

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA POLITÉCNICA E DE ARTES
GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO



REDES NEURAIS APLICADAS A SEMÁFOROS DE TRÂNSITO

GOIÂNIA

2024

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA POLITÉCNICA E DE ARTES
GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO



REDES NEURAI APLICADAS A SEMÁFOROS DE TRÂNSITO

Trabalho de conclusão de Curso apresentado à
Escola Politécnica e de Artes, da Pontifícia
Universidade Católica de Goiás.

Orientando(a): Luciano Apolinário de Siqueira Filho

Orientador(a): Prof. M e . Gustavo Siqueira Vinhal

Banca examinadora:

Prof. Dr. Nilson Cardoso Amaral

Prof. Dr. Sibelius Lellis Vieira

GOIÂNIA

2024

RESUMO

A mobilidade urbana é um desafio recorrente nas grandes cidades, impactando diretamente o bem-estar da população. O tráfego intenso, causado pelo crescente número de veículos e pela falta de planejamento eficiente, resulta em congestionamentos, aumento da poluição e estresse para os moradores. Nesse contexto, a Inteligência Artificial (IA) surge como uma solução para melhorar o fluxo do trânsito. Esta pesquisa tem como objetivo aplicar redes neurais artificiais para otimizar o controle de semáforos em sistemas de tráfego urbano. Após uma revisão da literatura sobre controle de tráfego e aprendizado de máquina, identificou-se uma possibilidade do uso de redes neurais para melhorar a eficiência do trânsito em ambientes urbanos. Para a realização dos experimentos, foi utilizado um simulador de tráfego baseado no modelo *Intelligent Driver Model (IDM)*, que foi customizado a partir de um código-fonte existente, permitindo a integração de novas funcionalidades e a implementação da rede neural para controle dinâmico dos ciclos semafóricos. A metodologia incluiu a coleta de dados da simulação, como a taxa de veículos, o número de veículos que passaram, o número de veículos aguardando nos sinais e a velocidade média dos veículos. Esses dados foram utilizados para treinar a rede neural, que ajusta em tempo real a duração dos ciclos semafóricos de acordo com as condições do tráfego. O modelo foi validado com base em métricas de desempenho, como a previsão de tempos ideais de sinalização, e comparado com os ciclos de semáforos tradicionais. Os resultados mostraram que a aplicação da rede neural proporcionou uma leve redução no tempo de espera dos veículos e uma melhora moderada na fluidez do tráfego em relação ao controle tradicional. A pesquisa sugere que o uso de aprendizado de máquina para o controle de semáforos pode ser uma solução promissora para otimizar o fluxo de veículos em interseções urbanas, contribuindo para a mitigação de congestionamentos.

Palavras-chave: *redes neurais, controle de tráfego, semáforos, simulação, aprendizado de máquina.*

ABSTRACT

Urban mobility is a recurring challenge in large cities, directly impacting the well-being of the population. Heavy traffic, caused by the growing number of vehicles and lack of efficient planning, results in congestion, increased pollution, and stress for residents. In this context, Artificial Intelligence (AI) emerges as a solution to improve traffic flow. This research aims to apply artificial neural networks to optimize traffic light control in urban traffic systems. After reviewing the literature on traffic control and machine learning, a growing trend was identified in the use of neural networks to improve traffic efficiency in urban environments. For the experiments, a traffic simulator based on the Intelligent Driver Model (IDM) was customized from an existing codebase, allowing for the integration of new features and the implementation of a neural network for dynamic traffic light cycle control. The methodology included collecting simulation data such as vehicle rate, the number of vehicles that passed, the number of vehicles waiting at signals, and the average vehicle speed. These data were used to train the neural network, which adjusts traffic light cycle durations in real-time according to traffic conditions. The model was validated using performance metrics, such as the prediction of ideal signal timing, and compared to traditional traffic light control cycles. The results showed that the neural network provided a slight reduction in vehicle waiting times and a moderate improvement in traffic flow compared to traditional control methods. The research suggests that using machine learning for traffic light control could be a promising solution for optimizing vehicle flow at urban intersections, contributing to congestion mitigation.

Keywords: *neural networks, traffic control, traffic lights, simulation, machine learning.*

SUMÁRIO

1. INTRODUÇÃO	9
1.1 JUSTIFICATIVA	10
1.2 OBJETIVO GERAL	11
1.3 OBJETIVOS ESPECÍFICOS	11
1.4 CONTRIBUIÇÃO DA PESQUISA	12
2. REFERENCIAL TEÓRICO	14
2.1 TEORIA DE CONTROLE DE TRÁFEGO URBANO	14
2.2 INTELIGÊNCIA ARTIFICIAL	15
2.3 MACHINE LEARNING	16
2.4 REDES NEURAIS	17
2.5 INTELLIGENT DRIVER MODEL (IDM)	19
3. PROCEDIMENTOS METODOLÓGICOS	22
3.1 PREPARAÇÃO DOS DADOS	25
3.2 SIMULAÇÃO DE TRÁFEGO	26
3.3 TREINAMENTO DO MODELO DE REDE NEURAL	27
3.3.1 DIVISÃO DOS DADOS E NORMALIZAÇÃO	27
3.3.2 ESTRUTURA E CONFIGURAÇÃO DO MODELO	28
3.3.3 TREINAMENTO E MONITORAMENTO	31
3.3.4 AVALIAÇÃO E PREVISÃO	33
3.4 IMPLEMENTAÇÃO DA REDE NEURAL NA SIMULAÇÃO	35
3.4.1 INICIALIZAÇÃO E CARREGAMENTO DO MODELO	35
3.4.2 PROCESSAMENTO DOS DADOS E PREVISÃO DE CICLOS	35
3.4.3 VANTAGENS DO CONTROLE ADAPTATIVO	36
3.4.4 FLUXO DE CONTROLE DO MODELO ADAPTATIVO	37
4. RESULTADOS E DISCUSSÃO	40
4.1 APRESENTAÇÃO DOS RESULTADOS	40
4.1.1 MÉDIA DE VEÍCULOS ESPERANDO	40
4.1.2 VEÍCULOS PASSADOS	43
4.1.3 VELOCIDADE MÉDIA	45
4.2 LIMITAÇÕES E PONTOS FORTES DA SIMULAÇÃO	47
4.3 DIFICULDADES NA IMPLEMENTAÇÃO NO MUNDO REAL	49
5. CONSIDERAÇÕES FINAIS	52
5.1 PERSPECTIVAS PARA ESTUDOS FUTUROS	52
REFERÊNCIAS	55

LISTA DE FIGURAS

Figura 1 – Simulação.....	24
Figura 2 - Arquitetura da Rede Neural.....	30
Figura 3 - Estrutura Visual da Rede Neural.....	31
Figura 4 - Evolução da Perda durante o treinamento.....	33
Figura 5 - Evolução do Erro Absoluto Médio durante o treinamento.....	34
Figura 6 - Comparação entre Valores Reais e Previsões (50 ciclos)	35
Figura 7 - Fluxo de Controle do Modelo de Rede Neural Adaptativo.....	39
Figura 8 - Comparação da Média de Veículos Esperando.....	42
Figura 9 - Comparação da Média de Veículos Esperando Detalhada.....	43
Figura 10 - Comparação de Veículos Passados.....	44
Figura 11 - Comparação de Veículos Passados Detalhada.....	45
Figura 12 - Comparação de Velocidade Média de Veículos.....	46
Figura 13 - Comparação de Velocidade Média de Veículos Detalhado.....	47

LISTA DE TABELAS

Tabela 1: Variáveis Coletadas Durante a Simulação de Tráfego	26
Tabela 2: Atributos Derivados Criados a Partir dos Dados Coletados	27
Tabela 3: Parâmetros dos Veículos na Simulação de Tráfego.....	28
Tabela 4: Principais Componentes da Arquitetura da Rede Neural.....	30
Tabela 5: Vantagens do Controle Adaptativo com Rede Neural.....	37

LISTA DE ABREVIATURAS E SIGLAS

4G	Quarta Geração de Redes Móveis
5G	Quinta Geração de Redes Móveis
AI	<i>Artificial Intelligence</i> (Inteligência Artificial)
CSV	Valores Separados por Vírgula (<i>Comma-Separated Values</i>)
DENATRAN	Departamento Nacional de Trânsito
IA	Inteligência Artificial
IDM	Modelo de Condutor Inteligente (<i>Intelligent Driver Model</i>)
IoT	Internet das Coisas (<i>Internet of Things</i>)
MAE	Erro Absoluto Médio (<i>Mean Absolute Error</i>)
MSE	Erro Quadrático Médio (<i>Mean Squared Error</i>)
ReLU	Unidade Linear Retificada (<i>Rectified Linear Unit</i>)
V2X	Comunicação Veículo-para-Tudo (<i>Vehicle-to-Everything Communication</i>)
Wi-Fi	<i>Wireless Fidelity</i>

1. INTRODUÇÃO

A mobilidade urbana é um dos principais desafios enfrentados pelas grandes cidades modernas, afetando diretamente a qualidade de vida e o bem-estar da população (ZAMIN, 2018). O crescimento acelerado das áreas urbanas, aliado ao aumento exponencial do número de veículos, tem sobrecarregado as infraestruturas viárias, muitas vezes inadequadas ou mal planejadas para atender à crescente demanda (DE FREITAS, 2015). Como consequência, os congestionamentos se tornaram parte da rotina diária de milhões de pessoas, levando à perda significativa de tempo em deslocamentos, ao aumento nos níveis de estresse e à elevação das emissões de poluentes, que impactam negativamente o meio ambiente e a saúde pública (ANDRADE, 2016).

Diante dessa realidade, soluções tecnológicas têm ganhado destaque como ferramentas essenciais para repensar e melhorar a mobilidade urbana. Entre essas inovações, a inteligência artificial (IA) desponta como uma aliada poderosa para enfrentar os desafios do trânsito nas cidades. Uma das aplicações mais promissoras é o uso de sistemas de IA no controle de semáforos, que podem operar de maneira dinâmica e adaptativa. Esses sistemas analisam, em tempo real, o volume de veículos em cada via, ajustando automaticamente os tempos de sinalização para priorizar os fluxos mais intensos e evitar a formação de filas desnecessárias (ROSSI, 2024). Essa abordagem inteligente não apenas reduz os congestionamentos, mas também melhora a eficiência geral da circulação de veículos, diminuindo o tempo de viagem e o consumo de combustível.

