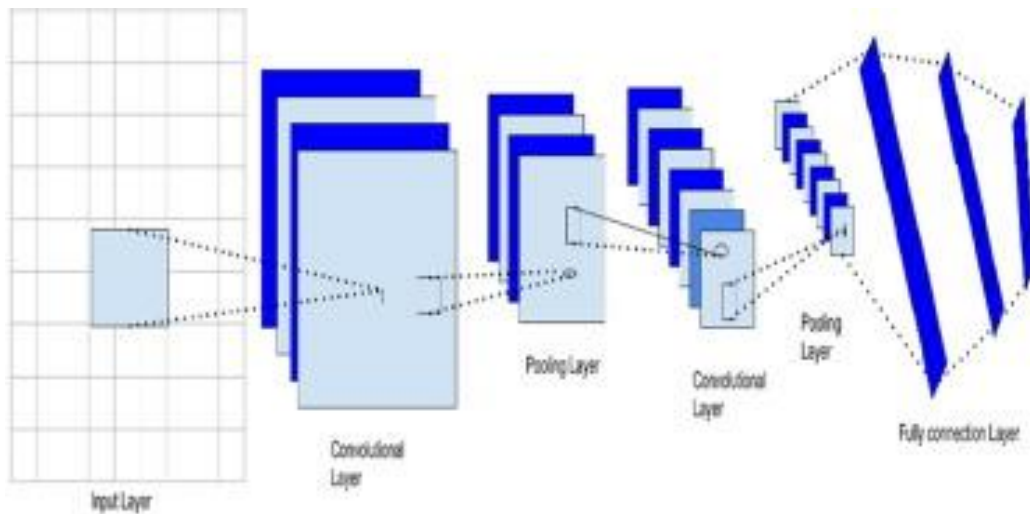


Figura 3.2 Modelo CNN e suas respectivas camadas
 Fonte: Narmadha e Vijayakumar (2023).

As camadas convolucionais são o principal componente das CNN, sendo responsáveis pela extração de características relevantes dos dados de entrada. Elas funcionam aplicando filtros convolucionais (também chamados de *kernels*) sobre a matriz de entrada, permitindo detectar padrões locais, como bordas, texturas e formas específicas. Esse processo é essencial para redes neurais aplicadas a imagens, onde diferentes camadas convolucionais capturam características de baixa a alta complexidade. Além disso, essas camadas podem ser aplicadas a séries temporais e dados espaciais, como na previsão de tráfego, onde analisam relações entre diferentes segmentos de vias ao longo do tempo (MA *et al.*, 2017; ENAMOTO, 2021). A formulação matemática que representa o processamento das camadas convolucionais é descrita na equação 3.6:

$$O_{i,j} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} I_{i+m,j+n} \cdot K_{m,n} \quad (3.6)$$

As variáveis representam:

- I é a entrada;
- K é a matriz de pesos para o *kernel convolucional*;
- $O_{i,j}$: Saída da camada convolucional
- m e n são as dimensões da matriz de *kernel*.

Os *kernels* convolucionais são matrizes de pesos utilizadas nas Redes Neurais Convolucionais (CNN) para extrair padrões espaciais dos dados de entrada. Durante a convolução, esses *kernels* percorrem a entrada e geram mapas de características, armazenando informações em diferentes níveis de abstração. No entanto, o grande volume desses mapas pode aumentar o custo computacional e introduzir redundância, exigindo estratégias de otimização como o *pooling* (GHOLAMALINEZHAD & KHOSRAVI, 2020).

O *pooling* reduz a dimensionalidade dos mapas de características sem necessidade de aprendizado adicional, contribuindo para a mitigação do *overfitting* e para a preservação das informações mais relevantes. Entre as abordagens mais utilizadas, o *Max Pooling* seleciona o maior valor dentro de uma janela deslizante, enfatizando características mais expressivas, enquanto o *Average Pooling* calcula a média dos valores na região analisada, proporcionando um efeito suavizador. Já o *Global Pooling* reduz toda a matriz de características a um único valor por canal, sendo empregado antes da camada densa final (GHOLAMALINEZHAD & KHOSRAVI, 2020).

3.4.2. Recurrent neural network (RNN)

As Redes Neurais Recorrentes (RNNs) apresentam uma arquitetura semelhante às Redes Neurais *Feedforward* (FFNNs), com a principal diferença de que possuem conexões recorrentes, permitindo que as saídas de instantes anteriores sejam realimentadas para a rede. Essa característica possibilita que a RNN capture dependências temporais e estabeleça relações entre diferentes momentos nos dados de entrada, tornando-a particularmente útil para modelagem de sequências, como previsão de séries temporais (RAMAKRISHNAN E TONI, 2017).

A dinâmica de funcionamento da RNN pode ser descrita matematicamente pelas Equações 3.7 e 3.8:

$$h_t = f(W_{xh} x_t + W_{hh} h_{t-1} + b_h) \quad (3.7)$$

$$y_t = W_{hy} h_t + b_y \quad (3.8)$$

As variáveis representam:

- h_t representa o estado oculto da rede no instante t ;
- x_t é a entrada da rede no instante t ;
- W_{xh} , W_{hh} e W_{hy} são as matrizes de pesos que conectam a entrada ao estado oculto e o estado oculto anterior ao estado atual, respectivamente;
- b_y e b_h são os termos de viés (bias);
- y_t representa a saída da rede no instante t ;
- $f(\cdot)$ é a função de ativação, normalmente uma função não linear como tangente hiperbólica ou ReLU.

Para o treinamento das RNNs utiliza métodos de otimização semelhantes aos empregados em FFNNs, mas com um ajuste importante: o algoritmo de retropropagação através do tempo (*Backpropagation Through Time* - BPTT) é utilizado para calcular os gradientes e atualizar os pesos da rede (RAMAKRISHNAN E TONI, 2017; AMIRI E PIERRE, 2020).

No entanto, as RNNs tradicionais enfrentam alguns desafios que podem comprometer o aprendizado de dependências de longo prazo (PHILIPP, 2017). Para mitigar esses problemas, arquiteturas aprimoradas foram desenvolvidas, entre as quais se destacam as redes *Long Short-Term Memory* (LSTM) e *Gated Recurrent Units* (GRU), que incorporam mecanismos internos para melhor captura de padrões temporais e controle do fluxo de informações na rede.

3.4.2.1. Long-Short Term Memory (LSTM)

Em 1997, Hochreiter *et al.* (1997) propuseram o módulo *Long-Short Term Memory* (LSTM) para resolver o problema de dependência de longo prazo que ocorre no RNN básico. A arquitetura LSTM modifica o modelo RNN adicionando uma unidade de memória. Cada unidade LSTM contém uma célula de memória c_t tem uma saída h_t (RAMAKRISHNAN E TONI, 2017):

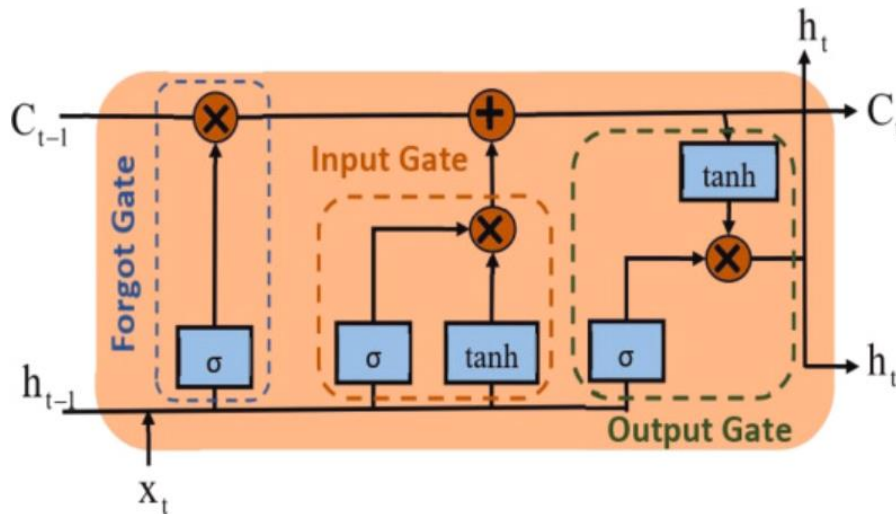


Figura 3.3 Arquitetura de uma célula LSTM
Fonte: Ramakrishnan e Toni (2017).

Na Figura 3.3, pode-se ver a estrutura de uma célula *Long Short-Term Memory* (LSTM). A célula LSTM permite o armazenamento e a atualização de informações relevantes ao longo do tempo por meio de três portas fundamentais: porta de esquecimento (*forget gate*), porta de entrada (*input gate*) e porta de saída (*output gate*).

Porta de Esquecimento (*Forget Gate*): Representada por f_t , essa porta regula quais informações do estado da(s) célula(s) anterior(es) devem ser descartadas ou mantidas. A Equação 3.9 representa a porta de esquecimento:

$$f_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (3.9)$$

Onde:

- f_t é chamado de portão de esquecimento;
- i_t é o chamado de portão de entrada.

Porta de Entrada (*Input Gate*): Responsável por determinar quais novas informações devem ser adicionadas ao estado da célula. Ela consiste em duas operações: a ativação da porta de entrada c_t (Equação 3.10) e a criação de um novo vetor candidato \bar{c}_t (Equação 3.11), dados por:

$$c_t = f_t c_{t-1} + i_t \bar{c}_t \quad (3.10)$$

$$\bar{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (3.11)$$

As variáveis representam:

- f_t é chamado de portão de esquecimento;
- i_t é o chamado de portão de entrada.

Porta de Saída (*Output Gate*): Determina quais partes da memória interna da célula devem ser utilizadas para gerar a saída o_t . A ativação dessa porta é dada pela Equação 3.12:

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o) \quad (3.12)$$

As variáveis representam:

- o_t é a porta de saída.
- σ representa a função de ativação, também chamada de função sigmóide;

Finalmente, o estado oculto atualizado é obtido aplicando a função tangente hiperbólica ao estado da célula e ponderando com h_t , a representação matemática é dada pela Equação 3.13:

$$h_t = o_t \tanh(c_t) \quad (3.13)$$

O portão de esquecimento e portão de entrada são as bases do modelo LSTM. A partir da análise de pesos, o modelo decide se deve permanecer com a informação ou renová-la a partir do parâmetro f_t . A partir dessa análise, entende-se que o modelo de LSTM tem um ótimo potencial de rastrear

dependências a longo prazo, visto que ele pode detectar informações ao longo da cadeia do treinamento (RAMAKRISHNAN E TONI, 2017).

3.5. REDE NEURAL BASEADA EM GRAFOS

Métodos tradicionais enfrentam limitações ao tratar redes viárias em que as vias interferem mutuamente nos valores de tráfego. Métodos convencionais, ao restringirem sua modelagem a vias específicas, não capturam adequadamente a interação entre os elementos da rede como um todo. Consequentemente, essas abordagens apresentam resultados limitados, incapazes de representar com precisão a influência mútua entre as vias (ZHANG *et. al.*, 2021)

A modelagem de redes de transporte por meio de grafos ganhou destaque a partir de 2017, com a publicação dos primeiros artigos dedicados ao tema. Essa abordagem se mostrou especialmente adequada porque a teoria dos grafos, ao representar sistemas compostos por nós e conexões, reflete a estrutura das redes viárias, formadas por interseções e vias. Assim, a aplicação de grafos tornou-se uma solução viável e eficaz para a previsão de curto prazo no setor de transportes (JIANG *et al.*, 2022, YU *et al.*, 2017). Ao representar uma rede viária como um grafo, os nós podem ser definidos como interseções ou pontos de coleta de informações, enquanto as arestas representam as vias que conectam esses nós. (JIANG *et al.*, 2022; RICO *et al.*, 2021).

Os grafos constituem a base estrutural das redes neurais baseadas em grafos e são definidos como $G = (V, E, A)$, em que:

- V é o conjunto de vértices ou nós;
- E é o conjunto de arestas que conectam os nós;
- A é a matriz de adjacência, que representa matematicamente as conexões entre os nós.

Tanto os nós $n_{\{i\}}$ quanto as arestas podem estar associadas a diferentes atributos, dependendo do problema específico. Os nós, no contexto das redes viárias, geralmente representam interseções, cruzamentos ou pontos de coleta de dados de tráfego. Cada nó N pode estar associado a diversos atributos, como a velocidade média, fluxo de veículos ou densidade do tráfego naquele ponto específico (YU *et al.*, 2017).

Por outro lado, as arestas $e_{\{ij\}} \in E$ representam as conexões físicas ou funcionais entre os nós, ou seja, as vias que ligam um a interseção a outra. Essas conexões não precisam ser necessariamente diretas — podem ser ponderadas com base em fatores como a distância física, tempo de viagem, ou capacidade da via (YU *et al.*, 2017).

3.5.1. Matriz de Adjacência

A matriz de adjacência A é um dos conceitos da teoria de grafos e da modelagem computacional de redes (JIANG *et al.*, 2017). Formalmente, a matriz de adjacência $A \in R^{\{N \times N\}}$ descreve matematicamente as conexões entre os nós, com $N = |V|$ denota o número de nós no grafo. Os elementos da matriz $A = [a_{\{ij\}}]$ são definidos como 1 se existe uma aresta entre nós ou 0 caso contrário (BONDY E MURTY, 2008; YU *et al.*, 2017). Em algumas aplicações, os valores da matriz de adjacência podem ser ponderados para refletir a intensidade da conexão entre os nós n_i e n_j . No contexto de redes viárias, por exemplo, o elemento $a_{\{ij\}}$ pode ser definido como inversamente proporcional à distância geográfica ou ao tempo de viagem entre dois nós, representando a força da interação entre eles (JIANG *et al.*, 2021; OLÍMPIO, 2022).

Durante o treinamento de uma *Graph CNN*, a matriz de adjacência atua como uma espécie de "mapa" que direciona o fluxo de informações de um nó para seus vizinhos, preservando as dependências estruturais da rede. Isso possibilita que os nós não apenas aprendam características locais, mas também capturem padrões globais por meio da combinação iterativa de informações de vizinhanças sucessivas (YU *et al.*, 2020). Assim, as dependências estruturais do grafo, como relações espaciais ou topológicas, são incorporadas no processo de aprendizado da RNA.

Diferentes estruturas de grafos são utilizadas para modelar problemas de previsão de tráfego, dependendo tanto do tipo de problema quanto dos conjuntos de dados disponíveis. Essas estruturas podem ser classificadas como grafos estáticos pré-definidos ou grafos dinâmicos, que são continuamente atualizados a partir dos dados em relação a um intervalo de tempo (JIANG *et al.*, 2017).

Os grafos estáticos são subdivididos em dois tipos principais. Os grafos naturais são baseados em sistemas de transporte do mundo real, como redes rodoviárias ou sistemas de metrô, utilizando conexões físicas. Por outro lado, os grafos de similaridade são baseados exclusivamente na similaridade entre diferentes atributos dos nós. Nesses casos, a similaridade é definida com base em características como padrões de tráfego ou proximidade em termos de variáveis específicas. Essa flexibilidade permite modelar o tráfego de maneira eficaz, considerando tanto conexões físicas quanto relações baseadas em dados (ZHANG *et al.*, 2017).

Os grafos de tráfego podem ser categorizados em três níveis principais: grafos em nível de via urbana ou rodovia, grafos em nível de região e grafos em nível de estação. Nesse trabalho, trata-se do sistema de grafos em nível de via urbana em detrimento da escolha para realizar o objetivo proposto.

Os grafos em nível de via urbana incluem diferentes representações da malha viária, dependendo da granularidade da modelagem (JIANG *et al.*, 2017):

- Grafos de sensores: Baseiam-se em dados de sensores de tráfego, onde cada sensor é representado como um nó, e as arestas correspondem às conexões entre as estradas monitoradas.
- Grafos de segmentos de estrada: Modelam redes rodoviárias, com os nós representando segmentos de estrada.
- Grafos de interseções de estrada: Estruturam-se como nós correspondentes às interseções das vias.
- Grafos de faixas de via urbana: Representam a malha viária em maior nível de detalhe, com nós associados a faixas individuais de circulação.

Ao incorporar a dimensão temporal, a análise de redes de tráfego passa a considerar não apenas a estrutura espacial, mas também sua evolução ao longo do tempo. Em vez de uma única configuração fixa de conexões, temos uma sequência temporal de estados da rede, onde as relações entre os elementos podem se modificar dinamicamente (JIANG *et al.*, 2021). No contexto deste estudo, os nós representam os pontos de captação de contagem de tráfego da malha viária, enquanto as arestas mantêm sua estrutura ao longo do tempo. O que varia são os pesos das conexões,

determinados pelos dados de tráfego registrados em cada intervalo. Dessa forma, a rede de tráfego pode ser interpretada como uma sucessão de instantâneos que refletem as condições do fluxo viário em diferentes momentos, possibilitando análises espaço-temporais que podem conter maior gama de variáveis levando a uma maior precisão do modelo.

A literatura destaca que o uso de uma matriz de adjacência estática impõe um padrão fixo de conexões, o que pode ser uma limitação na modelagem do tráfego urbano, onde as relações entre vias e interseções são dinâmicas (YIN *et al.*, 2025). Em horários de pico, determinadas vias podem se comportar como conexões “mais longas” ou “mais fracas” dentro da rede, enquanto em períodos de menor movimento, essas mesmas conexões tornam-se “mais curtas” e eficientes para o fluxo viário.

A fundamentação teórica para a matriz de adjacência dinâmica apoia-se nos conceitos de redes complexas e redes temporais. As redes complexas ponderadas permitem atribuir valores às interações, sendo esses valores, no presente caso, derivados do fluxo de veículos. Essa abordagem possibilita a quantificação da intensidade das conexões dentro da rede, permitindo, por exemplo, interpretar o grau ponderado de um nó como um indicador do volume total de tráfego que entra e sai de determinado ponto.

A literatura sobre vulnerabilidade em redes de transporte frequentemente avalia a resiliência da infraestrutura frente a falhas (PERTENCE *et al.*, 2020), e a matriz dinâmica permite simular esses cenários considerando a variação temporal das conexões. Por exemplo, a remoção de uma via de grande fluxo em horário de pico pode causar um impacto significativamente maior no tempo de viagem médio do que sua remoção em períodos de menor tráfego. Medidas como eficiência global da rede, diâmetro e conectividade podem ser analisadas ao longo do tempo para avaliar a resiliência e a eficiência operacional da malha viária.

No entanto, é importante reconhecer as limitações do modelo adotado. Como mencionado na introdução, a modelagem aqui proposta não abrange todos os fatores estruturais da infraestrutura de transportes, como topografia das vias, comportamento de pedestres e ciclistas, entre outros elementos que influenciam o fluxo viário. Entende-se também que há vias locais ao longo da área

analisada, que podem provocar uma queda no fluxo viário ao longo da malha. O objetivo deste estudo não é esgotar todas as variáveis que impactam o tráfego urbano, mas sim utilizar os dados disponíveis para construir uma representação dinâmica da rede viária, facilitando a análise da evolução do fluxo de tráfego nos pontos monitorados.

4. MÉTODO

Este capítulo apresenta o método utilizada na pesquisa, detalhando as etapas de captação, processamento e modelagem dos dados de tráfego. Inicialmente, são descritos os procedimentos de coleta de informações a partir de equipamentos de controle de velocidade, seguidos pelo pré-processamento dos dados, que inclui a verificação de inconsistências, o tratamento de valores ausentes e a segmentação dos registros em séries temporais. Em seguida, é abordada a estruturação dos dados para aplicação nos modelos de previsão de tráfego, considerando tanto a dimensão temporal quanto a espacial. Para isso, além da organização das séries temporais, é construída uma representação da malha viária por meio de um grafo direcionado, permitindo incorporar relações entre diferentes trechos da rede viária. Concomitantemente, descreve-se, de maneira superficial, o processo de obtenção e preparação dos dados utilizados na pesquisa. O detalhamento completo das características da base de dados, bem como análises exploratórias dos padrões de tráfego, é apresentado no Capítulo 5. A Figura 4.1. representa as etapas do trabalho.

01. PRÉ-PROCESSAMENTO



1.1. Recebimento de dados;
1.2. Juntar e agrupar dados;
1.3 Retirar vias do estudo;
1.4 Verificação dos dados;

1.6 Transformação dos fluxos urbanos para UCP
1.7 Considerações sobre as vias
1.8 Normalização dos dados

02. CRIAÇÃO DAS SÉRIES TEMPORAIS



2.1 Separação dos dados em dias de semana e fins de semana
2.2 Associação das informações e parâmetros físicos da via nos grafos.

2.3 Criação das Matrizes de Adjacência.
2.4 Criação das Séries Temporais

03. PREVISÃO DE TRÁFEGO



3.1 Aplicação do modelo para a área de estudo

3.2 Testar a aplicação do modelo Graph-CNN-LSTM na previsão de curto prazo

04. RESULTADOS



4.1 Análise dos resultados e da previsão.

Figura 4.1 Estrutura em passos

4.1. MÓDULO DE RECEPÇÃO E PRÉ-PROCESSAMENTO DE DADOS

Os dados brutos utilizados neste estudo foram fornecidos pelo Departamento de Estradas de Rodagem do Distrito Federal (DER-DF) e correspondem aos volumes de tráfego registrados por equipamentos de contagem automática instalados em dois trechos rodoviários específicos, identificados pelos códigos 025EDF0070 e 035EDF0010. Os registros contemplam a totalidade dos dias da semana, de segunda a domingo, abrangendo o intervalo completo de horários, das 00h00 às 23h59, no período de 1º de janeiro a 31º de dezembro de 2024.

Inicialmente, foi realizada uma triagem dos equipamentos disponíveis, com a exclusão daqueles que apresentavam falhas significativas de medição ou insuficiência de dados, de modo a garantir a qualidade e a consistência da base utilizada na modelagem. Após essas correções iniciais, cada conjunto de dados proveniente dos equipamentos selecionados foi padronizado em termos de formato e unidades, preparando-os para as etapas subsequentes de processamento.