Os semáforos podem ser definidos como um componente da sinalização viária que utiliza dispositivos luminosos para regular o tráfego. Esses dispositivos funcionam de maneira alternada ou intermitente, sendo controlados por sistemas eletromecânicos ou eletrônicos (DENATRAN, 2013). A utilização de semáforos pode causar um problema no meio urbano Definido por Zamin em sua pesquisa:

A desorganização do meio urbano traz diversos problemas, como por exemplo o excedente de pessoas, veículos e rotas que de certa forma, atrasam o trânsito. Dentre esses aspectos o aumento diário do fluxo de automóveis está diretamente ligado com a expansão populacional. Uma família de quatro pessoas, na qual todas tem mais de 18 anos, é provável que pelo menos duas tenham o seu próprio carro. Isso mostra que quanto mais indivíduos utilizam seu próprio carro, mais veículos irão estar nas ruas

aumentando o tráfego (ZAMIN, 2018).

Para tentar reduzir o impacto do uso de semáforos, pode-se utilizar Inteligência Artificial (IA). A Inteligência Artificial, utilizando técnicas como aprendizado de máquina e redes neurais, tem alcançado avanços notáveis em áreas como reconhecimento de padrões, processamento de linguagem natural e visão computacional, impulsionando a inovação tecnológica em diversos setores (RAJALINGAPPAA; SOLANKI, 2017).

Dentre os diversos algoritmos de IA existentes, o mais utilizado é a Rede Neural Artificial (RNA). Neste modelo, o computador processa dados de uma forma inspirada pelo cérebro humano (AWS, 2023). As RNAs são amplamente aplicadas na resolução de problemas complexos, especialmente quando o comportamento das variáveis não é totalmente conhecido ou previsível. Uma das características mais notáveis das RNAs é sua habilidade de aprender por meio de exemplos, adaptando-se e aprimorando suas respostas conforme é exposta a novos dados, o que permite resolver tarefas desafiadoras em áreas como reconhecimento de padrões, previsão e otimização (SPÖRL et al., 2011).

Para resolução do problema de congestionamento urbano, pode-se aplicar o conceito de Redes Neurais como uma possível solução. Justifica-se estudar o tema das redes neurais aplicadas a semáforos de trânsito pela possibilidade de melhorar a eficiência do tráfego, utilizar de forma mais inteligente a infraestrutura existente, promover a segurança viária, aplicar a inteligência artificial na prática e contribuir para a sustentabilidade e redução das emissões. Isso é particularmente relevante em grandes cidades, onde o tráfego intenso pode causar atrasos, acidentes e impactos ambientais negativos.

Diante desse contexto, este projeto visa responder a seguinte questão de pesquisa: **como as redes neurais podem ser utilizadas para melhorar o controle de semáforos de trânsito e otimizar o fluxo de veículos nas vias urbanas?**

1.1 JUSTIFICATIVA

A crescente urbanização e o aumento do tráfego em grandes centros urbanos têm gerado desafios significativos para a mobilidade e a eficiência dos sistemas de transporte. O controle de semáforos é um fator crítico para a gestão do fluxo de veículos, e o uso de ciclos semaforicos fixos pode resultar em

congestionamentos e desperdício de tempo, especialmente durante horários de pico ou em situações imprevistas. A falta de flexibilidade no tempo dos sinais pode causar longos tempos de espera e reduzir a eficiência do trânsito, afetando negativamente a qualidade de vida da população e o transporte de mercadorias.

A aplicação de redes neurais no controle de semáforos surge como uma solução promissora para ajustar dinamicamente os ciclos de acordo com as condições do tráfego em tempo real. O uso de redes neurais permite uma adaptação mais eficiente do sistema, levando em consideração variáveis como a taxa de veículos, o número de veículos aguardando e a velocidade média do tráfego. Essa abordagem pode contribuir para a mitigação de congestionamentos e otimização da fluidez nas interseções.

Além disso, o controle inteligente de semáforos pode ser fundamental para o futuro dos transportes em cidades inteligentes, onde o tráfego é monitorado e gerido de forma automatizada. A adoção de tecnologias de aprendizado de máquina nesse contexto tem o potencial de melhorar significativamente a mobilidade urbana, reduzindo o tempo de deslocamento, o consumo de combustível e as emissões de gases poluentes. Dessa forma, a implementação de redes neurais para o controle de semáforos se justifica não apenas como uma solução tecnológica avançada, mas também como uma estratégia para promover cidades mais sustentáveis e eficientes.

1.2 OBJETIVO GERAL

Aplicar redes neurais artificiais para o controle adaptativo de semáforos em sistemas de tráfego urbano, visando otimizar a fluidez do trânsito, reduzir o tempo de espera dos veículos e mitigar os congestionamentos por meio de ajustes dinâmicos nos ciclos de sinalização baseados em dados coletados em tempo real.

1.3 OBJETIVOS ESPECÍFICOS

- Realizar uma revisão bibliográfica sobre técnicas de controle de tráfego, aprendizado de máquina e redes neurais aplicadas ao trânsito urbano.
- Desenvolver um modelo de rede neural artificial capaz de ajustar dinamicamente os tempos de ciclo dos semáforos, com base em dados

coletados em simulações de tráfego.

- Simular diferentes cenários de tráfego urbano, variando as condições de fluxo veicular (leve, moderado e intenso), utilizando o modelo *Intelligent Driver Model (IDM)*.
- Treinar e validar o modelo de rede neural com os dados gerados nas simulações, avaliando sua eficiência em comparação aos métodos tradicionais de controle fixo.
- Analisar o impacto do modelo adaptativo na fluidez do tráfego, considerando métricas como o tempo de espera médio dos veículos, o número de veículos que atravessam os semáforos e a velocidade média do fluxo.
- Identificar as principais limitações e oportunidades para a implementação prática do sistema em ambientes urbanos reais, incluindo aspectos técnicos e comportamentais.
- Propor recomendações para estudos futuros, incluindo a integração do modelo com sistemas de transporte autônomo, variáveis climáticas e outros elementos do ambiente urbano.

1.4 CONTRIBUIÇÃO DA PESQUISA

A principal contribuição desta pesquisa é a aplicação de redes neurais artificiais para o controle inteligente de semáforos em sistemas de tráfego urbano. A partir de uma simulação customizada utilizando o modelo *Intelligent Driver Model (IDM)*, a pesquisa propõe uma solução que ajusta os ciclos semaforicos de forma dinâmica, com base em dados de tráfego coletados em tempo real. A integração de redes neurais nesse processo tem o potencial de melhorar a gestão do fluxo de veículos, resultando em uma leve redução no tempo de espera dos veículos e uma melhora na fluidez do tráfego, especialmente em interseções complexas.

Este trabalho também contribui para o avanço de tecnologias de aprendizado de máquina aplicadas à mobilidade urbana, oferecendo uma solução que pode ser escalada para diferentes contextos e cenários urbanos. A pesquisa

demonstra que, com a utilização de redes neurais, o controle de semáforos pode ser ajustado de maneira mais eficiente do que os métodos tradicionais, considerando as variáveis em tempo real do trânsito. Além disso, essa abordagem pode ser útil para futuras aplicações em cidades inteligentes, onde o controle automatizado do tráfego é crucial para reduzir congestionamentos e melhorar a mobilidade.

A conclusão bem-sucedida deste estudo contribuirá para o desenvolvimento de tecnologias mais inteligentes e sustentáveis no controle de tráfego, integrando algoritmos de aprendizado de máquina em um campo tradicionalmente dominado por sistemas fixos. Isso permitirá que gestores urbanos e engenheiros de tráfego tenham uma ferramenta mais flexível e adaptável para gerenciar o fluxo de veículos, reduzindo os impactos ambientais e promovendo maior eficiência no transporte urbano. Além disso, esta pesquisa abre espaço para futuras inovações, como a integração com sistemas de veículos autônomos e a expansão do controle inteligente de semáforos em redes de tráfego mais amplas.

2. REFERENCIAL TEÓRICO

2.1 TEORIA DE CONTROLE DE TRÁFEGO URBANO

O controle do tráfego em interseções urbanas tem como principal objetivo garantir a segurança e a eficiência do fluxo de veículos e pedestres. A sinalização semafórica, definida como "um subsistema da sinalização viária que se compõe de indicações luminosas acionadas alternada ou intermitentemente por meio de sistema eletromecânico ou eletrônico" (DENATRAN, 2013, p. 8), é um dos principais mecanismos para esse controle, sendo responsável pela alternância ordenada do direito de passagem em interseções.

A instalação de semáforos deve ser precedida por uma análise detalhada das condições do tráfego, incluindo o volume de veículos e o potencial de conflitos. O uso apropriado da sinalização semafórica, quando justificado por critérios técnicos, apresenta muitos impactos positivos, como o aumento da segurança viária, a melhoria da fluidez do trânsito e a redução de atrasos, ao garantir uma distribuição adequada dos tempos destinados a cada movimento e ao controlar de forma eficiente o direito de passagem de veículos e pedestres. Essas medidas promovem uma redução significativa dos conflitos e um aumento na credibilidade da sinalização por parte dos usuários (DENATRAN, 2013, p. 34).

Por outro lado, quando a instalação dos semáforos não é justificada tecnicamente, os impactos negativos podem ser significativos, resultando em aumento da ocorrência de acidentes, atrasos excessivos, e até mesmo indução ao desrespeito à sinalização devido à ociosidade na operação. Essa implantação inadequada também leva ao descrédito por parte dos motoristas e pedestres, além de representar um gasto desnecessário de recursos públicos (DENATRAN, 2013, p. 34). Portanto, é fundamental que, antes de se optar pela sinalização semafórica, sejam consideradas alternativas, como rotatórias ou placas de preferência, que podem ser mais eficientes e adequadas em determinados contextos para garantir a segurança e a fluidez do tráfego.