Na parte de pré-processamento de dados foram aplicadas transformações para uniformizar categorias de veículos, converter volumes de tráfego em unidades equivalentes e tratar lacunas nos dados:

- A harmonização das classes de veículos foi realizada para mitigar inconsistências terminológicas e redundâncias nos dados originais, que classificavam os veículos em categorias: “Caminhão”, “Médio”, “Moto” e “Ônibus”. Primeiramente, identificou-se a necessidade de consolidar a categoria “Médio” como “Carro”, uma vez que veículos de porte intermediário, em contexto de modelagem de tráfego, compartilham características operacionais e impactos similares aos automóveis de passeio. Adicionalmente, duplicações na categoria “Caminhão”, decorrentes de divergências na codificação do caractere especial “~” em sistemas computacionais, foram corrigidas, unificando todas as ocorrências em uma única classe representativa. Essa reestruturação reduziu a dimensionalidade do conjunto de dados, eliminando ambiguidades e alinhando as categorias a critérios técnicos;
- Conversão em Veículo Equivalente: Com as categorias definidas, transformou-se os volumes de tráfego de cada classe em unidades básicas equivalentes. Esse procedimento

consiste em converter veículos de portes distintos para uma unidade comum (geralmente equivalente a um automóvel de passeio), utilizando fatores de equivalência predefinidos, de acordo com a seção 2.1, tabela 2.1 desse documento. Por exemplo, um caminhão pode equivaler a dois automóveis em termos de impacto no fluxo. Assim, cada registro de contagem foi reescalado para representar o número de veículos equivalentes, o que permite somar diferentes tipos de veículos de maneira homogênea. Essa conversão é fundamental para combinar fluxos heterogêneos. Vale-se ressaltar que foi garantida que os dados só fossem somados, caso o intervalo, data e equipamentos fossem os mesmos, para criar de maneira apropriada a série temporal;

- Tratamento de Dados Ausentes e Anômalos: Removeu-se ou foi imputado dados faltantes para evitar que lacunas interfiram no treinamento do modelo. Como mencionado, leituras inexistentes (zeros) nos primeiros dias de alguns equipamentos foram substituídas pela interpolação do horário anterior (Q_a) e posterior (Q_b), uma técnica comum de imputação que preserva as tendências diurnas do tráfego. Além disso, as colunas não informativas para a previsão, como a coluna de descrição dos registros, que não continha dados numéricos relevantes para o modelo foram eliminadas. O resultado desse processo de limpeza é um conjunto de dados confiável, sem duplicatas, sem *outliers* e sem campos desnecessários, pronto para integração.

Após o pré-processamento individual de cada fonte, os dados de tráfego foram integrados em um único conjunto. Esta etapa envolveu a junção de diversas planilhas de tráfego correspondentes aos diferentes equipamentos analisados. A fusão foi realizada alinhando os registros pelo instante de tempo e pelo identificador do equipamento, de modo que cada linha da base consolidada passasse a representar o estado do tráfego em todos os equipamentos selecionados para um determinado intervalo de tempo. Durante a integração, assegurou-se que a nomenclatura de colunas e as unidades de medida estivessem consistentes. O resultado foi uma planilha, contendo para cada intervalo de tempo as contagens de veículos equivalentes em cada equipamento estudado, junto com informações auxiliares relevantes (como data, hora inicial do intervalo, etc.). Essa base integrada serve de ponto de partida para a extração de atributos espaciais e temporais e para a construção do modelo de previsão.

Após as etapas de transformação, pré-processamento e limpeza, os dados foram submetidos à normalização utilizando a técnica *MinMaxScaler*. Este procedimento visa garantir que todas as variáveis de entrada — incluindo métricas de fluxo viário, como volume de veículos e intensidade de tráfego — sejam escalonadas para um intervalo numérico comum [0, 1], eliminando disparidades de magnitude entre parâmetros. A normalização evita que valores elevados de fluxo, como picos de tráfego em vias arteriais, dominem desproporcionalmente o treinamento do modelo, prejudicando a capacidade de aprendizado de padrões em variáveis de menor escala. Ao equilibrar a contribuição de cada fator, preserva-se a relação intrínseca entre os dados e otimiza-se a convergência do algoritmo, assegurando que a influência de cada parâmetro reflète seu peso real no fenômeno analisado, sem distorções artificiais.

O detalhamento dos dados e das séries temporais será feita na seção 5. Porém, o autor achou necessário a descrição prévia da organização dos dados para a posterior leitura e melhor entendimento de como o trabalho foi formado.

4.2. CARACTERÍSTICAS ESPACIAIS E CONSTRUÇÃO DA REDE VIÁRIA

Com os dados de tráfego consolidados ao longo do tempo, as informações espaciais dos trechos monitorados foram incorporados para representar a estrutura da rede viária em estudo. Foi elaborada uma planilha de características contendo, para cada segmento viário correspondente aos equipamentos selecionados, atributos geográficos e de infraestrutura relevantes.

Utilizando essas características, foi construída uma representação em forma de grafo direcionado da rede viária. Cada nó do grafo representa um ponto de monitoramento (início ou fim de um trecho), e cada aresta representa o trecho rodoviário em si (associada a um equipamento de contagem). Durante a construção do grafo, todos os nós e arestas descritos na planilha de características foram adicionados: cada aresta conecta um *startNode* a um *endNode* correspondentes e recebe atributos como extensão da via. Essa estrutura de grafo fornece a base para derivar a matriz de adjacência da rede – uma matriz que indica quais trechos se conectam diretamente entre si (vizinhança viária). A matriz de adjacência foi inicialmente considerada de forma binária (conexão existe ou não entre dois nós), porém, posteriormente, os pesos das arestas

foram atualizados dinamicamente de acordo com os volumes de tráfego ao longo do tempo, como descrito a seguir.

4.3. MONTAGEM DAS SÉRIES TEMPORAIS

Para prever o volume de tráfego em um horizonte de $(t + n)$ intervalos de tempo para cada equipamento, os dados consolidados de tráfego foram reorganizados em janelas móveis, permitindo capturar as relações temporais subjacentes. Foi definido um intervalo de retrospectiva de oito passos de tempo, ou seja, para cada instante t , o modelo utiliza os valores observados nos oito intervalos anteriores $t - 8$ até t para estimar o valor no próximo instante $t + n$.

Esse período de análise foi determinado com base em estudos exploratórios das correlações temporais, mostrando-se adequado para identificar variações de curto prazo, como padrões que ocorrem ao longo do dia. Dessa forma, cada sequência temporal foi associada ao valor de tráfego imediatamente subsequente, organizando os dados em pares de entrada e saída para o treinamento do modelo.

4.4. MODELO PROPOSTO NO ESTUDO

Nesta seção, apresenta-se a abordagem metodológica adotada para a previsão de tráfego, baseada em um modelo híbrido que integra redes convolucionais aplicadas a grafos (*Graph-CNN*) com redes neurais recorrentes de memória de longo prazo (*LSTM*). A proposta busca combinar a topologia da malha viária — representada por grafos, onde os nós correspondem aos pontos de coleta de dados e as arestas às vias urbanas entre esses pontos, junto a variável de extensão da via — com os padrões temporais do fluxo veicular.

As informações espaciais são incorporadas ao modelo por meio de uma matriz de adjacência dinâmica, que representa as relações dos fluxos da rede viária. Já os dados temporais são tratados por meio de séries temporais que alimentam a LSTM. Essa combinação permite capturar, de forma dinâmica, as interações entre diferentes segmentos viários. O estudo parte da premissa de um modelo físico estático, continuamente atualizado com dados de tráfego em tempo real. A Figura 4.2 ilustra essa concepção inicial.

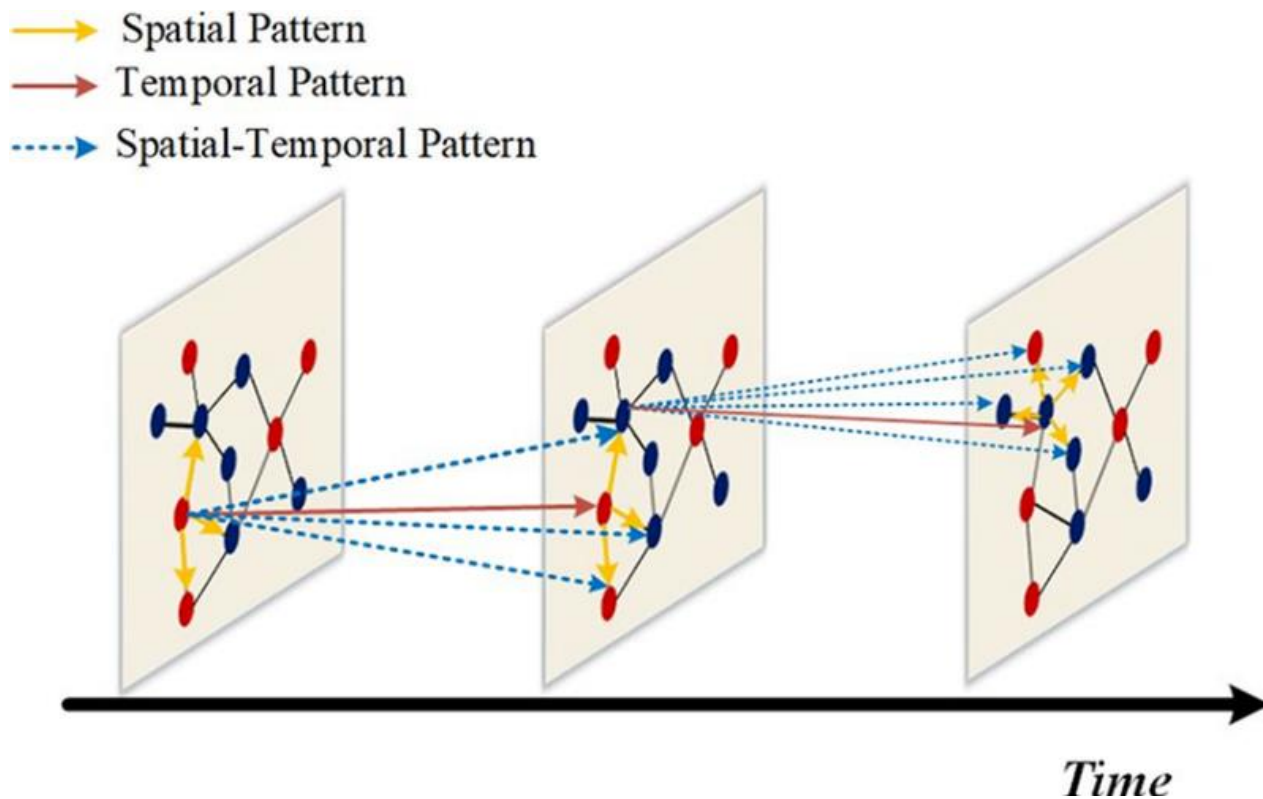


Figura 4.2 O presente estudo baseia-se no conceito de *Spatial Static Flow Dynamic Data*, que integra informações espaciais estáticas da malha viária com dados dinâmicos de fluxo de viário e outras informações que podem impactar sobre a previsão de tráfego
 Fonte: Gu *et al.* (2023).

O modelo desenvolvido recebe dois conjuntos de entrada principais: a matriz de adjacência temporal (entrada espacial) e a série temporal do fluxo veicular (entrada temporal). A matriz de adjacência temporal é representada por um tensor tridimensional de dimensão (i, n, n) , onde i corresponde ao número de registros históricos utilizados como entrada (janela temporal), e n representa o número de trechos analisados na malha viária. Essa matriz é processada para capturar relações estruturais e dinâmicas entre os trechos ao longo do tempo. Já a série temporal do fluxo veicular é composta por uma sequência univariada que representa a evolução do tráfego ao longo do tempo, capturando padrões sazonais e tendências na dinâmica do tráfego.

A matriz de adjacência dinâmica é gerada em três etapas interligadas. Inicialmente, define-se um grafo direcionado estático que representa a topologia física da rede viária: onde os nós correspondem a interseções ou pontos estratégicos, e arestas representam segmentos viários, com atributos fixos como identificador único, distância e velocidade máxima. Em seguida, para cada

intervalo temporal analisado, os dados de tráfego (UCP) são mapeados para as arestas correspondentes por meio de identificadores únicos. Arestas sem medição no intervalo recebem peso zero, garantindo que apenas conexões válidas e com dados contribuam para a matriz. Por fim, o grafo atualizado é convertido em uma matriz de adjacência numérica, onde cada elemento $a_{ij}t_k$ reflete a intensidade do fluxo do nó i para j no instante t_k . A sequência temporal de matrizes é armazenada em um vetor tridimensional $[A(t_1), A(t_2), \dots, A(t_T)]$, capturando a dinâmica espaço-temporal do tráfego. A matriz segue a regra: $a_{ij}t_k = w_{ij}t_k$ se a aresta existir e tiver dado em t_k , ou zero caso contrário. Essa estrutura preserva a topologia fixa da rede enquanto incorpora variações temporais de fluxo.

$$A(t_k) = [a_{\{ij\}(t_k)}]_{\{N \times N\}} \quad (4.1)$$

No processamento das informações, a matriz de adjacência é tratada por uma rede convolucional com camadas bidimensionais de convolução, que possuem filtros de tamanho (3×3) e utilizam a função de ativação ReLU. Camadas de subamostragem máxima (*MaxPooling*) são aplicadas para reduzir a dimensionalidade espacial, e em seguida os dados passam por uma camada LSTM que modela a evolução temporal das relações entre os trechos da rede viária.

Em paralelo, a entrada temporal é processada separadamente por uma LSTM, que modela a evolução do fluxo de tráfego, identificando padrões recorrentes e variações sazonais nos dados históricos. As saídas das redes convolucionais e da LSTM temporal são combinadas por meio de uma camada de concatenação, que unifica as representações extraídas de ambas as entradas. Essa fusão é processada por uma camada densa com 128 unidades e ativação ReLU, seguida por uma camada de *dropout* para reduzir o risco de sobreajuste.

A camada final do modelo é composta por uma rede densa com 128 neurônios. Foi utilizada a função de ativação linear para manter a escala original dos valores de fluxo veicular. O modelo foi compilado com o otimizador Adam, devido à sua eficiência na atualização dos pesos, e a função de erro quadrático médio (MSE) como função de perda, sendo o desempenho avaliado por meio da média do erro absoluto (MAE), que quantifica a diferença média entre os valores previstos e os valores observados.

Após o modelo realizar a previsão, os valores de saída passam por um processo inverso, conhecido como desnormalização. Nesse momento, os valores previstos são revertidos à sua escala original para que possam ser comparados corretamente com os dados reais de fluxo veicular. Isso garante que as previsões sejam interpretáveis no contexto real, permitindo avaliar a precisão do modelo em termos absolutos, como unidades de veículos por período.

Deve-se ressaltar que essa rede foi inspirada no estudo feito Bogaerts *et al.* (2020), como citado na introdução. Na Figura 4.3 há o modelo pelo Bogaerts *et al.* e a Figura 4.4 representa o modelo descrito no estudo.

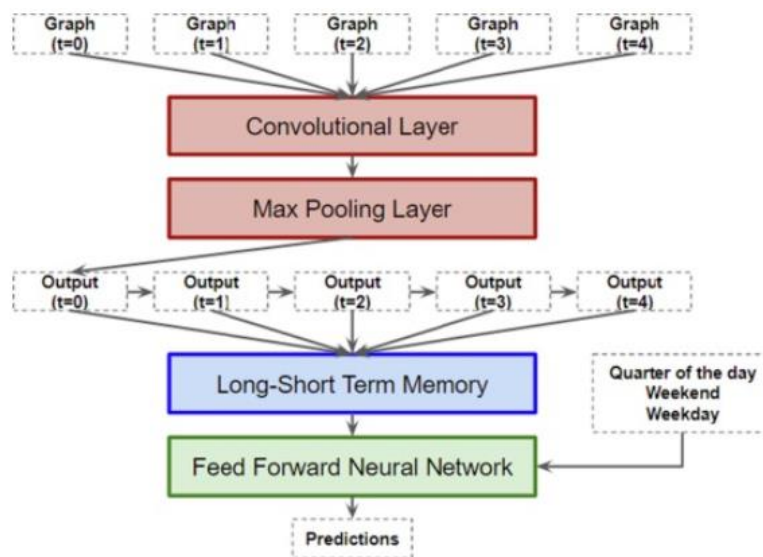


Figura 4.3 Estrutura do modelo proposto por Bogaerts *et al.* (2020).
 Fonte: Bogaerts et al (2020)

Pode-se falar que a Figura 4.3 não representa o modelo mais exato a essa dissertação, onde pode-se dizer que as camadas CNN e LSTM não acontecem de maneira sequenciais, mas de maneira simultânea. A Figura, 4.4, então demonstra a verdadeira estrutura do trabalho:

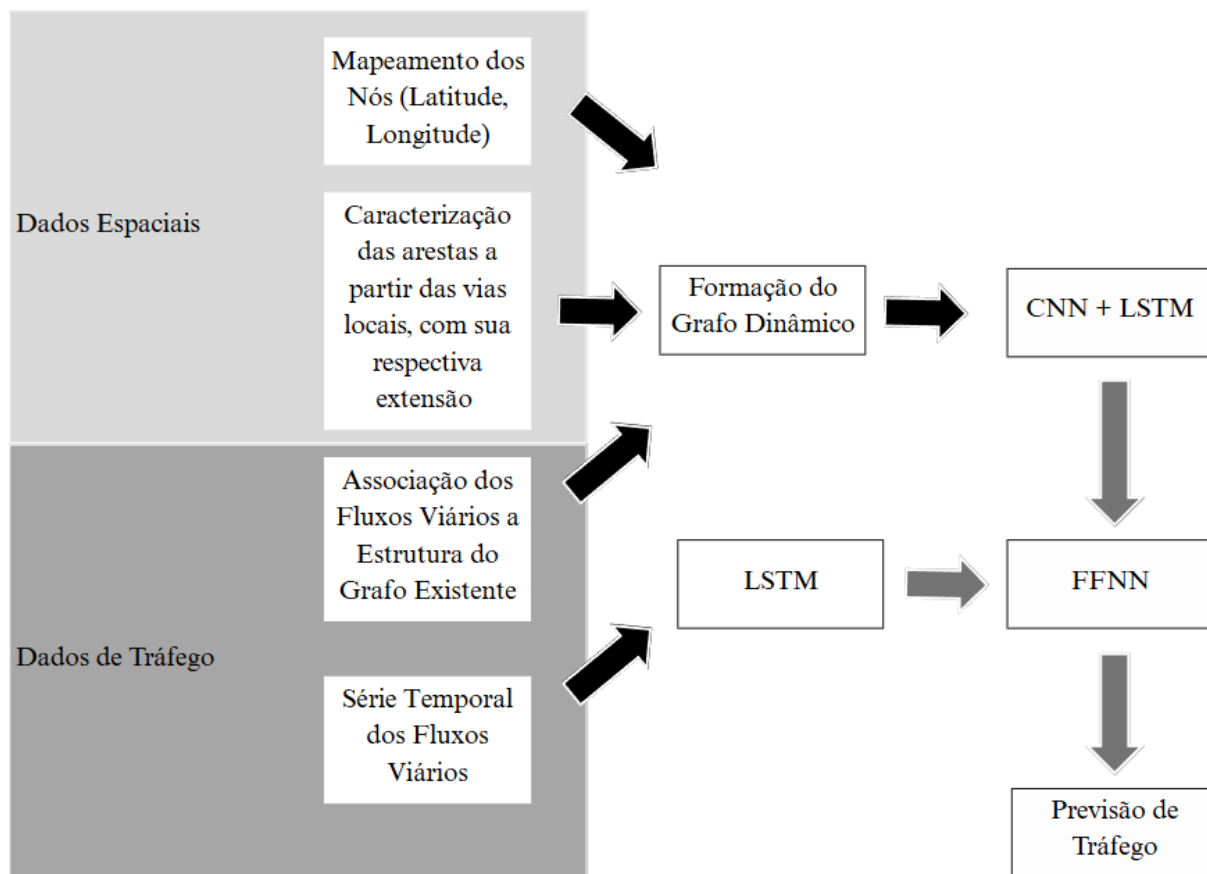


Figura 4.4 Representação do modelo proposto no trabalho
 Fonte: Zheng *et al.* (2019).

O modelo tem como objetivo principal a captação das informações espaciais da malha viária a partir da camada CNN-LSTM e o processamento da série temporal dos fluxos viários a partir da camada LSTM. A partir da captura das informações conjuntos de camadas citadas anteriormente, o processamento é repassado para a FFNN, que, então, dirá o valor do fluxo viário previsto. O foco principal do modelo é a tentativa e a busca de verificar se a entrada do grafo dinâmico melhora as previsões, assim, a comparação entre o valor predito e o valor real é importante para a validação do modelo. Para caracterizar melhor cada camada, as seções seguintes explicarão a quantidade de camadas a partir de cada componente.

4.4.1. Componente 1: CNN-LSTM – Extração de Relações Espaciais

O primeiro componente da arquitetura é um módulo de CNN-LSTM aplicado à matriz de adjacência da rede viária, responsável por capturar padrões espaciais e temporais no tráfego ao

longo do tempo. Esse módulo processa os dados de tráfego utilizando uma matriz de adjacência dinâmica normalizada A , que representa a conectividade entre os segmentos viários.

- Entrada: Matriz de características da via X_t e matriz de adjacência dinâmica A .
- Operação: A *Graph CNN-LSTM* aplica convoluções sobre o grafo, combinando informações de nós adjacentes para produzir representações espaciais, processa as informações em relação a série temporal formada na matriz de adjacência:
- Saída: Matriz H_t contendo informações espaciais processadas para uso na etapa seguinte.

Tabela 4.1 Apresentação das camadas do processamento da matriz dinâmica

Camada	Quantidade de Neurônios/Filtros	Função
Entrada do Grafo	-	Recebe a matriz de adjacência normalizada ao longo da janela temporal (LOOKBACK).
Camada Convolutacional 1	16 filtros (3x3)	Captura padrões espaciais locais na matriz de adjacência ao longo do tempo.
Camada Convolutacional 2	16 filtros (3x3)	Aprimora a extração de características espaciais, permitindo maior profundidade na análise.
Camada de Pooling	Redução dimensional (2x2)	Reduz a complexidade da matriz ao destacar as informações mais relevantes.
Camada de Flattening	-	Transforma os mapas de características convolucionais em um vetor 1D para ser processado na LSTM.
Camada LSTM	64 neurônios	Captura padrões temporais nos dados extraídos das convoluções, criando uma representação compacta para a previsão.

4.4.2. Componente 2: LSTM – Extração de Relações Temporais

Simultaneamente com a extração das características espaciais, as representações H_t são enviadas para uma Rede Neural Recorrente baseada em LSTM. Esse modelo captura padrões temporais de curto e longo prazo nos dados de tráfego.

- Entrada: Sequência temporal de representações espaciais $\{H_t, H_{\{t-1\}}, \dots, H_{\{t-m\}}\}$
- Operação: O LSTM processa a sequência temporal.
- Saída: Vetor h_t representando a síntese das informações temporais acumuladas.

Tabela 4.2 Apresentação da camada de processamento de tráfego ao longo do tempo

Camada	Quantidade de Neurônios/Filtros	Função
Entrada Temporal	-	Recebe a sequência temporal do tráfego ao longo da janela <i>LOOKBACK</i> .
Camada de Reshape	$LOOKBACK \times 1$	Transforma a entrada 1D em uma estrutura compatível para a LSTM.
Camada LSTM	64 neurônios	Processa dependências temporais nos dados, extraindo padrões ao longo do tempo.

4.4.3. Componente 3: Rede Neural *Feed-Forward* (FFNN) – Integração e Previsão Final

Após o processamento das relações espaciais e temporais, os resultados são combinados em uma rede neural *feed-forward* (FFNN), que junta as duas informações aplicando camadas densas até encontrar o fluxo previsto $t + n$.

- Entrada: Vetor do LSTM h_t e o valor da representação da matriz de adjacência processada na CNN-LSTM H_t :
- Operação: A FFNN processa essas entradas em camadas densas para modelar relações complexas.
- Saída: Previsão do estado de tráfego no próximo instante de tempo $t + n$.

Dessa forma, constrói-se o modelo, que será utilizado para a primeira análise de resultados no Capítulo 6. Para isso, serão explorados três conjuntos de dados distintos: o conjunto completo, os

dados referentes apenas a dias de semana e os dados restritos a finais de semana. Essa segmentação permitirá uma avaliação do comportamento do tráfego em diferentes contextos de base de dados.

Tabela 4.3 Apresentação da camada que forma a previsão

Camada	Quantidade de Neurônios/Filtros	Função
Concatenação	-	Combina as saídas da CNN aplicada ao grafo (x_{graph}) e da LSTM temporal (x_{temp}).
Camada Densa 1	128 neurônios	Aplica transformação não linear para refinar a representação combinada.
Camada Dropout	0.2	Reduz o risco de <i>overfitting</i> ao desativar neurônios aleatórios durante o treinamento.
Camada de Saída	1 neurônios	Gera a previsão do tráfego,

4.5. MÉTRICAS UTILIZADAS

A avaliação dos modelos desenvolvidos para previsão de tráfego foi conduzida utilizando um conjunto de dados de teste mantido separado durante o treinamento. Essa abordagem assegura que a avaliação reflita a capacidade dos modelos de generalizar para dados novos. Para verificar a eficácia das previsões, foram selecionadas métricas utilizadas na literatura. Assim, foram empregadas três métricas para avaliar o desempenho dos modelos:

- Erro quadrado médio (em inglês *Mean Absolute Error* - MAE): O MAE mede a média dos erros absolutos entre as previsões do modelo e os valores reais. O MAE representa o desvio médio das previsões sem considerar a direção do erro.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.3)$$

- *Mean Squared Error (MSE)*: O MSE calcula a média dos quadrados dos erros, destacando erros maiores devido à sua natureza quadrática. Esta métrica tem o objetivo de identificar modelos que tendem a fazer grandes erros de previsão.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.4)$$

- *Root Mean Squared Error (RMSE)*: A RMSE é a raiz quadrada do MSE e expressa os erros na mesma unidade dos dados originais, o que facilita a interpretação da magnitude dos erros.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.5)$$

No estudo, apenas o erro absoluto médio (MAE), o erro percentual absoluto médio (MSE) e a raiz do erro quadrático médio (RMSE) serão utilizados como métricas de avaliação do modelo. A escolha dessas métricas visa garantir a avaliação do modelo considerando diferentes aspectos do erro, desde a magnitude média até a penalização de grandes desvios, aspectos essenciais na previsão de tráfego, onde variações tanto pequenas quanto grandes no fluxo veicular podem ter implicações importantes e, concomitantemente, mostrando possíveis problemas envolvendo o modelo criado.

5. DADOS UTILIZADOS

Neste capítulo, são apresentados os dados utilizados na pesquisa, abordando o processo de obtenção, o período de coleta e o pré-processamento necessário antes da entrada nas Redes Neurais Artificiais (RNA). Inicialmente, descreve-se a origem dos dados de tráfego, especificando as fontes e o intervalo temporal considerado. São indicados os critérios adotados para a coleta e seleção das informações, bem como as medidas tomadas para lidar com inconsistências e ruídos. O pré-processamento envolveu etapas como normalização, segmentação temporal e espacial, e a transformação de variáveis, quando necessário, visando adequar os dados ao formato exigido pelas RNA. A descrição dos dados seguiu o modelo proposto na tese de doutorado de Barros (2022), que serviu como base para este capítulo. O modelo foi adaptado conforme as características específicas dos dados de tráfego analisados nesta dissertação.

5.1. SELEÇÃO DOS LOCAIS PARA COLETA DOS DADOS DE TRÁFEGO

No Distrito Federal, diversos equipamentos monitoram o volume de tráfego nas vias urbanas e rodoviárias. As vias federais são fiscalizadas pelo Departamento Nacional de Infraestrutura de Transportes (DNIT), enquanto as vias distritais são geridas pelo Departamento de Trânsito do Distrito Federal (DETRAN-DF) e pelo Departamento de Estradas de Rodagem do Distrito Federal (DER-DF).

Durante a seleção, foram analisados trechos de vias coletoras que contassem com um número adequado de equipamentos para viabilizar a análise, uma vez que a modelagem baseada em grafos se beneficia de uma maior quantidade de nós. Dentre as opções consideradas, os trechos 025EDF0070 e 035EDF0010 foram escolhidos, pois, embora inicialmente houvesse a intenção de incluir outros segmentos, esses foram os únicos disponibilizados pelo órgão responsável.

- DF - 025: Trecho 025EDF0070, em ambos os sentidos. Fica entre o acesso à Ponte Honestino Guimarães e a DF-035;
- DF – 035: Trecho 035EDF0010, em ambos os sentidos. Fica entre o acesso à DF-025 e a DF-001.

Na etapa de seleção dos dados, avalia-se a integridade dos dados de cada sensor. O sensor C VS238 apresentava uma quantidade significativa de dados faltantes, o que poderia comprometer a análise, por isso foi excluído. Outros sensores registraram contagens de zero, particularmente entre meia-noite e 4:00 da manhã, o que é esperado em períodos de baixo tráfego. Após a primeira verificação dos dados faltantes, selecionou-se nove dos dez equipamentos para fazer parte do estudo. Os equipamentos desse estudo estão representados na Figura 5.1.

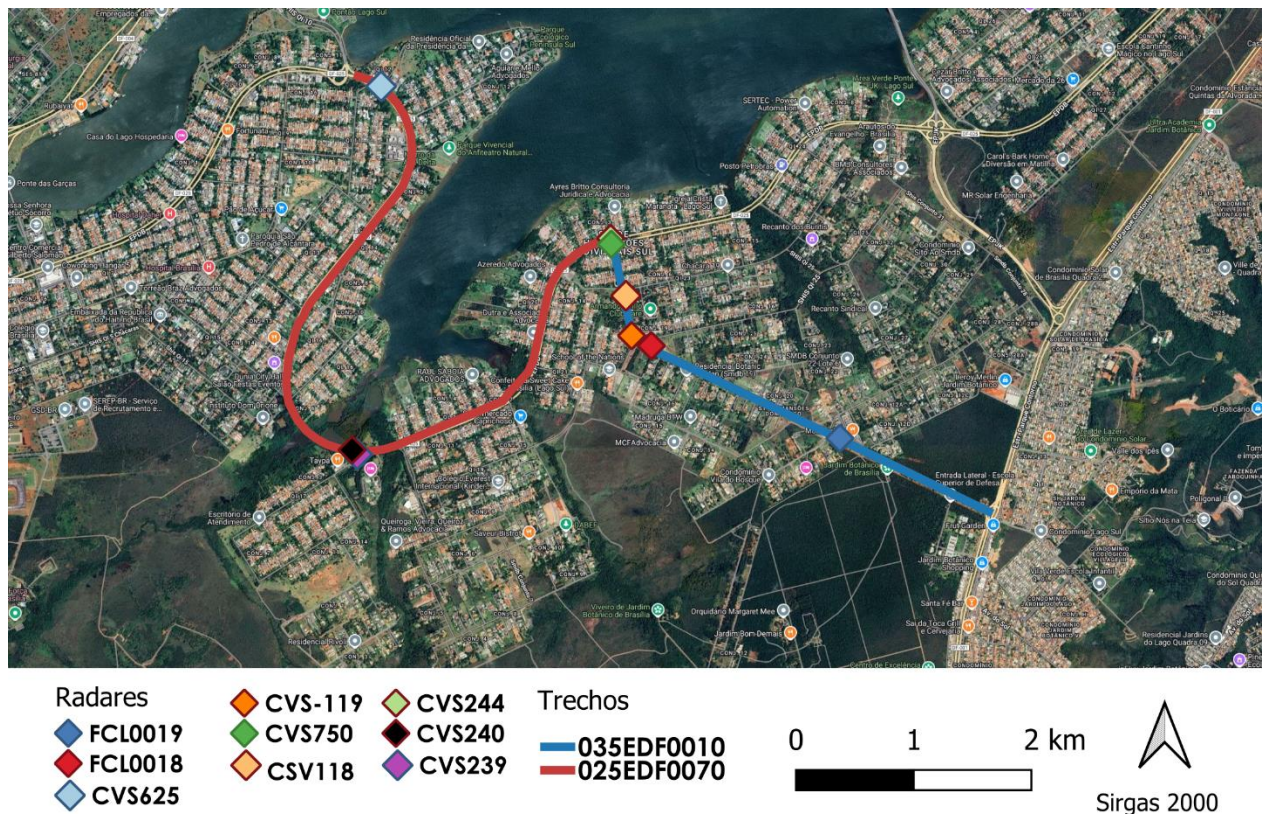


Figura 5.1 Vias e pontos de coleta do estudo

Os dois trechos analisados abrangem ambos os sentidos e foram tratados como vias distintas. Embora a área de estudo inclua vias locais, a ausência de dados específicos para esses subtrechos impossibilitou uma análise mais detalhada, que poderia contribuir para o aprimoramento do modelo proposto. Dessa forma, a pesquisa concentrou-se nos trechos disponibilizados pelo órgão responsável. No entanto, a falta de dados coletados no mesmo período para outros segmentos da

DF-025 representa uma limitação do estudo, restringindo a abrangência da análise e dificultando uma compreensão mais ampla do comportamento do tráfego na região.

O intervalo temporal selecionado para a análise abrangeu o período de janeiro a dezembro de 2024, garantindo uma janela ampliada para capturar padrões regulares de tráfego e viabilizar a incorporação de variáveis sazonais no modelo preditivo. Adicionalmente, a base de dados foi estratificada em três subconjuntos distintos: (i) *dataset* completo, (ii) dias úteis intermediários (terça, quarta e quinta-feira) e (iii) finais de semana (sábado e domingo). Essa segmentação buscou avaliar comparativamente o desempenho do modelo em cenários heterogêneos, permitindo a identificação de discrepâncias preditivas entre períodos com dinâmicas operacionais divergentes.

5.2. DADOS DE SENSORES E DAS CARACTERÍSTICAS DA VIA

A base de dados deste estudo foi constituída a partir de registros fornecidos pelo Departamento de Estradas de Rodagem do Distrito Federal (DER-DF), coletados por meio de uma rede de sensores inteligentes instalados em vias urbanas sob sua jurisdição. Esses dispositivos, distribuídos em 153 trechos viários monitorados, integram tecnologias de fiscalização eletrônica (EFE Tipo II) e câmeras de segurança (CFTV), capazes de capturar parâmetros operacionais do tráfego em tempo real. Dentre as variáveis registradas, destacam-se:

1. Infrações de trânsito (excesso de velocidade, invasão de faixa exclusiva, tráfego em contramão);
2. Contagem volumétrica de veículos por intervalo temporal;
3. Padrões de ocupação viária.

Os dados brutos, processados algoritmicamente pelo DER-DF, são armazenados em arquivos no formato “.csv”, estruturando um histórico temporal contínuo com registros horários de fluxo. Essa série temporal serviu como insumo primário para a modelagem preditiva.

Para representar a topologia da malha viária, complementou-se a base do DER-DF com atributos georreferenciados extraídos do *Google Earth Pro*, organizados em planilhas independentes para preservar a integridade das fontes. Esses metadados incluíram:

1. Coordenadas geográficas (latitude e longitude) de início e fim de cada trecho;
2. Extensão linear dos segmentos;

A partir dessas informações espaciais, modelou-se um grafo direcional da rede viária, onde:

1. Nós correspondem às coordenadas de início/fim dos trechos;
2. Arestas representam os segmentos viários, ponderadas por atributos como extensão e velocidade máxima.

Posteriormente, esse grafo foi incorporado ao modelo de Redes Neurais Artificiais (RNA) como uma matriz de adjacência com atributos espaciais. Essa representação permitiu que a RNA interpretasse não apenas padrões temporais de fluxo, mas também relações de conectividade e restrições físicas entre os trechos (ex.: sentido único, limitações de capacidade).

A integração do grafo viário ao fluxo de dados temporais (arquivos .csv) foi realizada por meio de associações entre arestas e nós, vinculando cada registro de tráfego ao segmento correspondente na topologia da rede. Essa abordagem garantiu que o modelo internalizasse a estrutura espacial da malha, essencial para prever comportamentos de congestionamento em cenários de interdependência entre vias.

5.2.1. Dados Disponíveis

Os dados brutos fornecidos pelo DER-DF, armazenados em arquivos “.csv”, estruturam-se em registros temporais de tráfego com resolução de 15 minutos. Conforme detalhado na Tabela 5.1, o conjunto de dados contém as seguintes variáveis-chave:

Tabela 5.1 Tabela com os dados enviados pelo DER-DF, volume de tráfego

Parâmetro	Informação/Descrição
Trecho	Identificação única do segmento de via monitorado.

Sentido	Em vias com dois sentidos de circulação, o sentido pode ser classificado como crescente ou decrescente.
Dia	Dia em que a informação de tráfego foi captada
Intervalo	Intervalo de captação do volume de tráfego
Veículo	Tipo de veículo observado. Os dados incluem cinco categorias: moto, caminhão, ônibus, passeio e não identificado.
Volume de Tráfego	Quantidade de veículos registrados no intervalo de captação.

A ausência de identificadores veiculares individuais limita a reconstrução de trajetórias, impedindo o cálculo direto de velocidades médias ou tempos de percurso entre trechos. Essa lacuna restringe a análise de dinâmicas microscópicas do tráfego, como a propagação de congestionamentos em cadeia, conforme discutido por Treiber e Kesting (2013).

Para a implementação do modelo de dependência espacial, como discutido anteriormente, foram consideradas as principais características das vias monitoradas, conforme apresentadas na Tabela 5.2. Essas informações incluem:

Tabela 5.2 Tabela com as características da via

Parâmetro	Informação/Descrição
Trecho	Identificação única do segmento de via monitorado.
Latitude Inicial	Latitude do ponto início do trecho
Longitude Inicial	Longitude de ponto início do trecho
Latitude Final	Latitude do ponto final do trecho
Longitude Final	Longitude do ponto final do trecho
Velocidade máxima	-

Extensão

Comprimento do trecho monitorado,
medido em metros

Essas características foram integradas à arquitetura de redes neurais profundas para incorporar a topologia viária e suas interdependências espaciais, fatores que modularam diretamente o comportamento preditivo do sistema. A representação direcional das vias foi codificada nos grafos orientados utilizados na modelagem, assegurando a preservação da cinemática do tráfego (e.g., sentido único ou fluxo bidirecional) durante o treinamento do modelo, conforme estabelecido no referencial teórico. Adicionalmente, a estrutura de grafos empregada — que será detalhada na Seção 6— foi otimizada para capturar relações de conectividade assimétrica

5.2.2. Visão Preliminar dos Dados de Volume de Tráfego

A partir da captação e separação dos dados por dias, foi possível analisar as variações no volume de tráfego ao longo do período de estudo. Essa análise permitiu identificar os padrões típicos das vias urbanas e os momentos de maior fluxo de veículos.

A Figura 5.2 e a Figura 5.3 apresentam a distribuição dos volumes de tráfego diários, como exemplificação. O índice representa a quantidade de dados de fluxo viário em intervalos de 15 minutos. Percebe-se que há padrões e diferenças de sazonalidades no conjunto de dados, esperado pelas diferenças dos volumes de tráfego ao longo dos anos.




Figura 5.2 Séries temporais para o equipamento CVS 239




Figura 5.3 Séries temporais para o equipamento CVS 240

A análise preliminar dos dados de volume de tráfego, ilustrada nas Figuras 5.3 evidenciou flutuações sazonais e padrões operacionais distintos ao longo do ano. Tais variações, como picos de fluxo em horários específicos e reduções significativas em períodos festivos (e.g., dezembro), corroboram a heterogeneidade intrínseca mencionada no modelo. A estratificação dos dados em categorias temporais (dias úteis intermediários, finais de semana e *dataset* agregado) não apenas reflete a segmentação natural observada nas séries temporais, mas também responde à necessidade metodológica de evitar generalizações inadequadas.

A discrepância entre os padrões, especialmente a queda drástica em dezembro, reforça a premissa de que arquiteturas preditivas especializadas são essenciais para capturar relações não lineares específicas de cada contexto. Por exemplo, enquanto dias úteis intermediários podem exibir padrões vinculados a deslocamentos rotineiros, finais de semana podem refletir dinâmicas recreativas ou eventos culturais, conforme sugerido pela distribuição assimétrica nas figuras.

A customização dos modelos por categoria temporal alinha-se diretamente às evidências empíricas obtidas na análise preliminar, convertendo as observações gráficas, como as sazonalidades, em parâmetros ajustáveis para otimização preditiva. Este estudo tem como objetivo a análise dos dias de fim de semana e dias úteis como uma forma de analisar a diferença entre as previsões para esses grupos de dados.

A diferença no fluxo veicular também pode ser observada a partir de uma amostra dos dados de contagem diária de tráfego, permitindo uma análise mais detalhada do comportamento do volume viário em diferentes dias. Essa variação é representada nas Figura 5.4 e 5.5, que ilustram exclusivamente a contagem de tráfego por via.




Figura 5.4 Trecho 025EDF0070, suas variações ao longo dos diferentes dias da semana




Figura 5.5 Trecho 035EDF0010, suas variações ao longo dos diferentes dias da semana

5.2.3. Identificação dos veículos

A análise do volume de tráfego permitiu identificar a distribuição dos diferentes tipos de veículos monitorados, conforme os registros fornecidos pelo DER-DF. A Figura 5.6 apresenta a distribuição

percentual dos tipos de veículos por equipamento ao longo do período analisado. Os dados foram agrupados por intervalos de tempo e separados entre dias úteis e finais de semana para capturar variações comportamentais.




Figura 5.6 Descrição do percentual do tipo de veículo para dia útil. Equipamento: FCL018




Figura 5.7 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS239




Figura 5.8 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS240




Figura 5.9 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS244

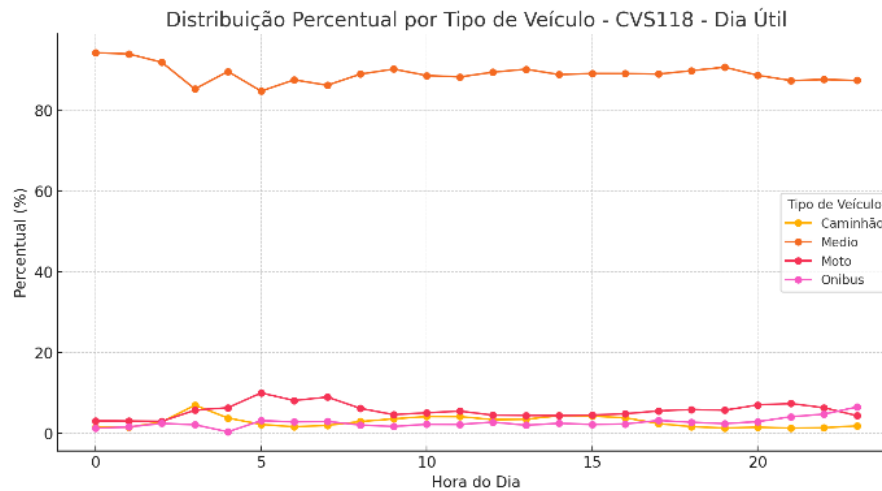


Figura 5.10 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS118




Figura 5.11 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS750




Figura 5.12 Descrição do percentual do tipo de veículo para dia útil. Equipamento: FCL019




Figura 5.13 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS625




Figura 5.14 Descrição do percentual do tipo de veículo para dia útil. Equipamento: CVS119

A análise quantitativa das Figuras revela uma predominância estatística dos veículos de porte médio, que representam entre 80% e 90% da frota em ambos os segmentos viários analisados, independentemente da variação horária. Essa homogeneidade modal exerce um impacto estrutural nas dinâmicas de congestionamento, especialmente na rápida propagação de disrupções e nos picos de emissões locais. Esses efeitos são corroborados por modelos de redes complexas (NAGEL *et al.*, 2003) e por estudos sobre emissões em regime transiente (RAKHA *et al.*, 2011).

5.3. PRÉ-PROCESSAMENTO

O pré-processamento dos dados foi uma etapa fundamental deste estudo, garantindo que as informações de tráfego estivessem organizadas, consistentes e adequadas para o treinamento do modelo preditivo. Esse processo envolveu a combinação, limpeza, filtragem e transformação dos dados, seguindo uma sequência estruturada de etapas interdependentes.

Inicialmente, os dados foram disponibilizados em múltiplos arquivos “.csv”, organizados por diferentes períodos de coleta, com dados dos fluxos viários por equipamento segregados a cada 15 minutos e com a respectiva localização dos dispositivos. Para viabilizar a análise e assegurar a continuidade temporal, esses arquivos foram integrados em um único conjunto de dados unificado. Essa abordagem possibilitou a consolidação de informações provenientes de diversos dias e meses de coleta, resultando em uma base de dados contínua.

Em seguida, as colunas de data e hora foram convertidas para um formato padronizado, no qual ambas as informações foram unificadas para representar com precisão o instante temporal de cada Unidade de Contagem de Passagem (UCP). Esse processo envolveu a fusão dos dados de data e intervalo de tempo, assegurando a correta associação de cada registro ao seu respectivo ponto temporal. Durante essa etapa, registros com erros de formatação foram identificados e eliminados, garantindo a integridade e a confiabilidade dos dados.