Em termos de programação dos semáforos, é essencial considerar o tempo de verde de segurança, que visa garantir a segurança dos usuários da via, evitando tempos excessivamente curtos que possam resultar em situações de alto potencial de acidentes. Para cada grupo de movimentos, deve-se definir um valor mínimo admissível para a duração do tempo de verde, garantindo que, mesmo que a

demanda possa ser atendida em um tempo menor, a segurança dos usuários não seja comprometida (BRASIL, 2018, p. 87).

O dimensionamento desse tempo para veículos é função de diversos fatores, como a hierarquia da via, o volume de veículos, a largura da transversal, a composição do tráfego e a presença de pedestres. Além disso, a presença de pedestres deve ser considerada, assegurando que o tempo de verde permita sua travessia segura, mesmo que não haja um grupo focal específico para pedestres. Os valores usualmente utilizados para o tempo de verde de segurança para veículos variam entre 10 e 20 segundos, não sendo admitidos valores inferiores a 10 segundos (DENATRAN, 2013, p. 86). Esse valor mínimo é fundamental para garantir uma fluidez razoável e para minimizar os tempos de espera, mantendo a segurança tanto dos veículos quanto dos pedestres.

Portanto, o controle de tráfego por meio de semáforos é uma solução essencial para organizar o trânsito urbano, especialmente em locais onde há conflitos complexos de circulação de veículos e pedestres. Entretanto, sua implementação deve ser baseada em uma análise criteriosa, que considere a demanda real e as características do fluxo de tráfego para justificar sua necessidade. Uma instalação inadequada pode levar a consequências negativas, como atrasos excessivos e maior número de acidentes. Assim, o planejamento dos tempos de sinalização deve refletir um equilíbrio que assegure tanto a segurança quanto a eficiência.

2.2 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial é um campo que abrange diversas técnicas e algoritmos, projetados para possibilitar que sistemas computacionais realizem tarefas que normalmente requerem a inteligência humana. Esses sistemas são capazes de processar e interpretar grandes volumes de dados, aprender de forma autônoma e tomar decisões inteligentes. A IA inclui tecnologias como aprendizado de máquina, processamento de linguagem natural, visão computacional e robótica. Esses avanços têm permitido a IA trazer contribuições notáveis para áreas variadas, incluindo saúde, finanças, transportes, manufatura e assistentes pessoais, o que tem gerado impactos significativos para a sociedade (RUSSEL, S.; NORVIG, 2020).

A base da IA está em modelos e algoritmos que tornam possível o aprendizado a partir dos dados, a identificação de padrões, a previsão de eventos e

a tomada de decisões inteligentes. O aprendizado de máquina, especificamente, tem sido um dos principais motores da IA, com algoritmos que aprendem a partir de exemplos e conseguem melhorar suas capacidades conforme se alimentam de novos dados. Além disso, as redes neurais artificiais, especialmente as redes neurais profundas, têm revolucionado a área ao permitir o processamento de dados não estruturados e resolver problemas complexos, como o reconhecimento de imagens e o entendimento de linguagem natural (LECUN, Y.; BENGIO, Y.; HINTON, 2015).

2.3 MACHINE LEARNING

Machine learning, ou aprendizado de máquina, é uma subárea da inteligência artificial focada no desenvolvimento de algoritmos que permitem que sistemas computacionais aprendam automaticamente a partir de dados e aprimorem suas habilidades ao longo do tempo. Ao identificar padrões presentes nos dados, esses algoritmos são capazes de gerar previsões ou tomar decisões, sendo uma ferramenta poderosa que pode ser aplicada em diferentes contextos, como análise de dados, automação de decisões, reconhecimento de padrões, e processamento de linguagem natural. Assim, o aprendizado de máquina tem contribuído significativamente para diversos setores da sociedade, trazendo avanços importantes (MITCHELL, 1997).

Os algoritmos de aprendizado de máquina se baseiam em conjuntos de dados que permitem aos modelos aprender padrões relevantes e se adaptar conforme novas informações são inseridas. Existem três categorias principais de aprendizado de máquina: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço. No aprendizado supervisionado, os modelos são treinados utilizando um conjunto de dados que possui rótulos, ou seja, exemplos acompanhados por respostas corretas, permitindo ao algoritmo aprender com a orientação adequada. O aprendizado não supervisionado, por outro lado, trabalha com dados não rotulados, exigindo que o modelo detecte padrões ou estruturas internas por conta própria. Já o aprendizado por reforço é um processo no qual o algoritmo aprende por meio da interação com o ambiente, utilizando um sistema de recompensas que guia a tomada de decisões para atingir um objetivo específico (GOODFELLOW; BENGIO; COURVILLE, 2016).

Essas diferentes abordagens são amplamente usadas em problemas complexos, possibilitando que os sistemas computacionais melhorem continuamente, sem a necessidade de intervenção humana direta. Isso tem permitido avanços significativos em áreas como diagnósticos médicos, sistemas de recomendação, direção autônoma, e otimização de processos industriais, demonstrando o vasto potencial e a aplicabilidade do aprendizado de máquina em solucionar desafios contemporâneos.

2.4 REDES NEURAIAS

As redes neurais artificiais são um elemento central da inteligência artificial, mostrando grande eficácia em diversos cenários, incluindo o controle inteligente de sistemas complexos, como o trânsito urbano. No contexto do controle de semáforos, redes neurais são utilizadas para ajustar dinamicamente o tempo dos sinais, com o objetivo de melhorar a fluidez do tráfego e reduzir o tempo de espera dos veículos já que as camadas densas são versáteis e podem ser aplicadas a qualquer problema que envolva relações complexas entre variáveis de entrada e saída (Goodfellow, Bengio & Courville, 2016). Essa abordagem tem o potencial de mitigar congestionamentos e adaptar os ciclos de sinalização às condições reais de trânsito de forma muito mais eficiente do que sistemas baseados em regras fixas.

As redes neurais são inspiradas no funcionamento do cérebro humano e são compostas por camadas de neurônios artificiais que se comunicam. Cada neurônio realiza operações matemáticas simples, recebendo informações das camadas anteriores e transmitindo o resultado para as camadas seguintes, permitindo que o sistema aprenda padrões complexos presentes nos dados de tráfego (HAYKIN, 2000).

No contexto deste trabalho, o modelo de rede neural para o controle dos semáforos é composto por diferentes camadas que contribuem para o aprendizado de padrões no fluxo de tráfego. A arquitetura da rede consiste em:

- **Camada de Entrada:** Recebe dados de entrada relacionados ao tráfego, como a taxa de veículos, o número de veículos que passaram, os veículos aguardando no sinal e a velocidade média dos veículos. Esses dados são essenciais para entender a situação atual da

interseção e decidir sobre a melhor ação para otimizar o fluxo.

- **Camadas Ocultas:** A rede inclui camadas ocultas que realizam transformações matemáticas para extrair padrões mais profundos dos dados de tráfego. Estas camadas são responsáveis por identificar relações complexas entre as variáveis de entrada, que são fundamentais para a tomada de decisões em tempo real.
- **Camada de Saída:** A camada de saída produz o valor final, que neste caso é a previsão do tempo ideal do ciclo de sinal verde, visando reduzir o tempo de espera e melhorar a eficiência do tráfego em uma interseção específica.

As redes neurais são particularmente vantajosas no controle de semáforos devido à sua habilidade de aprender padrões não triviais nos dados, como o impacto de variações no volume de tráfego durante diferentes horários do dia. No entanto, como em qualquer aplicação de redes neurais, existem alguns desafios importantes, como:

- **Quantidade de Dados:** Para treinar eficazmente uma rede neural para controlar semáforos, são necessários grandes volumes de dados sobre o tráfego. Neste trabalho, foram utilizados dados coletados em simulações de tráfego, que alimentam a rede para ajustar os tempos dos sinais com base nas condições reais.
- **Interpretabilidade:** Outro desafio é o fato de as redes neurais serem frequentemente vistas como "caixas-pretas", o que dificulta entender como as decisões são tomadas. Embora este seja um problema comum em redes neurais, a avaliação das previsões feitas pela rede com base em métricas como erro absoluto médio (MAE) e erro quadrático médio (MSE) ajuda a garantir a eficácia das decisões tomadas.
- **Overfitting:** Redes neurais podem sofrer de *overfitting*, especialmente quando a rede é muito complexa em relação ao tamanho dos dados disponíveis. Neste projeto, técnicas como *dropout* e *Batch Normalization* foram utilizadas para melhorar a capacidade de generalização do modelo e evitar o *overfitting* (GOODFELLOW;

BENGIO; COURVILLE, 2016).

Para evitar *overfitting* e garantir um treinamento eficaz, diferentes hiperparâmetros foram otimizados, como:

- **Taxa de Aprendizado (*Learning Rate*):** Determina a velocidade com que a rede ajusta seus pesos durante o treinamento. A escolha de uma taxa apropriada evita problemas de convergência e ajuda a rede a aprender de forma eficiente.
- **Número de Épocas:** O modelo foi treinado por várias épocas, e o tamanho do lote de amostras (batch size) foi ajustado para garantir que a rede pudesse generalizar bem, sem levar a um treinamento lento ou instável.
- **Regularização:** Técnicas para evitar *overfitting*, adicionando uma penalidade aos pesos ou desativando aleatoriamente neurônios durante o treinamento.

A implementação do modelo de rede neural para controle de semáforos, descrita no código fornecido, utiliza técnicas como normalização dos dados, camadas de regularização, e otimizadores avançados como *Adam*, que permitem uma convergência mais rápida e eficiente. Esses componentes são essenciais para permitir que a rede se adapte rapidamente às mudanças nas condições do tráfego, melhorando a eficiência do sistema de controle semafórico em ambientes urbanos.

Em resumo, as redes neurais aplicadas ao controle de semáforos representam uma abordagem poderosa para enfrentar os desafios do tráfego urbano, permitindo o ajuste dinâmico e adaptativo dos ciclos dos semáforos. No entanto, seu sucesso depende de um treinamento adequado, da disponibilidade de dados de qualidade, e do uso de técnicas eficazes para evitar problemas como *overfitting* e falta de interpretabilidade. Com a evolução contínua das técnicas de aprendizado profundo, espera-se que as redes neurais continuem a contribuir significativamente para a otimização dos sistemas de transporte urbano, tornando o fluxo de veículos mais eficiente e menos sujeito a congestionamentos.