Para ficar mais claro, os seguintes passos foram feitos:

- a) Análise dos Sensores e Segmentação dos Dados: Os dados foram juntos, de acordo com o sensor de captação, o tipo de veículo, data, intervalo temporal de 15 minutos e contagem de tráfego.
- b) Calcular o volume equivalente: contagem classificada e ponderada dos veículos i que passaram no sensor L no intervalo j . Para isto deve ser feita a contagem classificada dos veículos por espécie no intervalo (E_v) e multiplicar o volume por espécie pelo fator de equivalência F_e definidos na Tabela 2.1., considerando-se todos os caminhões como tendo 2 eixos. Calcular o volume equivalente E^j com base na equação abaixo

$$E_j = E_v \cdot \text{fluxo} \quad (5.1)$$

Para o tratamento de valores ausentes no volume de tráfego, foi empregada a interpolação linear, método escolhido por sua eficiência na preservação dos padrões temporais da série de dados. Esse procedimento permitiu minimizar a perda de informações relevantes e garantir a consistência na análise do fluxo viário.

5.3.1. Separação dos dados em dados de treinamento, validação e teste.

Para garantir a eficiência do treinamento e da avaliação do modelo, os dados foram divididos em três conjuntos distintos, seguindo a proporção 60-20-20, correspondendo a treinamento, validação e teste, respectivamente. Esse procedimento visa equilibrar a aprendizagem do modelo e a

avaliação de seu desempenho preditivo, garantindo que os resultados obtidos sejam generalizáveis e robustos (BARBOSA, 2019).

A literatura apresenta diversas metodologias para a validação de modelos, mas, de maneira geral, esse processo busca assegurar que o modelo seja adequado ao seu propósito original, proporcionando confiabilidade na interpretação dos resultados. No caso específico das redes neurais artificiais (RNAs), a validação é essencial para a avaliação do desempenho preditivo, sendo comumente realizada com um subconjunto independente de 20% dos dados (BARBOSA, 2019).

Após a separação dos conjuntos, os dados passaram por um processo de normalização, utilizando a técnica *Min-Max Scaling*. Esse método padroniza os valores para uma escala entre 0 e 1, reduzindo discrepâncias causadas por diferentes magnitudes entre as variáveis. A normalização é essencial para evitar que atributos com escalas muito distintas impactem desproporcionalmente o aprendizado da rede neural. A transformação foi realizada com base na seguinte expressão matemática:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (5.2)$$

Onde X é o valor original da característica, X_{min} é o valor mínimo dessa característica no conjunto de dados. X_{max} é o valor máximo dessa característica no conjunto de dados e X_{norm} é o valor normalizado da característica após o processo de *Min-Max Scaling*. Esse processo foi implementado para todas as variáveis numéricas do conjunto de dados, garantindo que o modelo não sofresse distorções devido a escalas desbalanceadas entre os atributos. A Figura 5.15 representa o esquema de processamento com maior detalhamento:

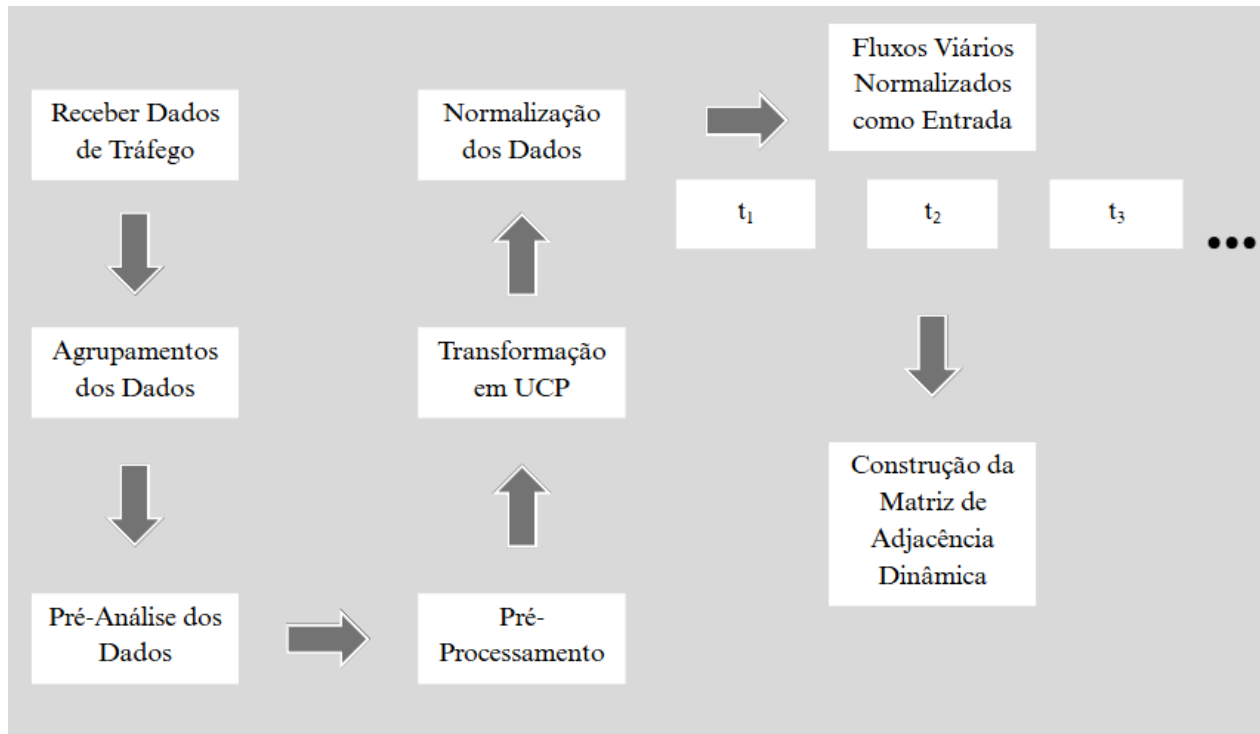


Figura 5.15 Fluxograma para formação da matriz de adjacência dinâmica

Após a normalização, os dados foram estruturados em matrizes de adjacência dinâmicas, que representam as conexões espaciais e temporais entre os diferentes trechos viários ao longo do tempo. Essas matrizes foram utilizadas para capturar as relações entre diferentes segmentos da malha viária, garantindo que o modelo considerasse variações dinâmicas no tráfego.

A construção dessas matrizes seguiu o princípio de aprendizado sequencial, no qual a rede viária foi modelada como um grafo dinâmico, onde os nós representam os trechos analisados e as arestas representam as interações entre eles. As atualizações dessas matrizes ocorreram periodicamente com base no volume de tráfego registrado em cada intervalo de tempo, garantindo que as variações sazonais e operacionais fossem adequadamente capturadas.

Para alimentar o modelo preditivo, os dados foram organizados em sequências temporais deslizantes, onde cada entrada foi composta por um conjunto de observações anteriores, permitindo a identificação de padrões temporais e tendências. Esse método possibilitou ao modelo capturar as dependências de longo prazo no comportamento do tráfego, aprimorando a precisão das previsões.

Pode-se ver esse comportamento na Figura 5.16, que representa os valores de observação para previsão e o valor da previsão.




Figura 5.16 Previsão de Tráfego
 Fonte: Zhan *et al.* (2019).

Por exemplo, os dados de tráfego registrados em 12 períodos anteriores foram utilizados como entrada para prever o tráfego no período subsequente. Essa abordagem assegura que o modelo incorpore relações temporais e espaciais de maneira eficaz, aumentando sua capacidade de generalização e sua aplicabilidade na previsão de demanda viária.

Após toda o pré-processamento e separação da base de dados. Seguiu-se para estipular os hiperparâmetros da rede.

5.4. HIPERPARÂMETROS DOS MODELOS

O treinamento das redes neurais foi implementado integralmente em *Python*, utilizando as bibliotecas *TensorFlow* e *Keras*, que oferecem suporte robusto para modelagem, otimização e ajuste de hiperparâmetros. A configuração dos hiperparâmetros desempenhou um papel fundamental na eficiência do treinamento, estabilidade da rede e capacidade de generalização do modelo preditivo. Cada hiperparâmetro foi ajustado iterativamente para garantir um equilíbrio entre complexidade e desempenho preditivo.

5.4.1. Tamanho do Lote (*Batch Size*)

O tamanho do lote define quantas amostras são processadas antes da atualização dos pesos da rede. Neste estudo, foi adotado um *batch size* de 32, um valor utilizado na literatura devido ao seu compromisso entre eficiência computacional e estabilidade do gradiente.

Lotes muito pequenos (por exemplo, 8 ou 16) podem levar a atualizações instáveis, pois o gradiente sofre variações bruscas entre iterações. Por outro lado, lotes muito grandes (128 ou mais) exigem maior capacidade computacional e podem resultar em generalização ruim, pois o modelo pode convergir para mínimos locais de forma mais rígida. O valor 32 proporciona um equilíbrio adequado entre velocidade de treinamento, estabilidade na otimização e capacidade de generalização do modelo.

5.4.2. Número de Épocas (Epochs)

O número de épocas refere-se à quantidade de vezes que a rede percorre todo o conjunto de treinamento. Inicialmente, os modelos foram treinados por até 200 épocas, mas a estratégia de *early stopping* foi aplicada para interromper o treinamento assim que a função de perda no conjunto de validação deixasse de melhorar, prevenindo *overfitting*.

A escolha desse limite de épocas foi baseada em experimentações preliminares, nas quais se observou que a convergência do modelo ocorria antes de atingir esse número máximo. Além disso, a taxa de aprendizado foi ajustada dinamicamente, permitindo que o modelo estabilizasse o treinamento de maneira eficiente.

5.4.3. Otimização e Função de Perda

O otimizador utilizado foi o Adam (*Adaptive Moment Estimation*), um dos algoritmos mais eficazes para o treinamento de redes neurais profundas. O Adam combina as vantagens dos métodos AdaGrad (*Adaptive Gradient Descent*) e RMSProp (*Root Mean Square Propagation*), ajustando dinamicamente a taxa de aprendizado de cada parâmetro da rede com base no histórico de gradientes. Essa abordagem permite que a otimização seja rápida e estável, reduzindo oscilações e facilitando a convergência.

A função de perda escolhida foi o Erro Quadrático Médio utilizada em problemas de regressão. O MSE penaliza desvios maiores de forma mais acentuada, forçando o modelo a minimizar grandes erros e melhorar a precisão das previsões.

5.4.4. *Lookback* (Janela Temporal de Entrada)

O parâmetro *Lookback* define o número de períodos anteriores considerados pelo modelo para prever o próximo valor. Neste estudo, foi adotado um *lookback* de 8 períodos, significando que as previsões foram baseadas nas 8 observações anteriores da série temporal.

Essa escolha foi determinada a partir da análise da autocorrelação dos dados, garantindo que o modelo capturasse as principais tendências e padrões sazonais sem adicionar complexidade desnecessária. Um *lookback* muito curto pode levar à perda de informações importantes, enquanto um *lookback* muito longo pode introduzir ruído e dificultar a convergência do modelo.

5.4.5. *Forecast* (Horizonte de Previsão)

O horizonte de previsão (*Forecast*) determina quantos períodos à frente o modelo deve prever. Neste caso, foi adotado um *forecast* de n período, ou seja, o modelo prevê o tráfego para o próximo n intervalo de tempo.

Previsões de múltiplos períodos podem ser feitas de forma iterativa, onde o valor previsto em um passo é utilizado como entrada para a próxima previsão.

5.4.6. Taxa de Aprendizado (*Learning Rate*)

A taxa de aprendizado determina o passo que o modelo dá ao ajustar os pesos durante a otimização. Foi adotada uma *learning rate* inicial de 0,001, um valor comum para otimização com Adam, pois oferece um equilíbrio entre estabilidade e velocidade de convergência.

Valores muito altos podem fazer o modelo divergir, enquanto valores muito baixos podem tornar o treinamento excessivamente lento (ENAMOTO, 2023). O ajuste dinâmico da taxa de aprendizado foi utilizado para refinar o desempenho do modelo, permitindo uma convergência eficiente sem comprometer a estabilidade da otimização.

5.4.7. *Dropout*

O *Dropout* foi configurado com uma taxa de 0,2 (20%), funcionando como uma estratégia de regularização para reduzir *overfitting*. O *Dropout* funciona desativando aleatoriamente algumas unidades da rede durante o treinamento, evitando que o modelo memorize padrões específicos do conjunto de treinamento e promovendo uma maior capacidade de generalização.

A escolha de 0,2 foi baseada em experimentações que indicaram que essa proporção é suficiente para melhorar a robustez do modelo sem comprometer sua capacidade de aprendizado. Valores mais altos podem prejudicar a convergência, enquanto valores muito baixos podem ser insuficientes para evitar sobreajuste.

6. RESULTADOS ALCANÇADOS

Para alcançar os objetivos supracitados, foram construídos e avaliados modelos preditivos baseados em séries temporais de tráfego, descritas no capítulo de dados. O modelo *Graph-CNN-LSTM* foi implementado para explorar as correlações espaço-temporais no tráfego urbano. Além disso, as relações entre variáveis foram analisadas e visualizadas por meio de mapas cartográficos, permitindo uma interpretação mais intuitiva dos padrões observados.

6.1. CONSTRUÇÃO DOS MODELOS

Após a realização do estudo preliminar e o processamento dos dados, o algoritmo para a previsão do tráfego foi desenvolvido. Sua estrutura baseia-se na utilização da matriz de adjacência dinâmica como entrada para a CNN, permitindo a extração de padrões espaciais da rede viária, enquanto as séries temporais de tráfego são processadas pela camada LSTM, capturando dependências temporais. A seguir, a Tabela 6.1 apresenta o modelo proposto nesta dissertação, detalhando a metodologia utilizada para a previsão:

Tabela 6.1 Treinamento e resultados dos modelos de rede neurais propostos.

Algorithm 1 Train and Evaluate Hybrid CNN-LSTM Model

Require: test_df: Test DataFrame,

train_df: Train DataFrame,

caracteristicas_data: Graph Characteristics

DataFrame Ensure:

Evaluation metrics: MAE, MAPE, RMSE

1: Load and preprocess train_df and test_df

2: Convert timestamps to datetime format

3: Build a dynamic graph using caracteristicas_data

4: Construct adjacency matrices over time

5: Normalize traffic data using MinMaxScaler

6: Create time sequences for training and testing

7: Define Hybrid CNN-LSTM Model:

7.1: Input adjacency matrix

7.2: Apply Conv2D and MaxPooling2D layers

7.3: Apply LSTM for temporal patterns

-
- 7.4: Input traffic time series data
 - 7.5: Merge CNN and LSTM outputs
 - 7.6: Apply Dense and Dropout layers
 - 7.7: Generate final prediction with Dense layer
 - 8: Compile model with Adam optimizer and MSE loss function
 - 9: Train model for num_epochs
 - 9.1: Train on training data
 - 9.2: Validate on validation data
 - 9.3: Apply EarlyStopping to prevent overfitting
 - 10: Evaluate model on test data:
 - 10.1: Make predictions
 - 10.2: Invert normalization to retrieve actual values
 - 10.3: Compute evaluation metrics: MAE, MAPE, RMSE
 - 11: Save results to an Excel file
 - 12: Return final evaluation metrics: MAE, MAPE, RMSE
-

O modelo desenvolvido integra informações espaciais e temporais para a previsão do tráfego viário, combinando a estrutura da rede viária com séries temporais de fluxo de veículos. Ele recebe como entrada a matriz de adjacência, que representa a conectividade entre os segmentos viários, e os dados históricos de tráfego, permitindo capturar tanto padrões espaciais quanto variações temporais.

A matriz de adjacência é processada por uma rede *convolucional 2D* (Conv2D), que identifica padrões espaciais na malha viária e a relação entre diferentes trechos. Após essa etapa, uma camada de *MaxPooling2D* reduz a dimensionalidade dos dados, preservando as informações mais relevantes. Em seguida, os dados processados são achatados e alimentam uma rede LSTM, permitindo ao modelo aprender a evolução espacial do tráfego ao longo do tempo. Simultaneamente, o histórico de tráfego é processado por outra rede LSTM, que identifica padrões temporais na série histórica.

As saídas dessas duas redes são combinadas em camadas densas com ativação ReLU, garantindo que o modelo tenha ambas perspectivas. Para evitar sobreajustes e melhorar a generalização,

camadas de *Dropout* são aplicadas. Por fim, uma camada densa gera a previsão do volume de tráfego para $t + n$, permitindo antecipar as condições futuras com base nas informações analisadas.

O treinamento do modelo foi realizado dividindo os dados em treino, validação e teste. Durante o treinamento, ele aprendeu padrões históricos de tráfego e características da malha viária. A fase de validação foi essencial para ajustar os parâmetros e garantir um bom desempenho sem sobreajuste aos dados de treinamento. Na fase de teste, o modelo foi avaliado com dados não vistos, verificando sua capacidade preditiva.

Após o treinamento, as previsões do modelo foram comparadas aos valores reais e avaliadas por meio de métricas de erro. Foram calculados o Erro Médio Absoluto (MAE), que mede o desvio médio entre as previsões e os valores reais, o Erro Percentual Médio Absoluto (MAPE), que expressa esse erro em termos percentuais, e a Raiz do Erro Quadrático Médio (RMSE), que avalia a dispersão dos erros.

6.2. CONSTRUÇÃO DO GRAFO PARA REPRESENTAÇÃO DAS CORRELAÇÕES ESPAÇO-TEMPORAIS

A previsão de tráfego de curto prazo requer a consideração tanto de padrões temporais quanto de interdependências espaciais entre diferentes segmentos viários. Para capturar essas relações, foi desenvolvida uma abordagem baseada em grafos dinâmicos, nos quais os pesos das conexões entre nós variam conforme o volume de tráfego registrado em cada período.

6.2.1. Estruturação do Grafo e Definição dos Nós

Os dados de tráfego utilizados neste estudo foram coletados por sensores individuais, cada um associado a um segmento viário específico. Dessa forma, a modelagem do grafo foi estruturada considerando as vias como nós do sistema, conectados com base em suas coordenadas geográficas e características estruturais.

A definição dos nós seguiu os seguintes critérios:

- Cada nó representa um ponto de interseção ou extremidade de um segmento viário;

- As conexões (arestas) entre nós foram estabelecidas com base nas características espaciais da via, considerando os pontos inicial e final (latitude e longitude) de cada trecho analisado;
- O comprimento das vias foi incorporado à estrutura do grafo, permitindo uma melhor representação espacial do sistema viário.

A Figura 6.1 ilustra a representação gráfica dessa modelagem, destacando a estrutura espacial adotada no estudo.

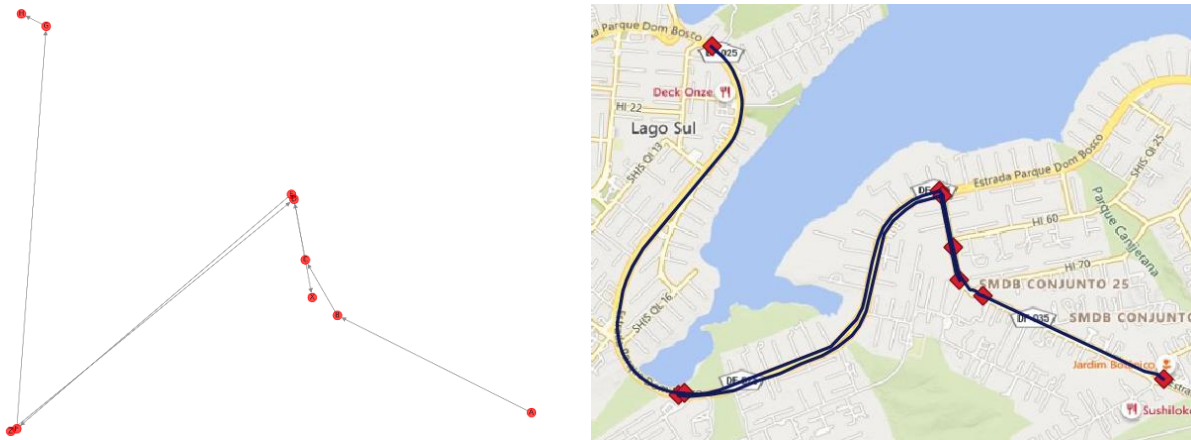


Figura 6.1 Grafo formado para análise espacial do modelo preditivo e a imagem da disposição real dos sensores

É importante ressaltar que a modelagem em grafos não considera curvas ao longo das vias, o que pode gerar discrepâncias quando comparada a métodos tradicionais de cálculo de tempos de percurso. No entanto, para a finalidade do estudo, a abordagem foi empregada para capturar relações estruturais básicas entre os segmentos viários, sem a necessidade de incluir elementos como acessos, interseções e semáforos.

Ainda assim, o grafo desempenha um papel fundamental ao integrar informações de fluxo viário, permitindo uma análise das variações de tráfego ao longo do tempo. A inclusão da variável peso dos veículos nas conexões do grafo possibilita a opção de o modelo aprender ao longo do tempo das condições do tráfego.

6.2.2. Construção da Matriz de Adjacência Dinâmica

Para capturar as interdependências temporais e espaciais, foi necessário integrar as informações de conectividade da rede viária com os dados temporais de tráfego. Esse processo envolveu os seguintes passos:

1. Mapeamento das arestas (conexões entre nós)
 - Cada registro de tráfego (UVP) foi associado a um código de Grupo, que mapeia diretamente para um segmento viário específico no banco de dados Caracteristicas.xlsx.
2. Definição dos nós do grafo
 - A partir dos dados de “*startNode*” e “*endNode*”, foram identificados 9 nós únicos, correspondendo a interseções ou extremidades de corredores viários.
3. Estruturação da conectividade
 - Com os nós e arestas definidas, foi construída a matriz de adjacência estática, representando quais nós estão conectados diretamente.
 - Essa matriz tem dimensões 9×9 , onde cada posição $(i, j) = 1$ indica que há uma conexão entre os nós i e j .
 - As conexões são direcionais, ou seja, um trecho $A \rightarrow B$ pode existir sem que $B \rightarrow A$ seja válido, refletindo a direção do tráfego.
4. Atribuição de pesos dinâmicos (Matriz de Adjacência Temporal)
 - Cada aresta do grafo recebeu um peso dinâmico, que variava ao longo do tempo com base no fluxo veicular (UVP).
 - Dessa forma, em vez de uma matriz de adjacência fixa, foi gerada uma sequência de matrizes, onde os valores mudam conforme a intensidade do tráfego em diferentes intervalos de tempo.