2.5 INTELLIGENT DRIVER MODEL (IDM)

O *Intelligent Driver Model (IDM)* é um modelo utilizado para descrever o

comportamento de veículos em sistemas de trânsito, sendo amplamente empregado em simulações de tráfego urbano e rodoviário. O IDM é capaz de representar diferentes situações de tráfego, como aceleração, frenagem, e transições de estados de tráfego, incluindo o fluxo livre e condições de stop-and-go (TREIBER; HELBING, 2008). Este modelo é particularmente adequado para simular situações complexas de trânsito, como a formação de congestionamentos e as mudanças dinâmicas na velocidade dos veículos.

No contexto deste trabalho, o IDM é usado para descrever o comportamento dos veículos em um ambiente urbano, controlado por semáforos. Esse modelo permite que cada veículo ajuste sua aceleração e velocidade de acordo com a distância em relação ao veículo à frente e à diferença de velocidade, replicando, assim, o comportamento real dos motoristas ao reagirem ao fluxo de tráfego.

O IDM é baseado em uma abordagem contínua e determinística para calcular a aceleração de um veículo. A aceleração de um veículo depende da sua própria velocidade, da distância em relação ao veículo à frente, e da diferença de velocidade entre os dois veículos. A equação geral para a aceleração é composta por dois termos principais:

- **Aceleração em Condições de Estrada Livre:** Quando o veículo está em um cenário onde não há obstáculos à sua frente, ele acelera até atingir uma velocidade desejada. Esse comportamento é modelado através de uma equação que considera a aceleração máxima do veículo e a velocidade desejada do motorista. Esse termo garante que o veículo alcance uma velocidade estável ao trafegar sem restrições de outros veículo
- **Frenagem Adaptativa:** Quando há um veículo à frente, o modelo inclui um termo de frenagem que é responsável por reduzir a velocidade para evitar colisões. Esse termo é função da distância de segurança e do tempo de reação do motorista, levando em consideração tanto a diferença de velocidade entre os veículos quanto o espaço disponível entre eles. A frenagem ocorre de maneira proporcional à proximidade e à velocidade relativa dos veículos, assegurando uma transição suave do movimento livre para uma condição de desaceleração quando necessário (TREIBER; HELBING, 2008).

Os parâmetros do IDM incluem valores como a velocidade desejada, a aceleração máxima, a desaceleração máxima e o tempo de reação do motorista. Esses parâmetros são ajustados para simular de forma realista diferentes tipos de condutores e condições de trânsito. Por exemplo, a velocidade desejada de um veículo reflete as características da via e as preferências do motorista, enquanto a aceleração máxima e a desaceleração máxima determinam o quão rápido o veículo pode reagir para aumentar ou reduzir a velocidade.

O uso do IDM permite modelar diferentes comportamentos de trânsito em uma interseção controlada por semáforos, o que é essencial para entender como diferentes estratégias de controle podem influenciar o fluxo de tráfego. As simulações realizadas com o IDM neste trabalho incluem cenários em que o fluxo de veículos é ajustado dinamicamente para refletir variações no volume de tráfego, por exemplo, em horários de pico e em condições de tráfego fluido.

3. PROCEDIMENTOS METODOLÓGICOS

Esta pesquisa, segundo sua natureza é um resumo de assunto, buscando explicar a área do conhecimento do projeto, indicando sua evolução histórica, como resultado da investigação das informações obtidas, levando ao entendimento de suas causas e explicações (WAZLAWICK, 2014).

Segundo os objetivos é uma pesquisa exploratória e descritiva. A pesquisa descritiva busca dados mais consistentes sobre determinado assunto, porém, não ocorre a interferência do pesquisador, apenas expõe os fatos como realmente são (WAZLAWICK, 2014). As pesquisas descritivas descrevem as características de certo fenômeno ou população. Também pode ser elaborada com o intuito de identificar as relações entre as variáveis (GIL, 2017).

A pesquisa exploratória muitas vezes é considerada como a primeira parte do processo de pesquisa, porque não necessariamente o autor tem um objetivo ou hipótese definida (WAZLAWICK, 2014). Essa pesquisa tem como objetivo a maior familiaridade do autor com o problema, tornando mais explícito ou facilitar a construção de hipóteses. Geralmente é uma pesquisa flexível, porque considera os variados aspectos referentes aos fatos ou fenômeno estudado (GIL, 2017).

Quanto aos procedimentos técnicos, será uma pesquisa bibliográfica e experimental. A pesquisa bibliográfica requer o estudo de teses, artigos, entre outros. A pesquisa experimental é caracterizada por ter uma ou mais variáveis experimentais que podem ser coordenadas pelo pesquisador (WAZLAWICK, 2014).

A pesquisa bibliográfica, foi elaborada a partir de materiais já publicados, podendo incluir livros, teses, materiais disponibilizados na Internet, revistas, entre outros. A principal vantagem é permitir uma sucessão de fenômenos maior do que seria capaz de pesquisar diretamente (GIL, 2017).

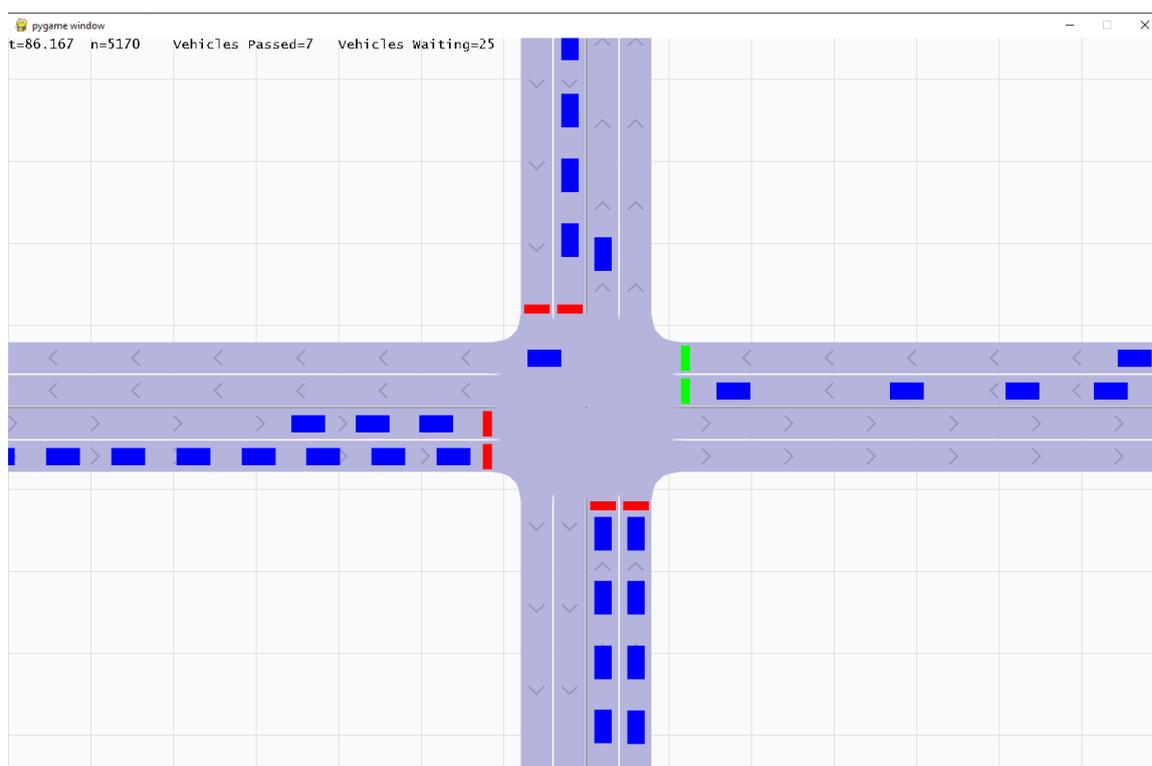
A pesquisa experimental consiste que o pesquisador provoque mudanças no ambiente de pesquisa, observando se as alterações realizadas são de acordo com os resultados esperados (WAZLAWICK, 2014).

A pesquisa experimental consiste em estabelecer um objeto de estudo, escolher as variáveis que a influenciam e determinar as formas de controle e observar os efeitos que a variável gera no objeto. Realiza pelo menos um dos elementos que julga ser responsável pela circunstância que está sendo pesquisado (GIL, 2017).

o presente trabalho, foram utilizadas simulações de tráfego para investigar o

uso de redes neurais aplicadas ao controle de semáforos urbanos. A simulação utilizada foi baseada no repositório público Traffic Simulator disponível em BilHim (2023). O código original do repositório foi modificado e adaptado para se adequar às necessidades do estudo, especialmente em relação ao armazenamento e coleta dos dados durante a execução da simulação, aspectos desenvolvidos especificamente para este projeto. Essas modificações permitiram a geração de dados estruturados que foram armazenados em arquivos no formato Valores Separados por Vírgula (CSV), facilitando a análise do uso para o treinamento dos modelos preditivos. A Figura 1 apresenta o ambiente de simulação desenvolvido, incluindo as principais características do tráfego urbano modelado e os parâmetros coletados durante a execução.

Figura 1: Simulação



Fonte: Autoria própria

De acordo com a Figura 1, pode-se observar como a simulação foi configurada para modelar o tráfego urbano, considerando aspectos como a disposição das vias, os semáforos controlados, e as variáveis monitoradas durante a execução. Esses dados foram coletados e armazenados automaticamente para garantir consistência na análise e para alimentar os modelos preditivos utilizados no

controle semafórico. A simulação gerou variáveis importantes para o estudo, como a taxa de veículos por sinal, número de veículos aguardando, tempo de duração do sinal e velocidade média dos veículos, que foram essenciais para avaliar o comportamento dos semáforos e treinar a rede neural.

Os dados foram gerados em um formato já padronizado e estruturado, dispensando a necessidade de pré-processamento extenso. Todos os valores coletados foram diretamente preparados para uso na rede neural, sem etapas adicionais de limpeza ou correção de inconsistências, o que garantiu maior agilidade no desenvolvimento dos modelos e permitiu focar na análise e implementação das estratégias de controle adaptativo.

A coleta dos dados foi realizada de maneira automatizada, por meio de um módulo desenvolvido especificamente para este fim, que acumulava os valores ao longo dos ciclos da simulação e, ao término, salvava-os em arquivos CSV. Esses dados incluíam informações como o número de veículos que passaram pelo sinal, o tempo que cada sinal ficou verde, e a quantidade de veículos esperando em cada fase do ciclo do semáforo. Esses dados foram posteriormente utilizados para treinar um modelo de rede neural, capaz de prever o tempo ideal para cada sinal, visando melhorar o fluxo de tráfego.

Além disso, foi desenvolvido um modelo de rede neural utilizando a biblioteca *TensorFlow*, treinado com os dados coletados pela simulação para ajustar dinamicamente os tempos dos semáforos. O treinamento do modelo foi baseado nas informações registradas, como a quantidade de veículos aguardando, a taxa de entrada dos veículos, e o número de veículos que passaram por cada sinal. O objetivo foi criar um sistema de controle semafórico adaptativo, que respondesse eficientemente às condições de tráfego simuladas, reduzindo o tempo de espera e melhorando o fluxo geral dos veículos.

Diferentes cenários de tráfego foram modelados e simulados, variando as condições entre tráfego leve, moderado e intenso, para testar a robustez e a eficácia dos métodos de controle desenvolvidos. Esses cenários proporcionaram uma visão abrangente de como os semáforos adaptativos se comportariam em condições reais e extremas, ajudando a validar a eficácia da rede neural em ajustar os ciclos dos sinais conforme a demanda de tráfego variava ao longo do tempo.

Assim, o desenvolvimento metodológico deste trabalho consistiu em utilizar uma simulação de tráfego existente, adaptá-la para coleta e estruturação

automatizada de dados, e então usar esses dados para treinar um modelo de rede neural adaptativo. Esse modelo tem o potencial de melhorar significativamente a eficiência do controle semafórico e, conseqüentemente, o fluxo do tráfego urbano.

3.1 PREPARAÇÃO DOS DADOS

A preparação dos dados coletados durante a simulação de tráfego foi essencial para o treinamento eficaz da rede neural voltada ao controle adaptativo dos semáforos. Esse processo de coleta e estruturação dos dados foi realizado de forma automatizada, inicialmente usando tempos fixos de semáforo e módulos específicos para o armazenamento das informações em arquivos CSV. A Tabela 1 apresenta as variáveis coletadas durante o ciclo de simulação, detalhando os parâmetros essenciais que embasam o treinamento do modelo de controle:

Tabela 1: Variáveis Coletadas Durante a Simulação de Tráfego

Variável	Descrição
Taxa de Veículos	A quantidade de veículos entrando na interseção (número de veículos por unidade de tempo)
Veículos que Passaram	O número de veículos que passaram pelo semáforo durante o ciclo
Veículos Aguardando	O número de veículos aguardando no sinal vermelho
Veículos Aguardando no Próximo Sinal	Número de veículos aguardando no próximo sinal que ficará verde
Duração do Ciclo Semafórico	O tempo que o sinal de trânsito permaneceu verde no ciclo atual (em segundos)
Velocidade Média dos Veículos	A média das velocidades dos veículos em movimento durante o ciclo

Fonte: Autoria própria

De acordo com a Tabela 1, essas variáveis foram armazenadas em um formato tabular, com cada linha representando um ciclo de sinalização. A estrutura dos dados facilitou sua utilização direta para análise e posterior aplicação no treinamento do modelo de rede neural.

Com o objetivo de enriquecer os dados e fornecer ao modelo informações mais detalhadas sobre o comportamento do tráfego, foram criados atributos derivados com base nas variáveis coletadas. A Tabela 2 apresenta esses atributos

derivados, que foram calculados para capturar melhor as dinâmicas do sistema de controle semafórico.

Tabela 2: Atributos derivados criados a partir dos dados coletados

Variável	Descrição
Diferença no Número de Veículos Aguardando	Diferença entre o número de veículos esperando no sinal atual e no próximo sinal que ficará verde
Mudança na Taxa de Veículos	Variação na taxa de entrada de veículos entre ciclos consecutivos

Fonte: Autoria própria

De acordo com a Tabela 2, esses novos atributos forneceram ao modelo uma visão mais detalhada sobre as mudanças no fluxo de tráfego e sua relação com os estados dos sinais de trânsito. Eles foram essenciais para permitir que o modelo de rede neural capturasse padrões mais complexos de controle semafórico.

Para alimentar e treinar o modelo de controle adaptativo, os dados foram gerados automaticamente durante os ciclos da simulação e salvos em arquivos CSV. As taxas de veículos variaram de 50 a 90 veículos por minuto, abrangendo diferentes níveis de tráfego, desde baixa até alta demanda. As simulações abrangeram ciclos com durações variando entre 10 e 30 segundos, em conformidade com as diretrizes do DENATRAN que estabelecem que o ciclo total de um semáforo não pode ser inferior a 10 segundos nem superior a 120 segundos. Assim, para cada ciclo completo, cada fase do sinal (como o verde) pode ter uma duração máxima de 30 segundos (DENATRAN, 2013).

3.2 SIMULAÇÃO DE TRÁFEGO

A simulação de tráfego desempenhou um papel fundamental neste estudo, sendo utilizada para avaliar o desempenho de diferentes abordagens de controle semafórico adaptativo com o uso de redes neurais. A base da simulação foi o *Intelligent Driver Model (IDM)*, amplamente utilizado em pesquisas de tráfego devido à sua capacidade de modelar o comportamento dinâmico de veículos, considerando parâmetros como aceleração, velocidade máxima, tempo de reação e distâncias de segurança. O IDM foi responsável por simular o comportamento dos veículos ao

longo das vias, reproduzindo o fluxo de tráfego de forma realista e permitindo a análise de diferentes cenários de tráfego urbano.

Na simulação, cada veículo foi representado por meio de um conjunto de parâmetros que influenciam seu comportamento. Estes incluem:

Tabela 3: Parâmetros dos Veículos na Simulação de Tráfego

Variável	Valor/Configuração	Descrição
Aceleração Máxima	5 m/s ²	Define a aceleração máxima que o veículo pode atingir.
Velocidade Máxima	Variável, conforme o fluxo de veículos	Define a velocidade máxima que os veículos podem alcançar durante a simulação.
Distância Mínima de Segurança	Determinada com base no modelo IDM	Define a distância mínima que o veículo mantém em relação ao veículo da frente.
Desaceleração Máxima	50 m/s ²	Define a desaceleração máxima aplicada para simular frenagens bruscas.
Modelo de Controle	Ciclos fixos ou adaptativos dos semáforos	Indica como os sinais de trânsito foram controlados durante a simulação.

Fonte: Autoria própria

O controle semafórico pode ser implementado de duas maneiras distintas: por ciclos fixos ou ciclos adaptativos. No controle de ciclos fixos, as fases dos semáforos (verde e vermelho) alternam-se de forma pré-determinada, seguindo intervalos de tempo previamente estabelecidos, independentemente das condições de tráfego. Já o controle adaptativo ajusta dinamicamente a duração das fases de sinalização em tempo real, com base na quantidade de veículos presentes em cada interseção, buscando otimizar o fluxo de tráfego e reduzir o tempo de espera.

3.3 TREINAMENTO DO MODELO DE REDE NEURAL

O treinamento do modelo de rede neural foi desenvolvido utilizando os dados estruturados coletados durante a simulação de tráfego. Esses dados permitiram que o modelo aprendesse a prever a duração ideal dos sinais de trânsito, ajustando dinamicamente os tempos de sinalização conforme as condições do tráfego em tempo real. A seguir, detalham-se as principais etapas do treinamento.

3.3.1 DIVISÃO DOS DADOS E NORMALIZAÇÃO

Após a coleta dos dados e a criação dos atributos derivados, foi realizada a normalização, uma técnica fundamental para homogeneizar a magnitude das variáveis envolvidas na análise (HAYKIN, 2001). A normalização ajusta a distribuição dos dados dentro de uma amplitude específica, prevenindo que variáveis com magnitudes maiores tenham um peso desproporcional no processo de treinamento. Para essa etapa, utilizou-se o MinMaxScaler, que ajustou os valores para o intervalo entre 0 e 1. Todas as variáveis de entrada (como Taxa de Veículos e Veículos Aguardando) e a variável de saída (Duração do Ciclo Semafórico) passaram por esse procedimento.

Além da normalização, os dados foram particionados em 80% para treinamento e 20% para teste, prática comum em aprendizado de máquina que permite avaliar o desempenho do modelo em dados não vistos. Essa abordagem garante que o modelo aprenda padrões durante o treinamento e valide sua capacidade de generalização, minimizando o risco de overfitting. O overfitting ocorre quando o modelo se ajusta excessivamente aos dados de treinamento, perdendo a capacidade de generalizar para novos cenários (COSTA, 2024).

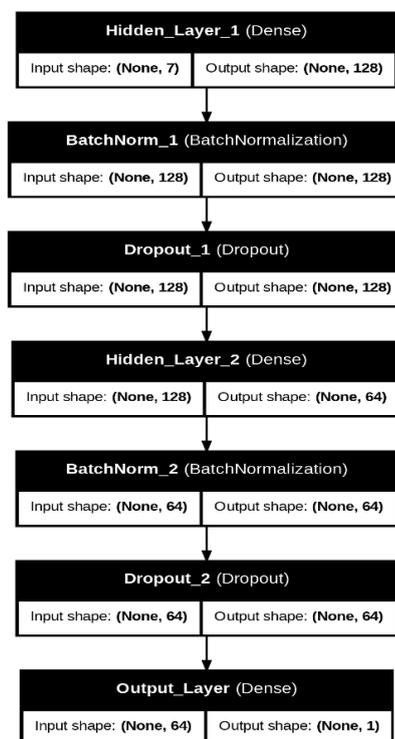
Os escaladores de normalização gerados durante o treinamento foram salvos em arquivos, permitindo sua aplicação posterior na fase de previsão, o que assegura consistência no processamento dos dados. Esse procedimento é essencial para que os dados utilizados na simulação sejam tratados da mesma maneira que os dados usados no treinamento, mantendo a acurácia e a confiabilidade das previsões ao ajustar os tempos dos ciclos semafóricos. A normalização é especialmente importante no caso das redes neurais, pois previne que variáveis com escalas diferentes prejudiquem o processo de aprendizado, evitando convergência lenta e previsões imprecisas.