6.3. PREVISÕES DE TRÁFEGO USANDO O GRAPH-LSTM-CNN

Para avaliar a eficácia dos modelos na previsão do tráfego, foi necessário definir os principais aspectos que poderiam influenciar o desempenho preditivo. A estrutura dos dados e a forma como as informações foram incorporadas ao modelo desempenham um papel fundamental na precisão das previsões. Assim, algumas variáveis-chave foram selecionadas para análise, permitindo comparações e ajustes metodológicos conforme necessário. Os critérios adotados foram:

1. Banco de Dados: Foram utilizados três conjuntos de dados distintos, segmentados em todos os dias, dias de semana e finais de semana, permitindo uma análise mais específica das variações no tráfego.
2. Matriz de Adjacência: A estrutura da rede viária foi representada por uma matriz de adjacência estática, contendo informações fixas sobre as conexões entre os nós, e uma matriz dinâmica, que reflete a variação das conexões entre as vias ao longo do tempo.
3. Abrangência: O estudo considerou um grupo composto por dois eixos de vias urbanas monitorados por nove sensores, abrangendo um intervalo de um ano, com medições realizadas a cada 15 minutos.
4. Horizonte de Previsão: Foram definidos dois grupos distintos. Para o conjunto de dados que engloba todos os dias, as previsões foram feitas para intervalos de 15 a 120 minutos. Já para os conjuntos segmentados em dias de semana e finais de semana, as previsões foram realizadas para 15, 30 e 120 minutos.

6.3.1. Previsão de Tráfego para o Conjunto de Todos os Dias

Após a caracterização completa dos dados e a aplicação do modelo de previsão, a Figura 6.2 apresenta graficamente os resultados obtidos, demonstrando a sobreposição entre os fluxos de tráfego observados e previstos em diferentes horizontes temporais (15, 30 e 120 minutos) no equipamento CVS118. No gráfico, os valores reais de tráfego, extraídos do conjunto de teste, são representados na cor preta, enquanto as previsões do modelo aparecem em vermelho. A diferença entre os valores observados e preditos é destacada em azul, permitindo uma análise visual do desempenho do modelo em distintos intervalos de previsão.

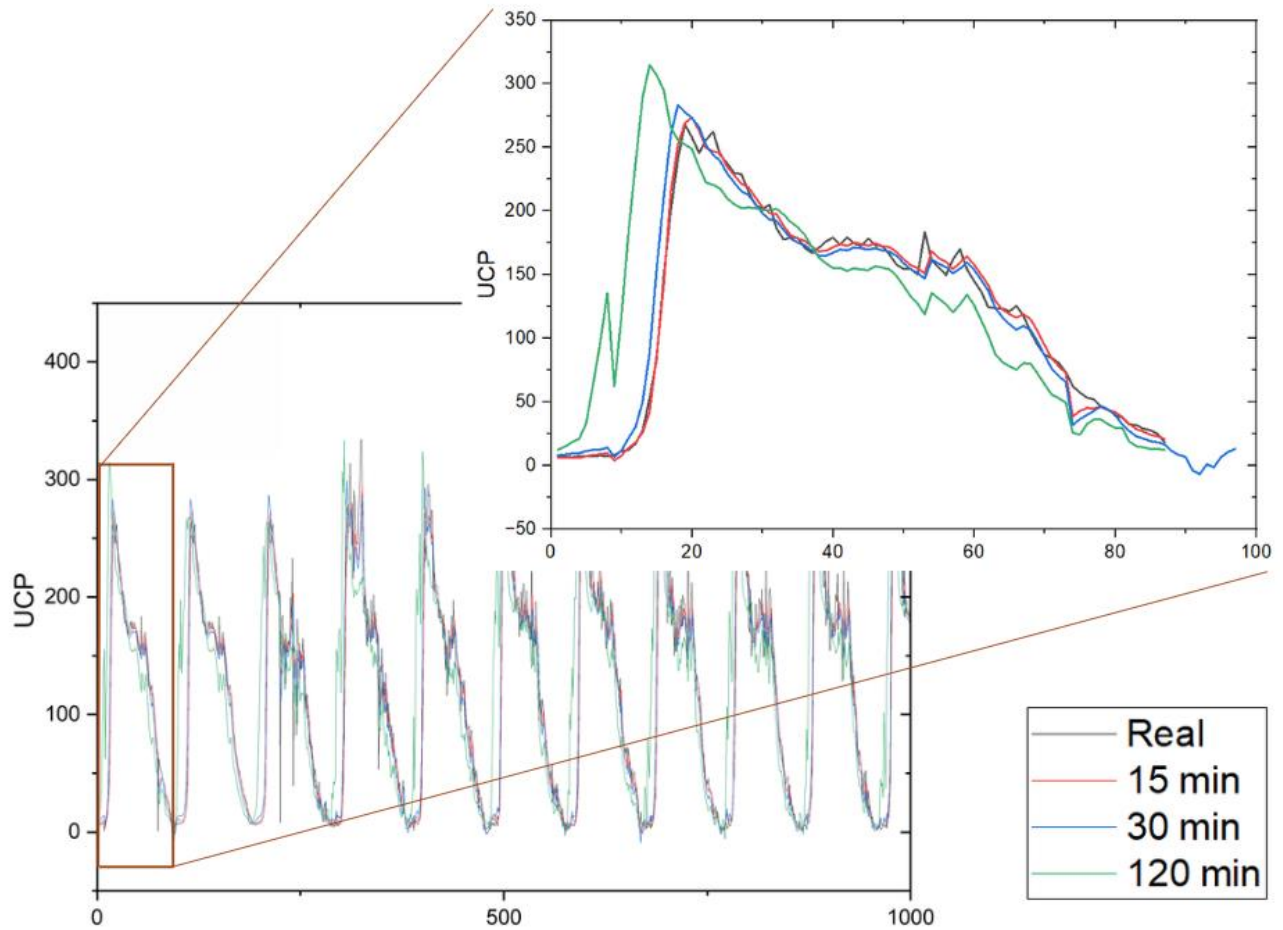


Figura 6.2 Equipamento CVS118: Sobreposição dos fluxos de tráfego com a unidade de veículo padrão para 15 min ($t+1$), 30 ($t+2$) e 120 minutos ($t+8$). A aproximação se refere ao intervalo de 1 dia

As Figuras 6.3 a 6.11 apresentam as séries temporais correspondentes a cada um dos equipamentos analisados, comparando os valores reais observados com as previsões geradas pelo modelo para um horizonte de 15 minutos. Em cada gráfico, a linha preta representa os dados reais de fluxo veicular, enquanto a linha vermelha indica os valores preditos pelo modelo.

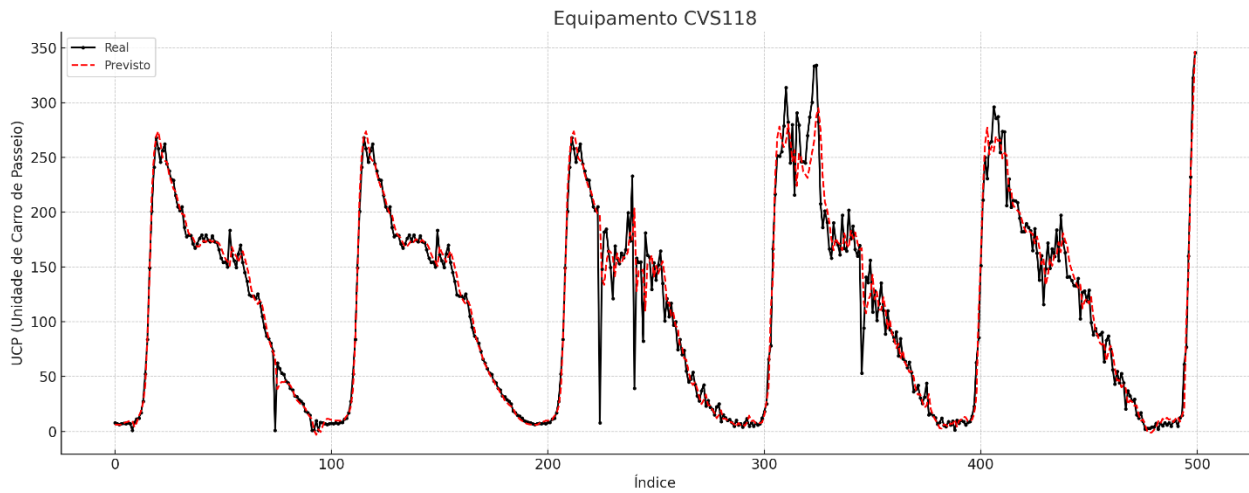


Figura 6.3 Previsão de Tráfego para o equipamento CVS118.




Figura 6.4 Previsão de Tráfego para o equipamento CVS119




Figura 6.5 Previsão de Tráfego para o equipamento CVS239




Figura 6.6 Previsão de Tráfego para o equipamento CVS240




Figura 6.7 Previsão de Tráfego para o equipamento CVS244




Figura 6.8 Previsão de Tráfego para o equipamento CVS625

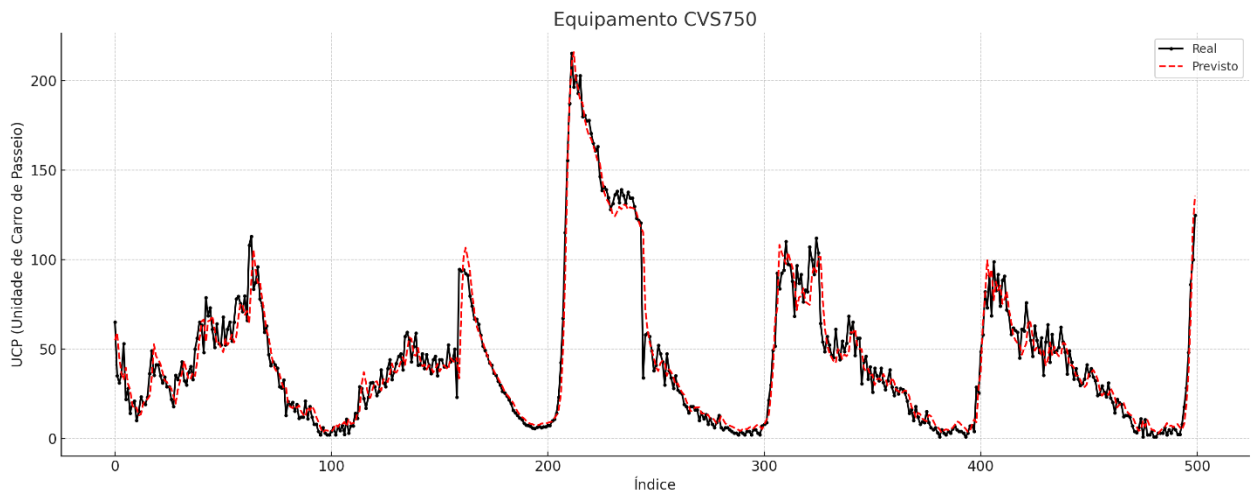


Figura 6.9 Previsão de Tráfego para o equipamento CVS750

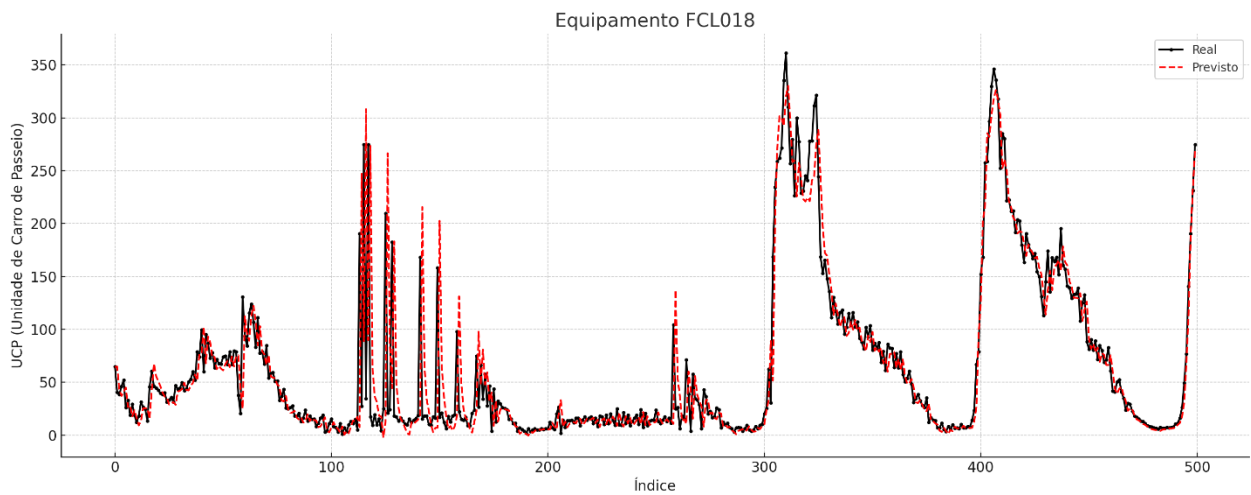


Figura 6.10 Previsão de Tráfego para o equipamento FCL018




Figura 6.11 Previsão de Tráfego para o equipamento FCL019

Para previsões de um passo a frente, ou seja, 15 minutos, percebe-se que as diferenças entre os valores previstos e valores reais são pequenos, quando se olha para o gráfico, percebe uma diferença maior a partir nos picos. Essa diferença, de maneira quantitativa, vista pode ser visto a partir da diferença entre a partir da Tabela 6.2 dada abaixo:

Tabela 6.2 Parâmetros encontrados MAE médios para cada equipamento nos horários de pico encontrados nas séries temporais

Equipamento	MAE (Todos os horários)	MAE (Manhã 7 - 9h)	MAE (Tarde 12- 14h)	MAE (Noite 17- 19h)
CVS239	20,1	29,7	27,2	35,6
CVS240	20,5	36,7	25,9	27,2
CVS244	12,9	22,8	16,3	17
CVS625	14,3	25,2	14,4	22,6
CVS750	11,9	21,1	15,4	13,3
FCL018	13,4	23,1	15	17,2
FCL019	10,8	20,6	11,4	12,6
CVS118	12,3	19,9	14,9	15,1
CVS119	15	21,1	16,8	23,5

Os problemas envolvendo relacionados com a predição de tráfego em condições de alta demanda em horários de pico pode ser explicados a partir de alguns artigos da literatura científica. Cogoni *et al.* (2022) investigou a formação de congestionamentos em redes urbanas durante os horários de pico e concluíram que, com o aumento do número de veículos, as interações se tornam mais complexas, dificultando a previsão precisa dos padrões de fluxo. De maneira similar, Nagel e Rasmussen (1995) destacaram que, em situações de saturação de tráfego, o sistema de tráfego se aproxima de um estado crítico, reduzindo a previsibilidade dos tempos de viagem. A partir dos artigos anteriormente mencionados, os resultados podem indicar que sistemas de gerenciamento de tráfego que operam próximos à capacidade máxima podem, aumentar a imprevisibilidade do fluxo, e, assim, tornar a predição de tráfego com maiores erros principalmente nos períodos de horário de pico.

A análise da previsão com os parâmetros foi, inicialmente, realizada para intervalos de 15 minutos, sendo posteriormente ampliada para horizontes de previsão maiores, variando entre 15 e 120 minutos. Para avaliar o desempenho das previsões feitas pelo modelo, foram consideradas três métricas estatísticas: MAE, RMSE e MSE. Os resultados detalhados desta avaliação estão apresentados nas Tabelas 6.3, 6.4 e 6.5.

Tabela 6.3 Parâmetros encontrados para os dias de semana em diferentes horizontes de previsão para o Erro Médio Absoluto (MAE)

	15 min	30 min	45 min	60 min	75 min	90 min	105 min	120 min
CVS118	12,3	14,4	15,6	17,7	18,4	21,2	22,2	23,8
CVS119	15	18,5	21,3	24,6	26,9	27,8	29,6	31,6
CVS239	20,1	23,7	27,3	30,2	34,7	36,4	36,5	38,6
CVS240	20,5	25,3	28,5	31,9	38,1	39,6	43,1	46,4
CVS244	12,9	14,8	17,5	19,3	22,5	24,4	26,6	28,3
CVS625	14,3	17,6	19,4	22,4	22,8	25,6	28,2	28,1
CVS750	11,9	13,3	15,1	17	19,4	21,3	22,7	23,9

FCL018	13,4	17,5	19,5	22,3	25,3	25,4	27,6	29,9
FCL019	10,8	13	15	17,1	20,5	21,5	22,6	23,5

Tabela 6.4 - Parâmetros encontrados para os dias de semana em diferentes horizontes de previsão para Raiz do Erro Quadrático Médio (RMSE)

	15 min	30 min	45 min	60 min	75 min	90 min	105 min	120 min
CVS118	18,4	21,2	23,1	26	28,4	32	36,1	37,1
CVS119	22	27,3	30,6	35,1	38,3	40,1	43,2	46
CVS239	32,8	37,2	41,3	44,4	50	52,6	54,3	55,7
CVS240	32,4	38,8	42,8	46,6	55,5	56,8	63,6	66,6
CVS244	19,9	22,6	26,2	28,7	32,3	35,3	37,9	39,8
CVS625	22,9	27,1	29,2	32,3	33,3	36,6	39,4	39,5
CVS750	21	22,8	25,2	28,2	31,3	34,8	37,4	39,1
FCL018	23	28,4	32,6	36,4	40,3	41	45	48,8
FCL019	18,7	23,3	26,9	30	33,8	36,6	38,5	39,5

Tabela 6.5 - Parâmetros encontrados para os dias de semana em diferentes horizontes de previsão para o Erro Quadrático Médio (MSE)

	15 min	30 min	45 min	60 min	75 min	90 min	105 min	120 min
CVS118	337	450,8	532,8	674,6	805,4	1024,4	1306,7	1373,4
CVS119	483,6	743,2	936,4	1232	1470,2	1608,9	1863,1	2119,9
CVS239	1073,7	1380,8	1706,8	1972,2	2496,4	2770,3	2950,6	3103,8
CVS240	1049,9	1505,4	1835,2	2170,2	3079,6	3220,8	4047,2	4431,9
CVS244	396	509,9	688,7	821,9	1042,4	1244,4	1439,9	1587,1
CVS625	522,8	733,9	852,1	1044,9	1105,7	1338,6	1552,5	1563,5

CVS750	440,7	521,6	637,4	797,4	977,8	1211,6	1396,1	1528,6
FCL018	528,2	807,6	1064,8	1324,6	1620,6	1677,1	2023,1	2382
FCL019	350,8	542,5	723,9	898,1	1143,4	1341,2	1485,6	1564,1

Os resultados indicam um aumento progressivo dos erros conforme o horizonte de previsão se amplia, evidenciando uma degradação na acurácia do modelo ao longo do tempo. Esse comportamento era esperado, uma vez que previsões para períodos mais longos estão sujeitas a uma maior incerteza e influências externas mais complexas (BOUKERCHE E WANG, 2020).

Entre as vias analisadas, destaca-se que CVS240 e CVS239 apresentaram os maiores erros em todas as métricas, especialmente em horizontes mais longos. O MSE para essas vias atingiu valores superiores a 4000 em 120 minutos, sugerindo que essas regiões possuem maior variabilidade ou desafios específicos na previsão. O RMSE reforça essa observação ao penalizar desvios maiores, indicando que esses trechos sofrem com flutuações mais intensas nos valores previstos. Por outro lado, vias como CVS750 e FCL019 demonstraram erros significativamente menores, com valores de MAE e RMSE mais baixos, sugerindo que as previsões nesses locais são mais estáveis.

A deterioração das métricas de previsão nos equipamentos CVS240 e CVS239 está diretamente relacionada ao volume de fluxo equivalente. A análise das séries temporais ao longo do ano revela que esses equipamentos registram valores máximos entre 600 e 700 veículos equivalentes, enquanto os equipamentos CVS750 e FCL019 apresentam fluxos significativamente menores, variando entre 300 e 400 veículos equivalentes nos horários de pico. Esse comportamento reforça a influência dos períodos de maior demanda, que, conforme discutido anteriormente, foram os momentos em que o modelo apresentou as maiores discrepâncias entre os valores previstos e os valores reais.

No curto prazo (15 a 60 minutos), as previsões apresentaram um desempenho mais consistente, com o MAE variando entre 10,8 e 32,4 e o RMSE permanecendo abaixo de 50 para a maioria das vias. Esse resultado demonstra que o modelo é eficiente para previsões imediatas, mantendo os erros sob controle em períodos mais curtos. Entretanto, a partir de 75 minutos, os erros se

intensificam de forma mais acentuada, sendo que, em 120 minutos, algumas vias ultrapassam MAE de 46,4 e RMSE de 66,6, tornando a previsão menos confiável.

Com base nesses achados, torna-se evidente a necessidade de otimizar as previsões para horizontes superiores a 75 minutos, visto que os erros aumentam significativamente a partir desse ponto. Técnicas avançadas, como ajustes na modelagem, inclusão de variáveis sazonais ou refinamentos no aprendizado profundo, poderiam contribuir para a redução dos desvios e melhoria na precisão das previsões de longo prazo.

6.3.1.1. Estratégias para Prevenção de *Overfitting* e *Underfitting* na Modelagem Preditiva

Um dos desafios mais significativos no treinamento de redes neurais artificiais está relacionado ao *overfitting* e *underfitting*, fenômenos que afetam diretamente a capacidade de generalização do modelo.

O *overfitting* ocorre quando o modelo aprende excessivamente os padrões específicos dos dados de treinamento, incluindo ruídos e variações aleatórias, resultando em um desempenho artificialmente elevado no treino, mas com baixa capacidade de generalização para novos dados. Esse comportamento compromete a robustez do modelo, tornando suas previsões inconsistentes quando aplicado a cenários não vistos durante o treinamento. Segundo Goodfellow *et al.* (2016), a regularização desempenha um papel fundamental na mitigação desse problema, sendo métodos como regularização L1/L2, *Dropout*, aumento do conjunto de dados (*data augmentation*) e *early stopping* amplamente utilizados para reduzir o risco de sobreajuste do modelo.

Por outro lado, o *underfitting* ocorre quando o modelo não consegue capturar de maneira adequada as relações subjacentes nos dados, resultando em uma performance insatisfatória tanto no conjunto de treinamento quanto no de validação. De acordo com Bishop (2006), esse problema pode ser decorrente de uma arquitetura inadequada (modelo muito simples para a complexidade do problema), falta de treinamento suficiente ou uma escolha inadequada de hiperparâmetros, como uma taxa de aprendizado muito alta que impede a convergência. Para lidar com o *underfitting*, é possível ajustar a complexidade do modelo, aumentar o número de camadas e neurônios, melhorar a qualidade dos dados de entrada e otimizar os hiperparâmetros do treinamento.