3.3.2 ESTRUTURA E CONFIGURAÇÃO DO MODELO

O modelo de rede neural foi desenvolvido utilizando a biblioteca TensorFlow, conhecida por sua robustez no treinamento de modelos de aprendizado profundo. A arquitetura foi projetada para identificar padrões complexos nos dados de tráfego e prever, de forma precisa, a duração ideal dos ciclos de sinalização. A Figura 2 apresenta a arquitetura da rede neural utilizada no estudo, destacando as principais

camadas que compõem sua estrutura.

Figura 2: Arquitetura da Rede Neural



Fonte: Autoria própria

De acordo com a Figura 2, a arquitetura da rede neural foi configurada para possibilitar ajustes automáticos nos tempos dos semáforos em resposta às condições de tráfego em tempo real. Essa estrutura utiliza técnicas e componentes essenciais para lidar com a complexidade dos dados, descritos na Tabela 4.

A Tabela 4 detalha os principais componentes da arquitetura da rede neural, explicando suas funções e como cada técnica contribui para o desempenho do modelo:

Tabela 4: Principais Componentes da Arquitetura da Rede Neural

Componente	Descrição
Camadas Densas com ReLU	Cada camada densa é conectada a todas as unidades da camada anterior. A função de ativação <i>ReLU</i> (<i>Rectified Linear Unit</i>) introduz não linearidade no modelo, permitindo capturar padrões complexos nos dados. As múltiplas camadas ocultas ajudam o modelo a aprender relações mais profundas entre as variáveis.
Batch Normalization	A técnica de <i>Batch Normalization</i> normaliza as ativações da rede durante o treinamento. Isso acelera o processo de convergência e estabiliza o aprendizado, sendo especialmente útil em redes neurais mais complexas, onde o ajuste fino dos parâmetros pode ser difícil.

Dropout

A técnica de *Dropout* desativa aleatoriamente uma fração dos neurônios em cada etapa de atualização dos pesos. Essa técnica é essencial para evitar o *overfitting*, melhorando a capacidade do modelo de generalizar para novos dados.

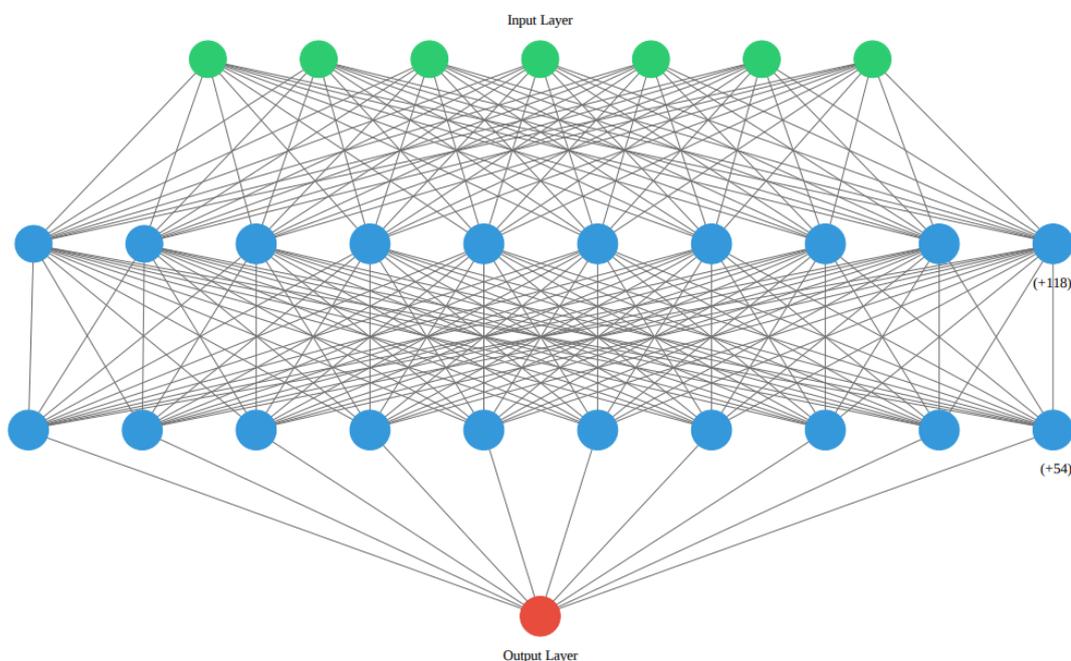
Fonte: Autoria própria

De acordo com a Tabela 4, a arquitetura foi construída com técnicas modernas, como camadas densas ativadas por *ReLU*, normalização de lote (*Batch Normalization*), e regularização por *Dropout*. Esses elementos foram projetados para garantir que o modelo aprenda padrões complexos e seja capaz de generalizar bem para diferentes condições de tráfego.

A camada de saída da rede, conforme mostrado na Figura 2, foi configurada para retornar um único valor, que representa a duração do ciclo semafórico em segundos. Essa configuração simplificada da camada final é fundamental para garantir que as previsões possam ser diretamente aplicadas à simulação.

A Figura 3 apresenta a estrutura visual detalhada da rede neural, mostrando como as camadas estão organizadas e conectadas.

Figura 3: Estrutura Visual da Rede Neural



Fonte: Autoria própria

De acordo com a Figura 3, é possível visualizar como as camadas estão dispostas, desde a entrada dos dados coletados durante a simulação, passando pelas camadas intermediárias (ocultas) responsáveis pelo aprendizado profundo, até

a camada de saída, que retorna o valor preditivo:

- **Otimizador Adam:** Uma das escolhas mais populares para modelos de aprendizado profundo, o otimizador *Adam* ajusta dinamicamente a taxa de aprendizado, permitindo uma convergência mais eficiente.
- **Função de perda *Mean Squared Error (MSE)*:** A função de perda MSE mede a média dos erros quadráticos entre as previsões do modelo e os valores reais, dando mais peso a erros maiores. Isso incentiva o modelo a ajustar melhor as previsões com grandes discrepâncias.

As métricas de avaliação utilizadas incluem:

- **Erro Absoluto Médio (MAE):** Mede a média das diferenças absolutas entre as previsões e os valores reais.
- **Erro Quadrático Médio (MSE):** Avalia a magnitude dos erros, com maior penalização para desvios maiores.

3.3.3 TREINAMENTO E MONITORAMENTO

O treinamento do modelo foi realizado ao longo de 100 épocas, com um tamanho de lote (batch) de 32, o que permitiu que o modelo ajustasse seus pesos de forma gradual e eficiente. A cada época, os dados eram alimentados à rede, que por sua vez ajustava seus pesos para minimizar a função de perda. Esse processo de aprendizado é fundamental para que o modelo reconheça padrões nos dados de tráfego e faça previsões precisas da duração dos sinais.

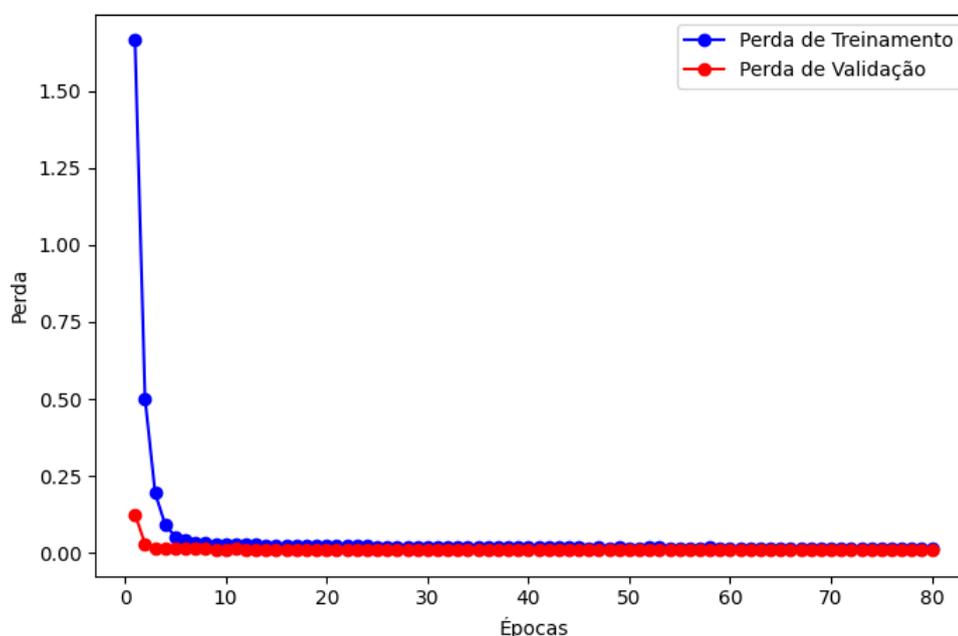
Para garantir que o modelo fosse robusto e evitasse o overfitting, duas técnicas de monitoramento (callbacks) foram utilizadas durante o treinamento:

- **Early Stopping:** Essa técnica interrompe automaticamente o treinamento quando a perda na validação não apresenta melhora após 10 épocas consecutivas. Isso impede que o modelo seja treinado além do necessário, prevenindo o ajuste excessivo aos dados de treinamento.
- **TensorBoard:** Uma ferramenta poderosa que permite monitorar as

métricas de treinamento em tempo real, como a perda de validação e a precisão. O uso do *TensorBoard* é essencial para identificar problemas de ajuste no modelo durante o treinamento e fazer ajustes apropriados.

A evolução da perda (loss) ao longo das épocas, tanto para os dados de treinamento quanto para os de validação, diminuiu rapidamente e estabilizou em um ponto, indicando que o modelo convergiu bem sem sinais significativos de overfitting. A Figura 4 apresenta a curva de evolução da perda durante o treinamento e a validação, evidenciando esse comportamento.

Figura 4: Evolução da Perda durante o Treinamento



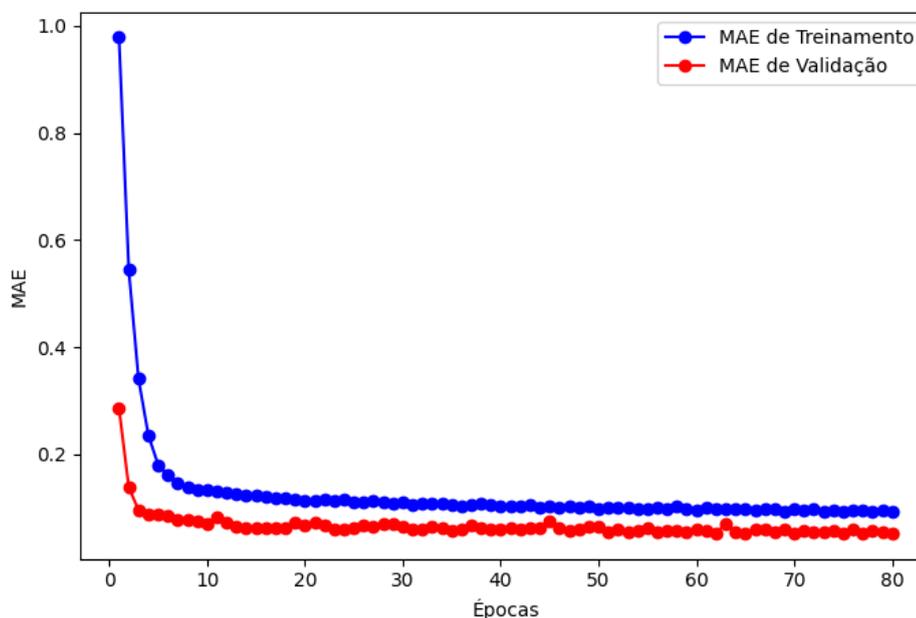
Fonte: Autoria própria

De acordo com a Figura 4, a perda no treinamento e na validação apresenta um declínio inicial acentuado, seguido por uma estabilização em níveis baixos, o que sugere que o modelo alcançou boa convergência. Esse comportamento é um indicador positivo, pois demonstra que o modelo conseguiu aprender os padrões nos dados sem sobreajustar às particularidades do conjunto de treinamento.

De forma semelhante, o erro absoluto médio (*Mean Absolute Error, MAE*) ao longo das épocas também apresentou uma tendência de estabilização, reforçando que o modelo atingiu um ponto ótimo de desempenho ao prever a duração dos sinais de trânsito. A Figura 5 ilustra a evolução do MAE durante o treinamento e

validação, permitindo uma análise complementar.

Figura 5: Evolução do Erro Absoluto Médio durante o Treinamento



Fonte: Autoria própria

De acordo com a Figura 5, o MAE segue uma tendência similar à da perda, apresentando redução inicial significativa e estabilização nas épocas subsequentes. Essa estabilidade confirma que o modelo é consistente em prever a duração dos ciclos semafóricos, tanto no treinamento quanto na validação.

Ao final do processo, o modelo foi salvo em um formato reutilizável, permitindo sua aplicação direta na fase de simulação, sem a necessidade de novo treinamento. Isso economiza tempo e garante que o modelo já treinado possa ser empregado de forma eficiente.

3.3.4 AVALIAÇÃO E PREVISÃO

Após o treinamento, o modelo foi avaliado utilizando o conjunto de teste, que inclui dados não utilizados no treinamento. Essa avaliação é fundamental para verificar a capacidade do modelo de generalizar para novos dados e garantir que suas previsões sejam precisas. As métricas utilizadas para essa avaliação foram:

- **Erro Absoluto Médio (MAE):** O MAE é uma medida da diferença média entre as previsões do modelo e os valores reais, fornecendo uma avaliação clara de quão próximo o modelo está de prever o tempo

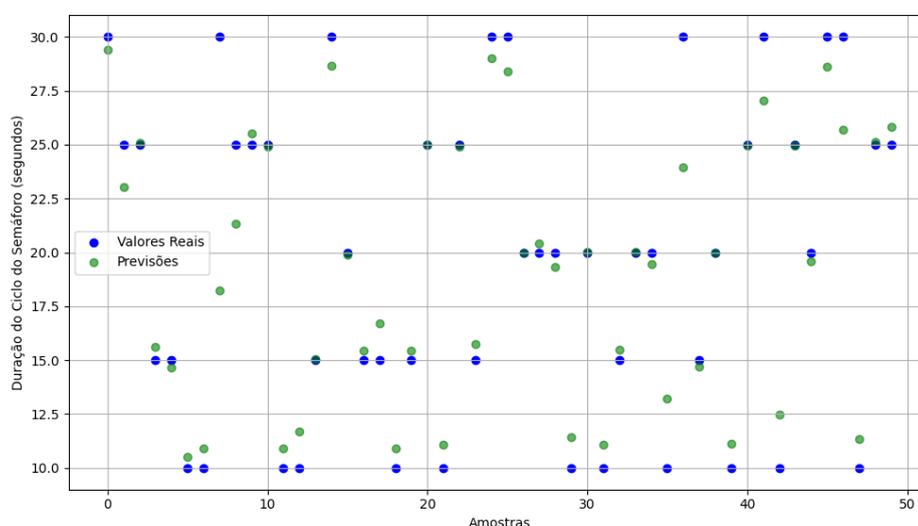
correto dos sinais.

- **Erro Quadrático Médio (MSE):** O MSE dá mais peso a erros maiores, o que é útil para identificar previsões que apresentem grandes desvios em relação aos valores reais.

As previsões realizadas pelo modelo foram convertidas de volta à sua escala original usando os escaladores salvos anteriormente e, em seguida, limitadas entre 10 e 30 segundos, em conformidade com as diretrizes regulamentares para ciclos semafóricos. Isso assegura que as previsões do modelo respeitem os parâmetros de segurança e eficiência, mantendo o fluxo de veículos sob controle.

Para avaliar a precisão das previsões do modelo, foi gerado um gráfico de dispersão que compara os valores previstos pelo modelo com os valores reais para uma amostra de 50 ciclos semafóricos. A Figura 6 apresenta essa análise gráfica, onde é possível observar a relação entre as previsões do modelo e os valores reais.

Figura 6: Comparação entre Valores Reais e Previsões (50 ciclos)



Fonte: Autoria própria

De acordo com a Figura 6, os pontos azuis representam os valores reais de duração dos ciclos semafóricos, enquanto os pontos verdes correspondem às previsões feitas pelo modelo. A proximidade entre os pontos das duas cores indica que o modelo apresentou alta precisão na maioria dos ciclos avaliados.

A análise dessa amostra revela que, para a maioria dos ciclos, as previsões do modelo foram bastante próximas dos valores reais. Nos poucos casos em que ocorreram desvios mais significativos, esses ainda se mantiveram dentro de limites aceitáveis, sugerindo que o modelo é robusto e confiável. Esse desempenho reforça a aplicabilidade do modelo em cenários de tráfego reais, onde a previsão precisa da duração dos ciclos semafóricos é crucial para uma gestão eficiente.

3.4 IMPLEMENTAÇÃO DA REDE NEURAL NA SIMULAÇÃO

A implementação da rede neural na simulação de tráfego foi projetada para permitir o ajuste dinâmico e adaptativo dos ciclos de sinalização, melhorando o fluxo veicular em tempo real. Essa integração é o ponto central deste estudo, pois demonstra a aplicabilidade prática das redes neurais no controle semafórico urbano. Nesta seção, serão abordadas as etapas de implementação e o funcionamento do modelo dentro da simulação.

3.4.1 INICIALIZAÇÃO E CARREGAMENTO DO MODELO

Na fase de inicialização da simulação, o modelo de rede neural é carregado a partir de um arquivo de armazenamento. Neste estudo, esse arquivo contém a estrutura da rede neural, os pesos ajustados durante o treinamento e as configurações otimizadas para as previsões dos ciclos semafóricos.

Além do modelo de rede neural, também são carregados os escaladores de normalização, que foram previamente ajustados durante o treinamento para garantir a consistência no processamento dos dados de entrada. Esses escaladores transformam os dados coletados em valores normalizados, garantindo que o modelo opere com dados na mesma escala que foi treinado, o que é essencial para a precisão das previsões.

Essa fase de carregamento é fundamental para que o sistema inicie a previsão das durações dos ciclos de sinal logo nos primeiros ciclos da simulação, permitindo que o processo de controle adaptativo comece de maneira consistente e eficiente.

3.4.2 PROCESSAMENTO DOS DADOS E PREVISÃO DE CICLOS

Durante a execução da simulação, a rede neural utiliza as variáveis de

entrada previamente definidas (Tabela 1) para prever a duração ideal do próximo ciclo de sinal. Após o processamento, o modelo ajusta dinamicamente a duração do ciclo dentro dos limites regulamentares (10 a 30 segundos), otimizando o fluxo de veículos em tempo real. Dessa forma, o sistema adapta continuamente a duração do sinal verde para cada interseção, reduzindo o tempo de espera e melhorando a fluidez do tráfego.

3.4.3 VANTAGENS DO CONTROLE ADAPTATIVO

A integração do modelo de rede neural na simulação apresenta diversas vantagens em relação aos sistemas tradicionais de controle de semáforos com ciclos fixos. A Tabela 5 detalha as principais vantagens do controle adaptativo utilizando a rede neural, destacando os benefícios que podem ser alcançados em cenários reais de tráfego.

Tabela 5: Vantagens do Controle Adaptativo com Rede Neural

Componente	Descrição
Adaptação em Tempo Real	O modelo é capaz de ajustar as durações dos sinais de acordo com o fluxo de tráfego, o que resulta em uma resposta mais eficiente às variações do tráfego, como congestionamentos ou momentos de tráfego mais leve.
Redução do Tempo de Espera	Ao ajustar a duração dos ciclos de sinal com base na demanda, a rede neural consegue minimizar o tempo de espera dos veículos nas interseções, melhorando a fluidez do tráfego.
Maior Eficiência	O modelo é capaz de identificar padrões complexos de tráfego e ajustar os ciclos de sinalização de forma mais precisa do que métodos fixos.

Fonte: Autoria própria

De acordo com a Tabela 5, o uso de um modelo de rede neural para controle semaforico adaptativo permite ajustes em tempo real, o que é uma vantagem significativa em comparação aos métodos tradicionais. A capacidade de adaptação ajuda a responder a variações no fluxo de tráfego, como congestionamentos repentinos ou períodos de menor movimentação, garantindo que os tempos de sinalização sejam otimizados.