No modelo (as estratégias para evitar o sobreajuste (*overfitting*) e garantir que os resultados não fossem enviesados seguiram as diretrizes previamente mencionadas. Para isso, os dados foram divididos em conjunto de treinamento, validação e teste, assegurando que o modelo fosse avaliado de maneira independente, sem aprendizado direto a partir dos dados de validação ou teste. A Figura 6.12 do lado esquerdo exibe a função de perda ao longo das épocas, também conhecida como curva de perda, enquanto do lado direito ilustra o momento em que o modelo aprende corretamente, demonstrando a estabilização da *loss* e a convergência para um valor mínimo:

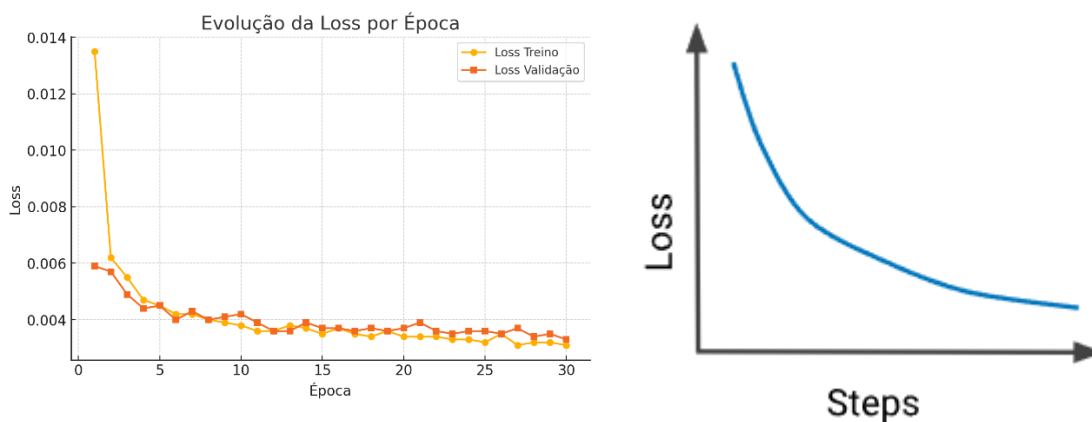


Figura 6.12 Evolução da função de perda ao longo das épocas

A Figura 6.12 apresenta a evolução da função de perda ao longo das épocas, permitindo a análise do comportamento do modelo durante o treinamento e o processo esperado de convergência do modelo, demonstrando a redução gradual dos valores da função de perda à medida que as iterações avançam, indicando o aprendizado progressivo e a estabilização da rede neural.

Além disso, ambos os modelos incorporaram camadas de *dropout* na rede neural densa, uma técnica essencial para reduzir o risco de sobreajuste ao zerar aleatoriamente uma fração dos neurônios durante o treinamento, impedindo que o modelo memorize padrões específicos dos dados de treino. Outra estratégia adotada foi a implementação do *early stopping*, que monitora a *loss* no conjunto de validação e interrompe o treinamento caso o modelo mantenha os mesmos valores de perda por cinco épocas consecutivas, evitando treinamentos desnecessários e prevenindo ajustes excessivos aos dados de treino.

Após a implementação dessas estratégias no código, foi realizada uma análise da função de perda para cada equipamento. Os resultados demonstraram que não havia necessidade de utilizar 30 épocas para o treinamento, especialmente nos conjuntos de dados referentes aos dias de semana e finais de semana. Assim, o número de épocas foi reduzido pela metade, para 15, pois o modelo indicou uma estabilização da perda e um aprendizado adequado para todos os equipamentos a partir desse ponto. Essa redução não apenas otimizou o tempo de treinamento, mas também minimizou o risco de ajustes desnecessários, garantindo um equilíbrio entre convergência eficiente e generalização adequada. A Figura 6.13 apresenta a variação da função de perda ao longo das épocas para cada equipamento analisado. Esse gráfico permite visualizar o comportamento do modelo durante o treinamento, destacando o ritmo de convergência e identificando eventuais diferenças na taxa de aprendizado entre os diferentes dispositivos monitorados.




Figura 6.13 Evolução da Função de Perda por Época para Cada Equipamento

6.3.2. Previsão de Tráfego para o Conjunto de Dias de semana e Dias de finais de semana

Após a avaliação sobre o modelo de previsão usando todos os dados, pulou-se para análise usando apenas dias de semana e dias de finais de semana. O intervalo temporal de previsão ficou sobre os

valores de 15 minutos, 30 minutos e 120 minutos. Esse formato foi feito para comparar o conjunto de dados inteiros com os de dia de semana e final de semana.

Tabela 6.6 - Parâmetros encontrados para os MAE, RMSE e MSE para dias de semana

	MAE			MSE			RMSE		
	15 min	30 min	120 min	15 min	30 min	120 min	15 min	30 min	120 min
CVS118	13,7	14,9	24,3	371,7	472,2	1411,7	19,3	21,7	37,6
CVS119	16,9	21,4	37,8	642	1007,5	2762,3	25,3	31,7	52,6
CVS239	24,6	29,7	46,9	1605,4	2154,6	4782,6	40,1	46,4	69,2
CVS240	22	25,6	52,2	1139,7	1476,9	5638,8	33,8	38,4	75,1
CVS244	13,7	15,8	33,3	404,2	542,1	1963,8	20,1	23,3	44,3
CVS625	16	19,6	34,4	694,9	960,3	2173,9	26,4	31	46,6
CVS750	11,7	14,1	27,9	337,1	444,3	1829,4	18,4	21,1	42,8
FCL018	15,2	18,2	32,2	524,5	768,4	2451,1	22,9	27,7	49,5
FCL019	12,5	14,5	27,3	391,4	567,4	1859,4	19,8	23,8	43,1

Tabela 6.7 - Parâmetros encontrados para os MAE, RMSE e MSE para dias de final de semana

	MAE			MSE			RMSE		
	15 min	30 min	120 min	15 min	30 min	120 min	15 min	30 min	120 min
CVS118	11,1	12,9	23,5	254,4	323	996,6	15,9	18	31,6
CVS119	11,9	14,6	27,8	257,8	393,6	1249,4	16,1	19,8	35,3
CVS239	16,8	20,8	38,1	619,3	876,7	2353,1	24,9	29,6	48,5
CVS240	18	22,4	45,6	703,7	1090,1	3667,1	26,5	33	60,6
CVS244	11,1	13,8	25,4	296,3	476,3	1154	17,2	21,8	34
CVS625	11,6	14,1	25,2	331,2	445,7	982,9	18,2	21,1	31,4
CVS750	10,3	11,9	22,9	297,8	339,1	1103	17,3	18,4	33,2
FCL018	10,7	14,5	28,4	286,5	451,9	1668,7	16,9	21,3	40,8
FCL019	9	11,8	24,7	186,3	310,3	1282,6	13,6	17,6	35,8

Para previsões de curto prazo, especificamente no horizonte de 15 minutos, os erros observados foram significativamente menores em comparação com previsões de períodos mais longos. Esse resultado sugere que o modelo consegue capturar com maior precisão as dinâmicas de tráfego imediatas, aproveitando a continuidade natural dos fluxos veiculares. Isso pode estar relacionado ao fato de que, em curtos intervalos, as condições do tráfego apresentam menor variabilidade, tornando as previsões mais confiáveis. Dessa forma, o modelo se mostrou eficiente para antecipar pequenas variações no fluxo de veículos, refletindo um bom ajuste às condições momentâneas da via.

Por outro lado, ao considerar previsões de 120 minutos, os valores de MAE (Erro Médio Absoluto) e RMSE (Raiz do Erro Quadrático Médio) aumentaram expressivamente. Isso indica que, conforme o horizonte de previsão se expande, o modelo enfrenta maiores dificuldades para capturar as variações no fluxo de tráfego. Essa deterioração da precisão pode ser explicada pelo aumento da influência de fatores externos e imprevisíveis, como mudanças abruptas no comportamento dos condutores, ocorrência de congestionamentos inesperados, variações climáticas ou eventos sazonais. Assim, para previsões de longo /prazo, a confiabilidade do modelo diminui, evidenciando a necessidade de estabelecer novos critérios no modelo ou a inserção de novas variáveis para melhorar o desempenho em períodos mais extensos.

Quando a análise é segmentada por tipo de dia, os resultados mostram que, para previsões de curto prazo (15 minutos), os erros foram ligeiramente menores durante os dias de semana. Esse comportamento sugere que os padrões de tráfego nos dias úteis são mais regulares, seguindo rotinas diárias previsíveis, como deslocamentos para o trabalho e para a escola. Essa regularidade facilita a captura dos padrões pelo modelo, permitindo um ajuste mais preciso às tendências do tráfego nesses dias. Além disso, a estrutura do tráfego nos dias de semana tende a ser mais estável, com uma distribuição de fluxos mais homogênea ao longo do tempo.

No entanto, para horizontes mais longos (120 minutos), os erros aumentaram de maneira semelhante tanto para dias de semana quanto para finais de semana. Esse padrão indica que, independentemente do tipo de dia, o modelo enfrenta maior incerteza para previsões de longo prazo. Isso ocorre porque, à medida que o horizonte de previsão se amplia, os fluxos de tráfego

tornam-se menos previsíveis, sendo mais suscetíveis a flutuações inesperadas. Nos finais de semana, essa imprevisibilidade pode ser causada por padrões de deslocamento mais variados e “menos estruturados”, enquanto nos dias úteis, eventos como acidentes ou mudanças nas condições viárias podem impactar significativamente a precisão das previsões.

6.3.3. Discussão

Quando se compara o modelo proposto nesta dissertação com outros modelos desenvolvidos por diferentes autores no Brasil, percebe-se que os resultados obtidos seguem um padrão semelhante aos encontrados na literatura.

Barros (2022) propôs um estudo semelhante ao desta dissertação, utilizando uma matriz espacial como entrada para seu modelo preditivo. De maneira análoga, ele estruturou tanto a série temporal quanto a matriz de adjacência (embora estática) para seu modelo baseado em STARIMA. Entre seus achados, destacam-se os seguintes resultados:

Matriz	Via Expressa											Via Arterial						
	10531	10500	10482	10433	10475	10528	10554	10637	10667	10632	10622	10563	10509	10556	10591	10594	10679	10748
Rede 1-1/L AG	27,9	44,2	106,0	67,0	26,4	40,1	17,8	34,5	26,6	22,1	8,3	33,0	16,3	24,4	52,7	32,9	18,7	17,7
Rede 1-1/T AG	27,4	42,8	106,7	69,4	26,1	39,1	16,8	33,6	26,0	22,8	7,6	31,0	16,2	24,7	52,9	33,1	19,0	17,9
Rede 1-1/V AG	26,7	40,5	106,1	64,2	26,8	40,7	19,3	34,8	28,9	24,7	14,0	34,6	16,3	24,5	52,4	32,3	18,2	18,2
Rede 1/D AG	27,7	43,2	105,6	67,8	27,1	46,5	24,0	38,0	31,9	24,6	13,3	34,5	17,6	32,5	51,7	32,4	18,8	18,0
Rede 1/L AG	29,4	47,6	103,9	66,6	29,7	44,0	18,5	35,4	29,7	23,1	10,6	34,3	16,2	25,1	52,8	33,2	18,8	17,4
Rede 1/T AG	26,9	41,6	102,9	67,2	28,4	38,3	17,6	33,8	27,4	21,6	7,9	33,4	16,0	25,9	53,2	34,3	18,4	17,8
Rede 1/V AG	27,4	43,5	106,6	68,7	26,3	41,8	21,4	39,0	31,6	24,5	11,1	33,3	17,8	26,2	52,5	32,2	20,5	21,0
Rede 1-1/T VC	28,5	49,3	102,1	66,4	31,0	40,4	16,9	33,5	26,6	22,6	7,6	32,6	16,9	25,7	52,9	33,3	18,6	18,0
Rede 1-1/T LP	28,3	42,5	102,1	66,2	33,0	42,9	16,4	33,3	26,5	22,4	7,6	32,4	16,0	25,5	52,6	33,2	18,8	17,9
Rede 1-1/V VC	26,6	41,5	104,8	61,9	27,1	42,1	18,1	33,8	31,5	21,8	8,1	37,7	16,9	25,2	52,5	34,1	19,1	17,4
Rede 1-1/V LP	26,8	40,7	103,8	62,7	26,5	42,1	19,5	32,8	26,6	21,2	14,7	36,6	16,2	25,1	52,2	32,9	18,9	17,6

Figura 6.14 Dados de RMSE para 60 minutos usando STARIMA

Fonte: Barros (2022).

Observa-se que os valores variam de acordo com o sensor, dependendo do fluxo de tráfego e da estrutura da matriz de adjacência. Ao comparar os resultados, verifica-se que os valores entre os dois estudos são extremamente semelhantes, sem que seja possível afirmar que um modelo supera o outro de maneira significativa.

As redes descritas por Barros (2022) incluem os diferentes pesos atribuídos à matriz de adjacência. Isso indica que, dependendo da parametrização da matriz, considerando fatores como tempo de

percurso e volume de tráfego, o desempenho pode ser otimizado para determinados sensores, mas, ao mesmo tempo, apresentar perdas em outros. Dessa forma, pode-se afirmar que os modelos atingiram desempenhos comparáveis em termos de eficiência, quando analisada exclusivamente essa métrica.

Ao se avaliar o erro absoluto médio (MAE) para toda a rede, o estudo de Barros (2022) encontrou um valor de 15,3, enquanto o presente estudo obteve um MAE de 14,6. Essa diferença não é estatisticamente significativa, reforçando que os modelos possuem desempenhos equivalentes. Entretanto, é relevante destacar que a estrutura empregada nesta dissertação poderia ter sido aprimorada, especialmente no que diz respeito ao número de camadas da rede neural, visando um melhor ajuste do modelo. No entanto, a configuração atual foi mantida com o objetivo de minimizar o risco de *overfitting*, um dos principais desafios em modelos de aprendizado de máquina.

Há espaço para melhorias no modelo, especialmente no que se refere à captação de dados históricos para aprimorar as previsões futuras, bem como ao aumento do número de iterações durante o treinamento. Essas melhorias poderiam contribuir para a redução dos erros, especialmente nos períodos de pico, que representam os maiores desafios para a acurácia do modelo. Esse fator é crucial para aplicações práticas, como a visualização de dados em painéis, ferramentas GIS ou integração com APIs para a gestão do tráfego, garantindo maior precisão nas previsões durante os momentos críticos do fluxo viário. Isso é fundamental para que os órgãos fiscalizadores possam atuar de forma eficaz na implementação de medidas que melhorem a circulação nas vias urbanas.

Ainda que os resultados indiquem que o modelo desenvolvido se equipara a modelos atualmente utilizados, a literatura recente sobre modelagem baseada em Grafos e Redes Neurais Artificiais apresenta avanços promissores. Um estudo publicado em 2023 demonstrou que, ao incorporar relações espaço-temporais do tráfego, houve melhorias significativas na previsão do fluxo viário. Trabalhos no intervalo entre 2017 a 2024 têm reportado valores de MAE entre 4 e 5 e RMSE entre 7 e 11 (LUO *et al.*, 2024; KONG *et al.*, 2024; LI *et al.*, 2017; YU *et al.*, 2017; WU *et al.*, 2017; ZHENG *et al.*, 2020; SUN *et al.*, 2022; SHAO *et al.*, 2022; SUN *et al.*, 2023; OUYANG *et al.*, 2023), sugerindo que abordagens de modelagem com mecanismos que extraíam características das séries temporais conseguem lidar com os desafios da predição de tráfego com maior precisão do

que o modelo utilizado nesta dissertação. A Figura 6.15 apresenta os modelos existentes, utilizando as bases de dados METR-LA, PEMS-BAY, PEMS 04 e PEMS-S08:

		METR-LA			PEMS-BAY			PEMS04			PEMS08		
		15 min	30 min	60 min	15 min	30 min	60 min	15 min	30 min	60 min	15 min	30 min	60 min
DCRNN	RMSE	4.61	5.33	6.25	2.18	2.84	3.58	29.50	31.35	34.20	22.08	23.64	25.99
	MAE	2.49	2.74	3.08	1.10	1.33	1.59	18.51	19.70	21.56	14.30	15.22	16.70
	MAPE	6.19%	7.12%	8.44%	2.21%	2.82%	3.58%	12.60%	13.45%	14.87%	9.31%	9.86%	10.79%
STGCN	RMSE	4.80	5.51	6.34	2.46	2.98	3.57	29.53	30.49	31.86	22.87	23.88	25.32
	MAE	2.59	2.82	3.11	1.32	1.50	1.73	18.70	19.28	20.11	14.80	15.33	16.22
	MAPE	6.61%	7.43%	8.53%	2.77%	3.23%	3.86%	13.06%	13.42%	13.98%	9.81%	10.11%	10.64%
Graph WaveNet	RMSE	4.84	5.54	6.33	2.20	<u>2.83</u>	<u>3.50</u>	<u>27.70</u>	28.60	<u>29.81</u>	<u>20.70</u>	<u>21.76</u>	23.34
	MAE	2.58	2.83	3.14	1.10	1.32	1.57	17.20	17.76	18.56	<u>13.03</u>	<u>13.55</u>	<u>14.34</u>
	MAPE	6.58%	7.58%	8.89%	2.23%	2.82%	<u>3.51%</u>	12.02%	12.49%	13.35%	8.76%	<u>8.98%</u>	<u>9.76%</u>
GMAN	RMSE	4.99	5.51	6.17	2.46	2.99	3.56	28.91	29.66	30.77	22.40	23.23	24.61
	MAE	2.80	3.01	3.31	1.33	1.54	1.78	18.47	18.88	19.59	14.92	15.29	16.11
	MAPE	7.44%	8.21%	9.26%	2.73%	3.26%	3.90%	15.66%	15.78%	16.12%	12.31%	12.52%	13.15%
MTGNN	RMSE	4.55	<u>5.19</u>	<u>6.01</u>	2.21	2.85	3.55	27.97	28.92	30.23	21.05	22.10	23.58
	MAE	2.46	<u>2.69</u>	<u>3.00</u>	1.11	1.34	1.59	17.41	17.97	18.73	13.55	14.08	14.96
	MAPE	6.87%	7.00%	<u>8.14%</u>	2.25%	2.86%	3.58%	12.75%	13.31%	13.81%	10.00%	9.99%	10.56%
DDSTGCN	RMSE	5.01	6.02	7.13	2.71	3.64	4.37	28.38	29.54	30.69	21.14	22.23	24.12
	MAE	2.64	3.00	3.44	1.29	1.60	1.89	17.69	18.51	19.51	13.54	14.02	14.70
	MAPE	6.76%	8.12%	9.74%	2.69%	3.62%	4.46%	12.34%	12.70%	13.46%	8.82%	9.71%	10.41%
STID	RMSE	5.53	6.60	7.54	2.81	3.72	4.40	28.48	29.86	31.79	21.66	23.57	25.89
	MAE	2.80	3.18	3.55	1.30	1.62	1.89	17.51	18.29	19.58	13.28	14.21	15.58
	MAPE	7.70%	9.40%	10.95%	2.73%	3.68%	4.47%	12.00%	12.46%	13.38%	<u>8.62%</u>	9.24%	10.33%
DSTET	RMSE	4.52	5.22	6.08	2.17	2.85	3.60	27.38	28.66	29.77	20.24	21.63	23.53
	MAE	<u>2.46</u>	2.71	3.03	1.06	1.29	<u>1.57</u>	16.90	17.68	18.48	12.25	13.21	14.11
	MAPE	<u>6.05%</u>	<u>6.95%</u>	8.30%	<u>2.13%</u>	<u>2.74%</u>	3.54%	<u>11.59%</u>	<u>12.44%</u>	<u>12.71%</u>	8.03%	8.83%	9.30%
DAGN	RMSE	5.03	6.00	7.49	2.58	3.22	4.21	29.68	32.02	38.87	23.56	25.46	31.97
	MAE	2.67	3.03	3.67	1.28	1.49	1.86	19.13	20.53	23.63	15.16	16.68	20.94
	MAPE	6.85%	8.16%	10.55%	2.75%	3.38%	4.50%	13.85%	14.31%	15.55%	10.87%	11.29%	14.30%
LSTTN (Ours)	RMSE	4.42	5.10	5.92	<u>2.18</u>	2.76	3.41	27.74	28.67	30.00	20.78	21.89	<u>23.47</u>
	MAE	2.42	2.65	2.96	<u>1.06</u>	1.26	1.48	<u>17.06</u>	17.62	18.46	13.17	13.71	14.54
	MAPE	5.94%	6.80%	7.93%	<u>2.11%</u>	2.63%	3.24%	<u>11.34%</u>	11.68%	12.17%	8.63%	9.09%	9.77%

Figura 6.15 Dados de outros modelos GNN
Fonte: Luo (2024).

Todos os valores de MAE e RMSE dos modelos analisados foram inferiores aos obtidos no trabalho atual, o que indica que os melhores apresentam menores erros entre os valores preditos e reais. Isso pode ser atribuído a diversos fatores, sendo o principal a falta de nós no modelo desta dissertação. Um dos principais motivos para a utilização de modelos GNN está precisamente na capacidade de lidar com grandes quantidades de nós e arestas, como ilustrado na Tabela 6.8, que apresenta a quantidade de nós e arestas nas bases de dados dos estudos mencionados:

Tabela 6.8 – Informações dos Bancos de Dados

Dataset	Nodes	Edges	Time interval	Samples
METR-LA	207	1722	5 mins	34272

PEMS-BAY	325	2694	5 mins	52116
PEMS04	307	987	5 mins	16992
PEMS08	170	718	5 mins	17856

A alta quantidade de nós e arestas nos modelos analisados pode corroborar a existência de diferenças significativas entre os estudos atuais e o modelo apresentado nesta dissertação. No entanto, novos modelos, como o de Luo (2024), incorporam mecanismos que extraem padrões de curto e longo prazo, além de capturar a periodicidade dos dados. De acordo com o artigo, essas melhorias têm impactado positivamente as métricas de avaliação do modelo.

Isso abre novas possibilidades para aprimorar a arquitetura da rede, como o aumento do número de camadas e a inclusão de novos componentes e mecanismos, com o objetivo de otimizar o desempenho preditivo. Embora comparações diretas entre os modelos não sejam viáveis devido às diferenças nos conjuntos de dados utilizados em cada estudo, é relevante destacar que as estruturas e os objetivos dos modelos analisados são semelhantes, justificando a comparação realizada.

6.3.3.1. Breve Descrição sobre as variáveis da infraestrutura viária existente e parâmetros de tráfego

A literatura em previsão de tráfego de curto prazo evidencia que à medida que o fluxo veicular cresce, os modelos de previsão tendem a apresentar maior erro, o que foi observado nos resultados deste estudo. Em um estudo recente, Żochowska e Pamuła (2024) analisaram dados de matriz origem-destino obtidos por vídeo-sensores e identificaram que, embora o erro percentual médio (MAPE) diminua com o aumento do volume médio, a variabilidade do tráfego amplifica significativamente o erro de previsão.

Da mesma forma, Żochowska e Pamuła (2024), em um estudo focado no tráfego urbano, demonstraram que zonas de tráfego sobrecarregadas, caracterizadas por carga dinâmica intensa, apresentaram erros de previsão significativamente mais elevados, especialmente quando os níveis de fluxo ultrapassavam determinados limiares, com o erro sendo avaliado por meio da métrica MAPE. Esses achados corroboram diretamente a observação empírica de que, nos trechos das

rodovias DF-025 e DF-035, o aumento do fluxo veicular está associado a maior discrepância entre os valores previstos e os valores reais, evidenciando a complexidade da previsão em contextos de alta demanda.

A literatura também mostra que a estrutura física e operacional das vias exerce influência significativa nos resultados de previsão de tráfego. Por exemplo, estudos como o de Eom & Kim (2020) destacam que o controle semaforico em interseções é um elemento estocástico complexo, cujos ciclos variáveis impactam diretamente a capacidade, os tempos de espera e o comportamento do fluxo em canais adjacentes (LIU *et al.*, 2021). Sistemas adaptativos demonstram ganhos de 15 a 40% em desempenho operacional ao ajustar os tempos de sinal em resposta ao tráfego real. Ao não incorporar essas características da infraestrutura de transportes em modelos de previsão, o erro de estimativa aumenta substancialmente, reduzindo a confiança nos *outputs* do modelo, o que aconteceu exatamente no estudo, visto que a captação de alguns sensores acontece em intersecção semaforizada.

Além disso, cruzamentos semaforizados com alta demanda pedonal, evidenciam que o comportamento espacial e temporal dos pedestres influenciados por sensores, botões e pausas inesperadas que afeta o perfil de tráfego veicular e introduz ruído nos dados, com impacto direto na acurácia preditiva (LIU *et al.*, 2021).

Por fim, pesquisas recentes em modelagem de tráfego usando GNNs espaciais, como STGCN e DGCRAN, demonstram que representar explicitamente a topologia da rede, com seus sinais, sentidos e acessos, gera melhorias de 10 a 20% nas métricas MAE e RMSE, quando comparado a modelos que descrevem apenas sequência temporal (LI *et al.*, 2021; YU *et al.*, 2018). Portanto, há possibilidade de inserir mais informações da infraestrutura de tráfego existente afim de melhorar os resultados de predição e, assim, diminuir os erros dos valores preditos e reais.

7. CONCLUSÃO

O presente estudo teve como objetivo principal o desenvolvimento e a aplicação de um modelo preditivo para a previsão de volume de tráfego de curto prazo em trechos das vias DF-025 e DF-035, no Distrito Federal. Para isso, foi proposto um modelo baseado em *Graph-CNN-LSTM*, visando captar de maneira eficiente as interdependências espaciais e temporais do tráfego. A previsão foi realizada em horizontes temporais de 15 a 120 minutos, permitindo uma análise da dinâmica viária na região estudada.

Os resultados obtidos demonstraram que o modelo proposto apresentou uma boa capacidade de previsão, com erros relativamente baixos para curtos intervalos de tempo, especialmente em previsões de até 75 minutos. Por exemplo, no curto prazo (15 a 60 minutos), o Erro Médio Absoluto (MAE) variou entre 10,8 e 32,4, e a Raiz do Erro Quadrático Médio (RMSE) permaneceu abaixo de 50 para a maioria das vias, indicando um desempenho confiável. No entanto, à medida que o horizonte de previsão aumentou, observou-se um crescimento significativo no erro médio, com o MAE ultrapassando 46,4 e o RMSE alcançando 66,6 em 120 minutos para algumas vias, como CVS240 e CVS239, o que está alinhado com a literatura vigente. Esse fenômeno evidencia a complexidade do tráfego urbano e a influência de fatores externos inesperados, como acidentes, condições climáticas e eventos atípicos.

Outro aspecto relevante foi a distinção no comportamento do tráfego entre dias úteis e finais de semana. Durante os dias úteis, os picos de tráfego foram mais acentuados e previsíveis, facilitando a modelagem dos padrões de fluxo, como demonstrado por erros ligeiramente menores em previsões de curto prazo (por exemplo, MAE de 11,7 para CVS750 em 15 minutos nos dias úteis contra 10,3 nos finais de semana). Já nos finais de semana, o tráfego apresentou uma distribuição mais dispersa e menos estruturada, refletindo diferenças nas demandas de mobilidade urbana, com erros aumentando de forma semelhante em ambos os tipos de dias para horizontes mais longos (por exemplo, MAE de 52,2 para CVS240 nos dias úteis e 45,6 nos finais de semana em 120 minutos).

Destaca-se que vias com maiores volumes de tráfego, como CVS240 e CVS239, que registraram 600-700 veículos equivalentes durante os horários de pico (7h-9h e 16h-19h), apresentaram os

maiores erros de previsão, com o Erro Quadrático Médio (MSE) superando 4000 em 120 minutos. Em contraste, vias como CVS750 e FCL019, com fluxos menores de 300-400 veículos, mostraram previsões mais estáveis, com valores menores de MAE e RMSE. Isso reforça que os horários de pico representam desafios significativos devido às rápidas variações no tráfego, em linha com achados de Cogoni *et al.* (2022) e Nagel e Rasmussen (1995).

7.1. LIMITAÇÕES DO ESTUDO

A modelagem preditiva utilizada neste estudo apresenta algumas limitações que podem impactar a precisão das previsões e a interpretação dos resultados.

Em primeiro lugar, a modelagem considerou exclusivamente os parâmetros de extensão da via, ponto inicial e ponto final, sem incluir informações sobre vias locais que podem influenciar significativamente o tráfego. Esse fator pode resultar em uma subestimação da influência de acessos e rotas alternativas à vias locais, que frequentemente redistribuem o fluxo de veículos e alteram padrões de congestionamento.

Além disso, a ausência de elementos geométricos, como curvas, declividades e interseções complexas, pode comprometer a fidelidade da representação da malha viária. No mundo real, curvas acentuadas e aclives/declives afetam diretamente a velocidade média dos veículos, e sua exclusão pode levar a diferenças entre as previsões do modelo e as condições observadas. A simplificação das vias como segmentos lineares em um grafo ignora esses fatores, o que pode introduzir erros na estimativa dos tempos de viagem.

Outro aspecto importante é a falta de elementos operacionais, como semáforos, faixas de pedestres e pontos de parada de transporte público. Esses fatores impactam diretamente a fluidez do tráfego, podendo gerar retenções pontuais não capturadas pelo modelo. Como resultado, em áreas urbanas com alto número de interseções semaforizadas, o modelo pode apresentar desvios em relação aos valores reais de tempo de deslocamento.

Além disso, a modelagem em grafos não leva em consideração variações sazonais e eventos inesperados, como obras, acidentes e condições climáticas adversas. Esses eventos têm o potencial

de modificar drasticamente a dinâmica do tráfego, e a ausência de mecanismos que incorporem tais variações pode reduzir a capacidade do modelo de generalizar previsões para diferentes cenários. Embora a abordagem em grafos tenha sido utilizada para capturar relações estruturais entre os segmentos viários, sua simplificação pode limitar a capacidade do modelo de diferenciar padrões locais de tráfego e identificar pontos críticos de congestionamento. Ainda assim, a estrutura do grafo permite a integração de informações de fluxo viário ao longo do tempo, possibilitando a análise de tendências e variações temporais do tráfego.

Por fim, a inclusão da variável peso dos veículos nas conexões do grafo oferece um mecanismo para que o modelo aprenda padrões de tráfego ao longo do tempo. No entanto, a ausência de dados detalhados sobre a distribuição de diferentes tipos de veículos pode restringir a precisão das estimativas, especialmente em cenários onde a presença de veículos pesados tem um impacto significativo na capacidade viária.

Dessa forma, futuras melhorias podem incluir a incorporação de fatores operacionais e geométricos, bem como a consideração de eventos externos, para aprimorar a representatividade da modelagem e a confiabilidade das previsões.

7.2. ESTUDOS FUTUROS

Para o avanço de estudos futuros, é essencial aprimorar as previsões para horizontes temporais superiores a 75 minutos, uma vez que os erros se mostraram mais expressivos nesses intervalos. Uma abordagem promissora envolve a incorporação de variáveis exógenas, como condições meteorológicas, eventos locais e incidentes viários, fatores que exercem influência direta sobre o fluxo de tráfego. Além disso, sugere-se a realização de ajustes nos hiperparâmetros da *rede Graph-CNN-LSTM*, incluindo a taxa de aprendizado, a profundidade da rede e o tamanho dos filtros convolucionais, com o objetivo de otimizar o desempenho do modelo e reduzir a variabilidade das previsões em diferentes cenários.

No contexto da implementação de um sistema preditivo para a malha viária do Distrito Federal, um dos desafios centrais reside na qualidade e na integração dos dados de contagem de tráfego. Atualmente, a coleta dessas informações é realizada por três órgãos distintos, tornando necessária

a harmonização e a compatibilização das bases de dados para a construção de uma malha viária unificada e abrangente. Essa integração é importante para que o modelo contemple o maior número possível de vias, possibilitando uma análise espaço-temporal mais robusta e representativa da dinâmica viária na região.

Caso a consolidação dessas bases de dados não seja viável, outras metodologias podem ser exploradas para a previsão do tráfego sem a necessidade de sensores físicos. Estudos como o de Yao *et al.* (2015) demonstram a viabilidade do uso de dados provenientes de redes de telefonia móvel e imagens de satélite para a estimativa do volume de tráfego. No entanto, esses métodos apresentaram erros mais elevados em comparação aos modelos baseados em sensores físicos, o que sugere a necessidade de investigações adicionais para melhorar sua precisão e aplicabilidade.

Para que o modelo desenvolvido possa ser utilizado como uma ferramenta prática na gestão urbana, torna-se imprescindível a implementação de um mecanismo de atualização em tempo real. Isso permitiria que os dados captados pelos sensores fossem processados instantaneamente, gerando previsões contínuas e adaptáveis às condições viárias dinâmicas. Uma solução viável seria o desenvolvimento de uma API para conectar os dados em tempo real ao modelo preditivo, viabilizando atualizações automáticas e respostas ágeis às variações do tráfego. Com essa integração, o sistema poderia não apenas prever o volume de tráfego nos próximos 15, 30 ou 120 minutos, mas também mapear probabilidades de diferentes cenários, exibindo essas informações em um painel interativo. Representações visuais, como mapas de calor, poderiam ser utilizadas para indicar a probabilidade de ocorrência de diferentes padrões de tráfego.

Embora o modelo proposto tenha demonstrado boa precisão sob condições normais de tráfego, sua capacidade de antecipar eventos atípicos, como acidentes e bloqueios inesperados, ainda é limitada. Dessa forma, a integração com dados em tempo real, aliada a um sistema interativo de visualização, é essencial para aprimorar sua aplicabilidade prática. Um painel dinâmico poderia ser desenvolvido para combinar dados observados e projetados, fornecendo suporte a gestores de tráfego na tomada de decisões estratégicas, como ajustes na temporização de semáforos e redirecionamento de fluxos viários em tempo real.

Para pesquisas futuras, recomenda-se o aperfeiçoamento da modelagem das interdependências entre vias no contexto de redes neurais baseadas em grafos. A principal limitação observada neste estudo foi a consideração exclusiva de conexões diretas na matriz de adjacência, desconsiderando os efeitos indiretos que variações no tráfego de uma via podem exercer sobre vias adjacentes ou interseccionadas. Um avanço significativo consistiria na incorporação de mecanismos capazes de capturar essas interações indiretas, como a atribuição de pesos dinâmicos à matriz de adjacência com base na correlação temporal histórica entre os segmentos viários, ou ainda, a adoção de redes convolucionais em grafos (GCNs) com múltiplas camadas, permitindo a propagação da informação de tráfego para além das conexões de primeiro grau.

Além disso, a inclusão de variáveis representativas do número de acessos e da perda de fluxo em vias locais como entradas adicionais no modelo pode contribuir para o refinamento da acurácia preditiva. Tais aprimoramentos visam proporcionar uma representação mais fiel da dinâmica de propagação do tráfego urbano, resultando em previsões mais robustas e alinhadas com a complexidade dos sistemas viários reais

Experiências documentadas na literatura e aplicações internacionais demonstram que sistemas que combinam previsão de tráfego com dados em tempo real podem tornar a gestão viária significativamente mais eficiente. Esses modelos permitem a antecipação de congestionamentos e a implementação de estratégias proativas para mitigar impactos negativos sobre a mobilidade urbana. No caso do Distrito Federal, a adoção dessas tecnologias poderia transformar o modelo proposto em uma ferramenta estratégica para otimizar a fluidez do trânsito, contribuindo para um sistema de transporte mais inteligente, adaptativo e sustentável.

Diante disso, a pesquisa reforça a relevância da previsão de tráfego de curto prazo para o planejamento urbano e a gestão de transportes, mostrando que abordagens baseadas em aprendizado profundo e teorias de grafos são ferramentas viáveis para lidar com a dinamicidade do trânsito urbano. Deve-se atentar que o trabalho de previsão tem múltiplas vertentes, e este estudo oferece uma base para explorações futuras.

Por fim, a pesquisa contribui para o aprimoramento das metodologias de previsão de tráfego no Brasil, oferecendo um modelo robusto que pode ser adaptado para diferentes cenários urbanos, fortalecendo a mobilidade urbana e promovendo soluções mais sustentáveis e eficientes para o trânsito nas cidades.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABDELGAWAD, K., HENNING, S., BIEMELT, P., GAUSEMEIER, S., & TRÄCHTLER, A. (2016). Advanced traffic simulation framework for networked driving simulators. *IFAC-PapersOnLine*, 49(11), 101-108.
- AGRAWAL, R., IMIELIŃSKI, T., & SWAMI, A. (1993). Mining association rules between sets of items in large databases. In *Proceedings of the 1993 ACM SIGMOD international conference on Management of data* (pp. 207-216).
- AGRAWAL, R. S., & SRIKANT, R. (1994). R. Fast algorithms for mining association rules. In *Proceedings of the 20th international conference on very large data bases, vldb* (pp. 487-499).
- AHMED, M., MAHMOOD, A. N., & ISLAM, M. R. (2016). A survey of anomaly detection techniques in financial domain. *Future Generation Computer Systems*, 55, 278-288.
- ALGHAMDI, T., ELGAZZAR, K., BAYOUMI, M., SHARAF, T., & SHAH, S. (2019). Forecasting traffic congestion using ARIMA modeling. In *2019 15th international wireless communications & mobile computing conference (IWCMC)* (pp. 1227-1232). IEEE.
- AMARAL, M. B. D. (2020). Previsão de velocidades de tráfego com rede neural LSTM. Departamento de Engenharia. Universidade Federal do Rio Grande do Sul, Porto Alegre.
- AMIRI, P. A. D., & PIERRE, S. (2023). A Soft Voting Classification Model for Network Traffic Prediction in VANET/V2X. In *2023 19th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)* (pp. 231-236). IEEE.
- AREM, B.; KIM, D.; PARK, S. (1997) Gerenciamento de volume de tráfego em áreas urbanas. *Transportation Research Part A: Policy and Practice*, v. 31, n. 3, p. 215–230.
- ATWOOD, J., & TOWSLEY, D. (2016). Diffusion-convolutional neural networks. *Advances in neural information processing systems*, v. 29, p. 1-10.
- BAER, W. (2001). *The Brazilian economy: Growth and development*. Bloomsbury Publishing USA.
- BARROS, O. M. D. (2022). Estimaco das caractersticas de tráfego em tempo prximo ao real para uso em sistemas de previso e controle de tráfego. Tese de Doutorado em Engenharia de Transportes. Universidade de So Paulo, So Carlos, SP.
- BAYLISS, C., & OUELHADJ, D. (2024). Mobility as a Service: An exploration of exact and heuristic algorithms for a new multi-modal multi-objective journey planning problem. *Applied Soft Computing*, 162, 111871.

- BIER, A. A., & FERRAZ, S. E. T. (2017). Comparação de metodologias de preenchimento de falhas em dados meteorológicos para estações no sul do Brasil. *Revista Brasileira de Meteorologia*, 32, 215-226.
- BISHOP, C. M., & NASRABADI, N. M. (2006). Pattern recognition and machine learning (Vol. 4, No. 4, p. 738). New York: springer.
- BOGAERTS, T., MASEGOSA, A. D., ANGARITA-ZAPATA, J. S., ONIEVA, E., & HELLINCKX, P. (2020). A graph CNN-LSTM neural network for short and long-term traffic forecasting based on trajectory data. *Transportation Research Part C: Emerging Technologies*, 112, 62-77.
- BOUKERCHE, A., & WANG, J. (2020). Machine learning-based traffic prediction models for intelligent transportation systems. *Computer Networks*, 181, 107530.
- BRASIL (2014) Departamento Nacional de Trânsito – DENATRAN. Manual Brasileiro de Sinalização de Trânsito: *Volume V – Sinalização Semafórica*. Ministério das Cidades. Brasília.
- BREIMAN, L., FRIEDMAN, J., OLSHEN, R. A., & STONE, C. J. (2017). Classification and regression trees. Routledge.
- BRÍGIDA, S. G. F. (2018). *Caracterização e Previsão do Tráfego Rodoviário*. Dissertação de Mestrado, Universidade NOVA de Lisboa, Portugal.
- BRUNA, J., ZAREMBA, W., SZLAM, A., & LECUN, Y. (2013). Spectral networks and locally connected networks on graphs. *arXiv preprint arXiv:1312.6203*.
- BUENO, E. (2003). Brasil: uma história. 2ª edição. São Paulo. Ática, 19.
- CABELLO-SOLORZANO, K., ORTIGOSA DE ARAUJO, I., PEÑA, M., CORREIA, L., & J. TALLÓN-BALLESTEROS, A. (2023). The impact of data normalization on the accuracy of machine learning algorithms: a comparative analysis. In *International conference on soft computing models in industrial and environmental applications* (pp. 344-353). Cham: Springer Nature Switzerland.
- CAI, J., ZHANG, X., LIN, Q., DONG, L., CHEN, W., & MING, Z. (2024). Deep Reinforcement Learning for Solving the Vehicle Routing Problem in Practical Logistics. In *2024 IEEE Congress on Evolutionary Computation (CEC)* (pp. 1-8). IEEE.
- CAI, P., WANG, Y., LU, G., CHEN, P., DING, C., & SUN, J. (2016). A spatiotemporal correlative k-nearest neighbor model for short-term traffic multistep forecasting. *Transportation Research Part C: Emerging Technologies*, 62, 21-34.
- CHAN, K. Y., ABU-SALIH, B., QADDOURA, R., AL-ZOUBI, A. M., PALADE, V., PHAM, D. S., ... & MUHAMMAD, K. (2023). Deep neural networks in the cloud: Review, applications, challenges and research directions. *Neurocomputing*, 545, 126327.

- CHEN, C., HU, J., MENG, Q., & ZHANG, Y. (2011). Short-time traffic flow prediction with ARIMA-GARCH model. In *2011 IEEE Intelligent Vehicles Symposium (IV)* (pp. 607-612). IEEE.
- CHIABAUT, N., & FAITOUT, R. (2021). Traffic congestion and travel time prediction based on historical congestion maps and identification of consensual days. *Transportation Research Part C: Emerging Technologies*, *124*, 102920.
- CHUNG, J., GULCEHRE, C., CHO, K., & BENGIO, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*.
- COCHRAN, W. G.; COX, G. M. (1995) *Experimental Designs*. 2. ed. Wiley, New York, USA.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine Learning*, v. 20, n. 3, p. 273-297, 1995.
- COUTINHO, L.; FERRAZ, J. C. (2013). Desenvolvimento, crise e padrões de crescimento industrial: A experiência recente brasileira. Universidade de Campinas, Campinas, SP.
- COVER, T., & HART, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, *13*(1), 21-27.
- DIA, HUSSEIN. An object-oriented neural network approach to short-term traffic forecasting. *European Journal of Operational Research*, v. 131, n. 2, p. 253-261, 2001.
- DOMINGOS, P. (2015). *The master algorithm: How the quest for the ultimate learning machine will remake our world*. Basic Books.
- EMO, A. K., MATTHEWS, G., & FUNKE, G. J. (2016). The slow and the furious: Anger, stress and risky passing in simulated traffic congestion. *Transportation research part F: traffic psychology and behaviour*, *42*, 1-14.
- EOM, J. & KIM, J. (2020) Signal control variability and its effects on urban intersection performance. *Sustainability*, v. 12, p. 1–15.
- ENAMOTO, L. M. (2023). *GeMGF – Generic Multimodal Gradient-Based Meta Framework*. Tese de Doutorado em Ciência da Computação. Departamento de Ciência da Computação, Universidade de Brasília, Brasília, DF, 103 p.
- FÁBIO, J. R. (2022) Fluxo em tempo real (veh/5min) e tempo semafórico (s): Previsão para acoplamento em semáforos. Dissertação de Mestrado, Universidade de Brasília, Brasília, DF.
- FANG, S., JI, W., XIANG, S., & HUA, W. (2024). PreSTNet: Pre-trained spatio-temporal network for traffic forecasting. *Information Fusion*, *106*, 102241.
- FILHO, M. S. F. (2020) O uso da tecnologia no trânsito no interior da Bahia. *Revista Brasileira de Engenharia de Transportes*, v. 10, n. 3, p. 159–181.

- GÉRON, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. " O'Reilly Media, Inc."
- GHOLAMALINEZHAD, H. & KHOSRAVI, H. (2020) Pooling Methods in Deep Neural Networks, a Review. *arXiv preprint arXiv:2009.07485*.
- GONÇALVES, J. M. *Infraestrutura, crescimento e desenvolvimento: Reflexões sobre o Brasil*. Brasília: Ipea, 2016.
- GOODFELLOW, I., BENGIO, Y., COURVILLE, A., & BENGIO, Y. (2016). *Deep learning* (Vol. 1, No. 2). Cambridge: MIT press.
- GUO, J.; LI, Y.; ZHANG, X.; LI, Z.; LIU, Z. (2023) Road traffic flow prediction based on dynamic spatiotemporal graph attention network. *Scientific Reports*, v. 13, art. 14729.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2. ed. New York: Springer, 2009.
- HAYKIN, S. (2009). *Neural networks and learning machines, 3/E*. Pearson Education India.
- HINSBERGEN, E. V.; VAN LINT, J. W. C.; VAN ZUYLEN, H. J. (2007) Urban traffic state estimation & prediction. *Transportation Research Part C: Emerging Technologies*, v. 15, n. 5, p. 347–365.
- HUO, G., ZHANG, Y., WANG, B., GAO, J., HU, Y., & YIN, B. (2023). Hierarchical spatio-temporal graph convolutional networks and transformer network for traffic flow forecasting. *IEEE Transactions on Intelligent Transportation Systems*, 24(4), 3855-3867.
- HCM. (2000) Highway Capacity Manual. *Transportation Research Board*, Washington, DC, USA.
- HCM. (2010) Highway Capacity Manual. *Transportation Research Board*, Washington, DC, USA.
- HOBEIKA, A. G., & KIM, C. K. (1994). Traffic-flow-prediction systems based on upstream traffic. In *Proceedings of VNIS'94-1994 Vehicle Navigation and Information Systems Conference* (pp. 345-350). IEEE.
- HOCHREITER, S., & SCHMIDHUBER, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- HUANG, L., LIU, X. X., HUANG, S. Q., WANG, C. D., TU, W., XIE, J. M., ... & XIE, W. (2021). Temporal hierarchical graph attention network for traffic prediction. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 12(6), 1-21.
- JAVAID, M., HALEEM, A., SINGH, R. P., & SUMAN, R. (2022). Artificial intelligence applications for industry 4.0: A literature-based study. *Journal of Industrial Integration and Management*, 7(01), 83-111.

- JIA, X.; LI, Y.; ZHANG, X.; LIU, Y. (2025) Traffic incident duration prediction using machine learning algorithms. *Transportation Research Part C: Emerging Technologies*, v. 136, p. 103–118.
- JIANG, R.; YIN, D.; WANG, Z.; WANG, Y.; DENG, J.; LIU, H.; CAI, Z.; DENG, J.; SONG, X.; SHIBASAKI, R. (2021) DL-Traff: Survey and Benchmark of Deep Learning Models for Urban Traffic Prediction. *arXiv preprint arXiv:2108.03594*
- JIANG, J.; WANG, Y.; ZHANG, Y.; LI, Y.; LIU, Z. (2017) An introduction to spectral graph theory. *arXiv preprint arXiv:1705.00499*.
- JIANG, W., HAN, H., HE, M., & GU, W. (2023). Machine Learning-based Multi-Class Traffic Management for Smart Grid Communication Network. In *Adjunct Proceedings of the 2023 ACM International Joint Conference on Pervasive and Ubiquitous Computing & the 2023 ACM International Symposium on Wearable Computing* (pp. 694-699).
- JOLLIFFE, I. T. (2002). *Principal component analysis for special types of data*. Springer New York.
- JOHNSON, S. C. (1967) Hierarchical clustering schemes. In: *Proceedings of the 3rd Symposium on Mathematical Statistics and Probability*, Berkeley, USA, p. 1–30.
- JUNIOR, G. D., FROZZA, R., & MOLZ, R. F. (2015). Simulação de controle adaptativo de tráfego urbano por meio de sistema multiagentes e com base em dados reais. *Revista Brasileira de Computação Aplicada*, 7(3), 65-81.
- KASHYAP, A. A., RAVIRAJ, S., DEVARAKONDA, A., NAYAK K, S. R., KV, S., & BHAT, S. J. (2022). Traffic flow prediction models—A review of deep learning techniques. *Cogent Engineering*, 9(1), 2010510.
- KAUFMAN, L., & ROUSSEEUW, P. J. (2009). *Finding groups in data: an introduction to cluster analysis*. John Wiley & Sons.
- KIM, Y.; LEE, S.; PARK, J.; KIM, H.; LEE, K. (2024) Parametric models for traffic prediction: Challenges and solutions. *Transportation Research Part C: Emerging Technologies*, v. 136, p. 103–118.
- KIM, Y., TAK, H. Y., KIM, S., & YEO, H. (2024). A hybrid approach of traffic simulation and machine learning techniques for enhancing real-time traffic prediction. *Transportation research part C: emerging technologies*, 160, 104490.
- KIPP, M. (2022). Analysis of the influence of non-driving-related activities on seat parameters and sitting postures. In *Proceedings of the 7th International Digital Human Modeling Symposium* (Vol. 7, No. 1). University of Iowa.
- KOHONEN, T. (1990). The self-organizing map. *Proceedings of the IEEE*, 78(9), 1464-1480.

- KONG, L., YANG, H., LI, W., GUAN, J., & ZHOU, S. (2024). Traffexplainer: A framework towards GNN-based interpretable traffic prediction. *IEEE Transactions on Artificial Intelligence*.
- LAÑA, I., CAPECCI, E., DEL SER, J., LOBO, J. L., & KASABOV, N. (2018). Road traffic forecasting using neucube and dynamic evolving spiking neural networks. In *Intelligent Distributed Computing XII* (pp. 192-203). Springer International Publishing.
- LEDUC, G. (2008) Road Traffic Data: Collection Methods and Applications. *Working Papers on Energy, Transport and Climate Change*, N. 1, Joint Research Centre, Sevilha, Espanha.
- LEVINSON, J. & et al. (2021) Autonomous vehicle perception: Advances in LiDAR and computer vision. *Annual Review of Control, Robotics, and Autonomous Systems*, v. 1, p. 1-23.
- LI, D., & LASENBY, J. (2021). Spatiotemporal attention-based graph convolution network for segment-level traffic prediction. *IEEE Transactions on Intelligent Transportation Systems*, 23(7), 8337-8345.
- LI, F.; FENG, J.; YAN, H.; JIN, G.; JIN, D. & LI, Y. (2021) Dynamic Graph Convolutional Recurrent Network for Traffic Prediction: Benchmark and Solution. *arXiv preprint arXiv:2104.14917*
- LI, G., & TIAN, Z. (2024). A new method of network traffic prediction based on combination model. *Peer-to-Peer Networking and Applications*, 17(3), 1075-1090.
- LI, M., & ZHU, Z. (2021). Spatial-temporal fusion graph neural networks for traffic flow forecasting. In *Proceedings of the AAAI conference on artificial intelligence* (Vol. 35, No. 5, pp. 4189-4196).
- LI, W., LIU, X., TAO, W., ZHANG, L., ZOU, J., PAN, Y., & PAN, Z. (2024). Location and time embedded feature representation for spatiotemporal traffic prediction. *Expert Systems with Applications*, 239, 122449.
- LI, X.; ZHANG, L.; CHEN, C. & GOU, J. (2021) A hierarchical traffic flow forecasting network by merging long-term temporal transformer and spatio-temporal graph convolutional networks. In: *Proceedings of the 29th ACM International Conference on Multimedia*, p. 3488–3496.
- LI, Y., YU, R., SHAHABI, C., & LIU, Y. (2017). Diffusion convolutional recurrent neural network: Data-driven traffic forecasting. *arXiv preprint arXiv:1707.01926*.
- LIAL, G. L. Controlo de tráfego. (2011). Tese de Doutorado. Instituto Superior de Engenharia de Lisboa, Lisboa, Portugal.
- LIU, J., WU, N., QIAO, Y., & LI, Z. (2021). A scientometric review of research on traffic forecasting in transportation. *IET Intelligent Transport Systems*, 15(1), 1-16.

- LIU, Y., WENG, X., WAN, J., YUE, X., SONG, H., & VASILAKOS, A. V. (2017). Exploring data validity in transportation systems for smart cities. *IEEE Communications Magazine*, 55(5), 26-33.
- LUO, D., CHENG, W., XU, D., YU, W., ZONG, B., CHEN, H., & ZHANG, X. (2020). Parameterized explainer for graph neural network. *Advances in neural information processing systems*, 33, 19620-19631.
- LUO, Q., HE, S., HAN, X., WANG, Y., & LI, H. (2024). LSTTN: A long-short term transformer-based spatiotemporal neural network for traffic flow forecasting. *Knowledge-Based Systems*, 293, 111637.
- LUO, Q.; HE, S.; HAN, X.; WANG, Y.; LI, H. (2024) Advancements of Graph Neural Networks in Urban Traffic Prediction. In: *Proceedings of the 1st International Conference on Engineering Management, Information Technology and Intelligence (EMITI 2024)*, p. 62–66
- LV, T., WU, Y., & ZHANG, L. (2021). A traffic interval prediction method based on ARIMA. In *Journal of Physics: Conference Series* (Vol. 1880, No. 1, p. 012031). IOP Publishing.
- MACQUEEN, J. B. (1967) Some methods for classification and analysis of multivariate observations. In: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, Berkeley, USA, v. 1, p. 281–297.
- MA, X., DAI, Z., HE, Z., MA, J., WANG, Y., & WANG, Y. (2017). Learning traffic as images: A deep convolutional neural network for large-scale transportation network speed prediction. *sensors*, 17(4), 818.
- MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, v. 1, n. 14, p. 281-297, 1967.
- MCCULLOCH, W. S., & PITTS, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5, 115-133.
- MCCULLOCH, W. S., & PITTS, W. (1990). A logical calculus of the ideas immanent in nervous activity. *Bulletin of mathematical biology*, 52, 99-115.
- MENEGUETTE, R. J., GRANDE, R & LOUREIRO A. (2018) Intelligent transport system in smart cities: Aspects and challenges of vehicular networks and cloud. In: *Applications and services*. Springer, p. 147–166.
- NAGY, A. M. & SIMON, V. (2018) Survey on traffic prediction in smart cities. *Pervasive and Mobile Computing*, v. 50, p. 148–163.
- NAHELIYA, B., REDHU, P., & KUMAR, K. (2024). Bi-directional long short term memory neural network for short-term traffic speed prediction using gravitational search algorithm. *International Journal of Intelligent Transportation Systems Research*, 22(2), 316-327.

- OUYANG, X., YANG, Y., ZHANG, Y., ZHOU, W., WAN, J., & DU, S. (2023). Domain adversarial graph neural network with cross-city graph structure learning for traffic prediction. *Knowledge-Based Systems*, 278, 110885.
- PASCANU, R., MIKOLOV, T., & BENGIO, Y. (2013). On the difficulty of training recurrent neural networks. In *International conference on machine learning* (pp. 1310-1318). Pmlr.
- PATIL, M., AHMED, Q., & MIDLAM-MOHLER, S. (2024). Urban Traffic Forecasting with Integrated Travel Time and Data Availability in a Conformal Graph Neural Network Framework. *arXiv preprint arXiv:2407.12238*.
- PEREGRINO, A. A., PRADHAN, S., LIU, Z., FERREIRA, N., & MIRANDA, F. (2021). Transportation scenario planning with graph neural networks. *arXiv preprint arXiv:2110.13202*.
- PHILIPP, G., SONG, D., & CARBONELL, J. G. (2017). The exploding gradient problem demystified-definition, prevalence, impact, origin, tradeoffs, and solutions. *arXiv preprint arXiv:1712.05577*.
- PINHEIRO, A. C.; GILL, I. S. & SERBÍN, A. O. (2001) O Brasil e a economia mundial: Desafios para um país grande e aberto. Editora FGV, Rio de Janeiro.
- RAMAKRISHNAN, N., & SONI, T. (2018). Network traffic prediction using recurrent neural networks. In *2018 17th IEEE international conference on machine learning and applications (ICMLA)* (pp. 187-193). IEEE.
- RANGEL, M. A., & TOMÉ, R. (2022). Health and the megacity: urban congestion, air pollution, and birth outcomes in Brazil. *International Journal of Environmental Research and Public Health*, 19(3), 1151.
- RASHIDI, T. H., MOHAMMADIAN, A., & KOPPELMAN, F. S. (2011). Modeling interdependencies between vehicle transaction, residential relocation and job change. *Transportation*, 38, 909-932.
- RICO, J., BARATEIRO, J., & OLIVEIRA, A. (2021). Graph neural networks for traffic forecasting. *arXiv preprint arXiv:2104.13096*.
- ROCHA FILHO, G. P., MENEGUETTE, R. I., NETO, J. R. T., VALEJO, A., WEIGANG, L., UHEYAMA, J., ... & VILLAS, L. A. (2020). Enhancing intelligence in traffic management systems to aid in vehicle traffic congestion problems in smart cities. *Ad Hoc Networks*, 107, 102265.
- ROESS, R. P.; PRASSAS, E. S.; MCSHANE, W. R. (2010) Engenharia de Tráfego. 4. ed. Pearson Prentice Hall, São Paulo.
- ROSENBLATT, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.

- RUMELHART, D. E., HINTON, G. E., & WILLIAMS, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536.
- RUSSELL, S. J., & NORVIG, P. (2016). *Artificial intelligence: a modern approach*. pearson.
- SEBER, G. A., & LEE, A. J. (2003). *Linear regression analysis*. John Wiley & Sons.
- SHAO, Z., ZHANG, Z., WEI, W., WANG, F., XU, Y., CAO, X., & JENSEN, C. S. (2022). Decoupled dynamic spatial-temporal graph neural network for traffic forecasting. *arXiv preprint arXiv:2206.09112*.
- SHAO, Z., ZHANG, Z., WANG, F., WEI, W., & XU, Y. (2022). Spatial-temporal identity: A simple yet effective baseline for multivariate time series forecasting. In *Proceedings of the 31st ACM international conference on information & knowledge management* (pp. 4454-4458).
- SHEN, X.; LI, Y.; ZHANG, H.; LIU, Y. (2024) A graph-based approach for traffic prediction using similarity and temporal patterns. *Journal of Transportation Engineering, Part A: Systems*, v. 150, p. 04023027.
- SHEN, X., CHEN, J., ZHU, S., & YAN, R. (2024). A decentralized federated learning-based spatial-temporal model for freight traffic speed forecasting. *Expert Systems with Applications*, 238, 122302.
- SHI, F., & ZHAO, C. (2023). Enhancing financial fraud detection with hierarchical graph attention networks: A study on integrating local and extensive structural information. *Finance Research Letters*, 58, 104458.
- SICHEL, D. E. (1991). Business cycle duration dependence: A parametric approach. *The Review of Economics and Statistics*, 254-260.
- SILVA, B. Z. (2024) Next trip prediction in public transportation: A study case in Fortaleza. Dissertação de Mestrado. Faculdade de Engenharia, Universidade do Porto. Portugal.
- SILVA, P. B. (2019) Modelos de previsão de acidentes em rodovia brasileira de pista dupla. Tese de Doutorado, Faculdade de Tecnologia, Universidade de Brasília, Brasília, DF.
- SMITH, B. L. & DEMETSKY, M. J. (1994) Short-term traffic flow prediction: Neural network approach. *Transportation Research Record*, v. 1453, p. 98-104
- SOUZA, H. M. (1997) Abertura econômica e reestruturação industrial no Brasil. Annablume, São Paulo.
- STEPHENS, A. N., & GROEGER, J. A. (2009). Situational specificity of trait influences on drivers' evaluations and driving behaviour. *Transportation research part F: traffic psychology and behaviour*, 12(1), 29-39.

- STEFANI, H. S. (2021) Método de previsão de fluxo de tráfego em rodovias urbanas a partir de dados de velocidade de fontes online. Dissertação de Mestrado. Universidade de São Paulo.
- STEIN, H. S. (2021) Gestão de tráfego urbano: desafios e soluções. Tese de Doutorado, Departamento de Engenharia Civil, Universidade de São Paulo, São Paulo, SP.
- SUN, W., CHENG, R., JIAO, Y., GAO, J., ZHENG, Z., & LU, N. (2023). Transformer network with decoupled spatial-temporal embedding for traffic flow forecasting. *Applied Intelligence*, 53(24), 30148-30168.
- SUN, Y., JIANG, X., HU, Y., DUAN, F., GUO, K., WANG, B., ... & YIN, B. (2022). Dual dynamic spatial-temporal graph convolution network for traffic prediction. *IEEE Transactions on Intelligent Transportation Systems*, 23(12), 23680-23693.
- TACO, G.; WILLY, P. (2003) Redes neurais artificiais aplicadas na modelagem individual de padrões de viagens encadeadas a pé. Tese de Doutorado. Universidade de São Paulo.
- TEDJOPURNOMO, D. A.; CHOUDHURY, F. M.; QIN, A. K. (2021) TrafFormer: A Transformer model for long-term traffic prediction. *Transportation Research Part C: Emerging Technologies*, v. 130, p. 103–118.
- VAN AREM, B., KIRBY, H. R., VAN DER VLIST, M. J., & WHITTAKER, J. C. (1997). Recent advances and applications in the field of short-term traffic forecasting. *International journal of forecasting*, 13(1), 1-12.
- VLAHOGIANNI, E. I., GOLIAS, J. C., & KARLAFTIS, M. G. (2004). Short-term traffic forecasting: Overview of objectives and methods. *Transport reviews*, 24(5), 533-557.
- VLAHOGIANNI, E. I.; KARLAFTIS, M. G.; MESSIAS, H. S. (2014) Short-term traffic forecasting: Where we are and where we're going. *Transportation Research Part C: Emerging Technologies*, v. 43, p. 3–19.
- WANG, J., GU, Q., WU, J., LIU, G., & XIONG, Z. (2016). Traffic speed prediction and congestion source exploration: A deep learning method. In *2016 IEEE 16th international conference on data mining (ICDM)* (pp. 499-508). IEEE.
- YU, B.; YIN, H. & ZHU, Z. (2018) Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting. *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence*, v. 27, p. 3634–3640.
- WANG, H., CHEN, J., PAN, T., DONG, Z., ZHANG, L., JIANG, R., & SONG, X. (2024). STGformer: Efficient Spatiotemporal Graph Transformer for Traffic Forecasting. *arXiv preprint arXiv:2410.00385*.
- WU, Z., PAN, S., LONG, G., JIANG, J., & ZHANG, C. (2019). Graph wavenet for deep spatial-temporal graph modeling. *arXiv preprint arXiv:1906.00121*.

- WU, Z., PAN, S., LONG, G., JIANG, J., CHANG, X., & ZHANG, C. (2020). Connecting the dots: Multivariate time series forecasting with graph neural networks. In *Proceedings of the 26th ACM SIGKDD international conference on knowledge discovery & data mining*, pp. 753-763.
- YAO, D., GU, Y., CONG, G., JIN, H., & LV, X. (2022). Entity resolution with hierarchical graph attention networks. In *Proceedings of the 2022 International Conference on Management of Data* (pp. 429-442).
- YANG, Z.; ZHANG, J.; WANG, Y.; LI, X. (2020) Traffic prediction using artificial intelligence: Review of recent developments. *Transportation Research Part C: Emerging Technologies*, v. 118, p. 1–17
- YIN, X.; YU, J.; DUAN, X.; LIANG, X.; CHEN, L.; LIANG, X. (2025) Previsão de tráfego urbano de curto prazo em cidades inteligentes: uma rede convolucional gráfica espacial-temporal de difusão dinâmica. *Complex & Intelligent Systems*, v. 11, p. 158
- YU, B., YIN, H., & ZHU, Z. (2017). Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. *arXiv preprint arXiv:1709.04875*.
- YU, B. & ET AL. (2020) Graph transformers for large-scale traffic forecasting. In: *Conference on Knowledge Discovery and Data Mining (KDD)*.
- YU, G., & ZHANG, C. (2004). Switching ARIMA model based forecasting for traffic flow. In *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing* (Vol. 2, pp. ii-429). IEEE.
- YUAN, H., YU, H., WANG, J., LI, K., & JI, S. (2021). On explainability of graph neural networks via subgraph explorations. In *International conference on machine learning* (pp. 12241-12252). PMLR.
- ZECHIN, D., DO AMARAL, M. B., & CYBIS, H. B. B. (2022). Previsão de velocidades de tráfego com rede neural LSTM encoder-decoder. *TRANSPORTES*, 30(3), 2660-2660.
- ZECHIN, D., & CYBIS, H. B. B. (2023). Probabilistic traffic breakdown forecasting through Bayesian approximation using variational LSTMs. *Transportmetrica B: Transport Dynamics*, 11(1), 1026-1044.
- ZEMA, D. A.; GOMES, R. C.; SILVA, J. A. (2020) Desafios na aplicação de modelos paramétricos para previsão de tráfego em redes urbanas. *Revista Brasileira de Engenharia de Transportes*, v. 14, n. 3, p. 45–58
- ZHANG, J. & ET AL. (2022) Dynamic graph neural networks for multistep traffic flow prediction. *Neural Networks*.
- ZHANG, S.; WU, Y.; LIU, H.; HUANG, R. & WANG, X. (2018) The impact of road traffic on carbon emissions: An empirical analysis based on city-level panel data from China. *IEEE Access*, v. 6, p. 44586–44598.

- ZHANG, T., DING, W., & XING, M. (2023). Attention-based Dynamic Graph Convolutional Recurrent Neural Network for Traffic Flow Prediction in Highway Transportation. *arXiv preprint arXiv:2309.07196*.
- ZHANG, X., & RICE, J. A. (2003). Short-term travel time prediction. *Transportation Research Part C: Emerging Technologies*, 11(3-4), 187-210.
- ZHANG, Y. & et al. (2022) Graph neural networks for real-time traffic prediction. *Nature. Machine Intelligence*.
- ZHENG, C., FAN, X., WANG, C., & QI, J. (2020). Gman: A graph multi-attention network for traffic prediction. In *Proceedings of the AAAI conference on artificial intelligence* (Vol. 34, No. 01, pp. 1234-1241).
- ZHOU, C., MA, J., DOUGE, L., CHEW, E. P., & LEE, L. H. (2023). Reinforcement Learning-based approach for dynamic vehicle routing problem with stochastic demand. *Computers & Industrial Engineering*, 182, 109443.
- ZHAO, L., SONG, Y., ZHANG, C., LIU, Y., WANG, P., LIN, T E LI, H. (2019). T-GCN: A temporal graph convolutional network for traffic prediction. *IEEE transactions on intelligent transportation systems*, 21(9), 3848-3858.
- ZHAO, Z., CHEN, W., WU, X., CHEN, P. C., & LIU, J. (2017). LSTM network: a deep learning approach for short-term traffic forecast. *IET intelligent transport systems*, 11(2), 68-75.
- ZHOU, X., ZHANG, Y., LI, Z., WANG, X., ZHAO, J., & ZHANG, Z. (2022). Large-scale cellular traffic prediction based on graph convolutional networks with transfer learning. *Neural Computing and Applications*, 1-11.
- ŻOCHOWSKA, R. & PAMUŁA, W. (2024) Analysis of prediction errors in OD-based traffic models using video-sensor data. *Remote Sensing*, v. 16, p. 1202.