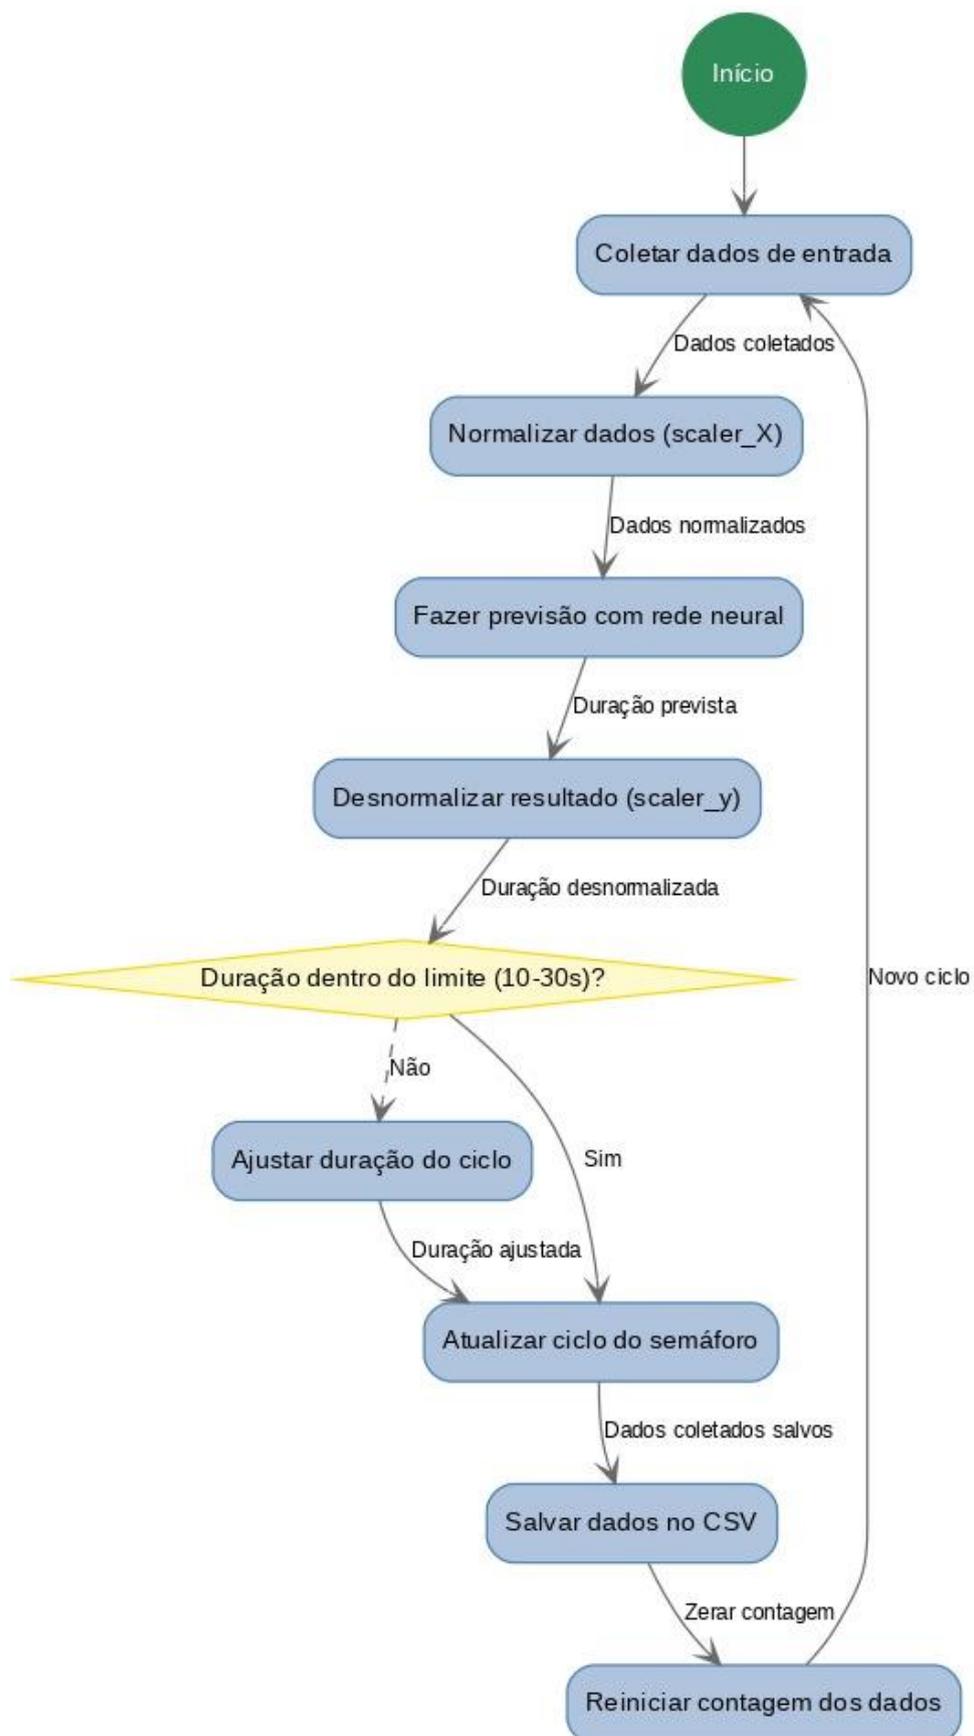
Além disso, a redução do tempo de espera nos semáforos, um dos principais benefícios observados, contribui para a melhoria da fluidez do tráfego e para a redução de emissões de gases devido ao menor tempo de veículos parados. Por fim, a eficiência geral do sistema é ampliada pela habilidade do modelo de reconhecer padrões complexos e aplicar ajustes precisos nos tempos dos

semáforos.

3.4.4 FLUXO DE CONTROLE DO MODELO ADAPTATIVO

O processo de controle adaptativo de semáforos utilizando o modelo de rede neural é composto por diversas etapas que asseguram a eficiência e a precisão do sistema. A Figura 7 ilustra o fluxo de dados nesse processo, desde a coleta e normalização das informações de tráfego até a previsão dos tempos ideais, o ajuste dos semáforos e o reinício do ciclo de controle.

Figura 7: Fluxo de Controle do Modelo de Rede Neural Adaptativo



Fonte: Autoria própria

De acordo com a Figura 7, o fluxo começa com a coleta de dados em tempo real sobre o tráfego, como número de veículos e tempos de espera. Esses dados são então normalizados para adequação ao modelo de rede neural. Após a normalização, o modelo realiza a previsão da duração ideal dos ciclos semafóricos, com base nos padrões identificados nos dados.

Com as previsões feitas, o sistema ajusta automaticamente os tempos dos semáforos, garantindo maior fluidez e menor tempo de espera nas interseções. Ao término de cada ciclo, o processo é reiniciado, permitindo que o sistema continue a se adaptar dinamicamente às condições do tráfego em tempo real.

4. RESULTADOS E DISCUSSÃO

4.1 APRESENTAÇÃO DOS RESULTADOS

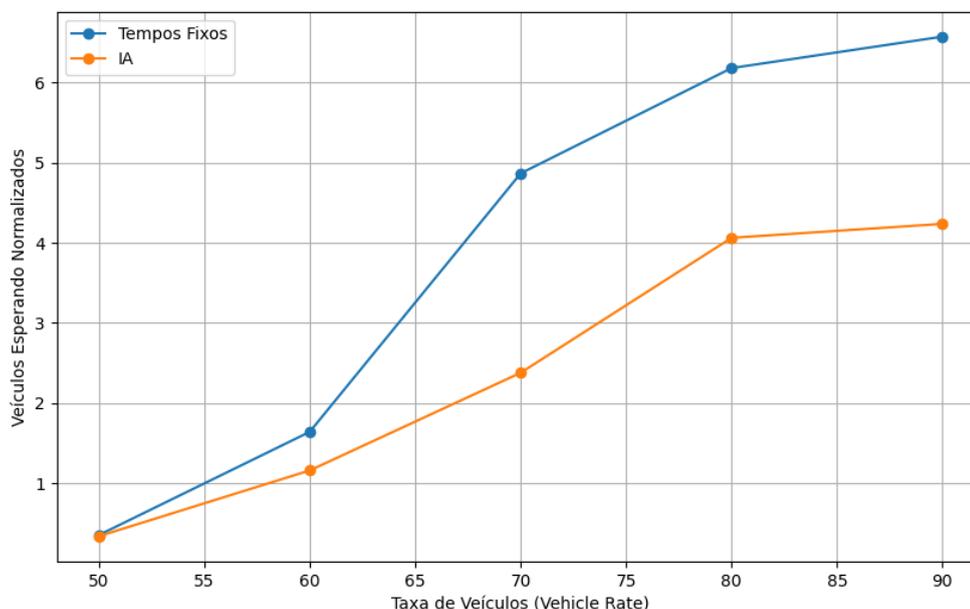
Para uma análise mais clara a métrica de veículos passados foi ajustada de acordo com a duração do ciclo de sinal, indicando a quantidade de veículos que passam por unidade de tempo, o que possibilita uma comparação justa entre as diferentes estratégias de controle. Já a média de veículos esperando não foi normalizada, pois reflete diretamente o número de veículos parados, independentemente do tempo de operação do sinal, sendo mais informativa em sua forma original.

Essas normalizações foram fundamentais para garantir comparações justas entre os dois tipos de controle, considerando a variação de duração dos ciclos de sinal. Os gráficos resultantes ilustram de forma clara as diferenças de desempenho entre o controle semafórico fixo e o controle adaptativo baseado em IA.

4.1.1 MÉDIA DE VEÍCULOS ESPERANDO

O primeiro aspecto a ser analisado é a média de veículos que ficaram esperando em diferentes interseções de semáforos sob cada um dos dois tipos de controle. Para entender o impacto das estratégias de controle sobre o acúmulo de veículos nas interseções, foi considerada a média de veículos aguardando para cruzar a interseção de 50 a 90 veículos por minuto, taxas que foram previamente definidas.

Figura 8: Comparação da Média de Veículos Esperando



Fonte: Autoria própria

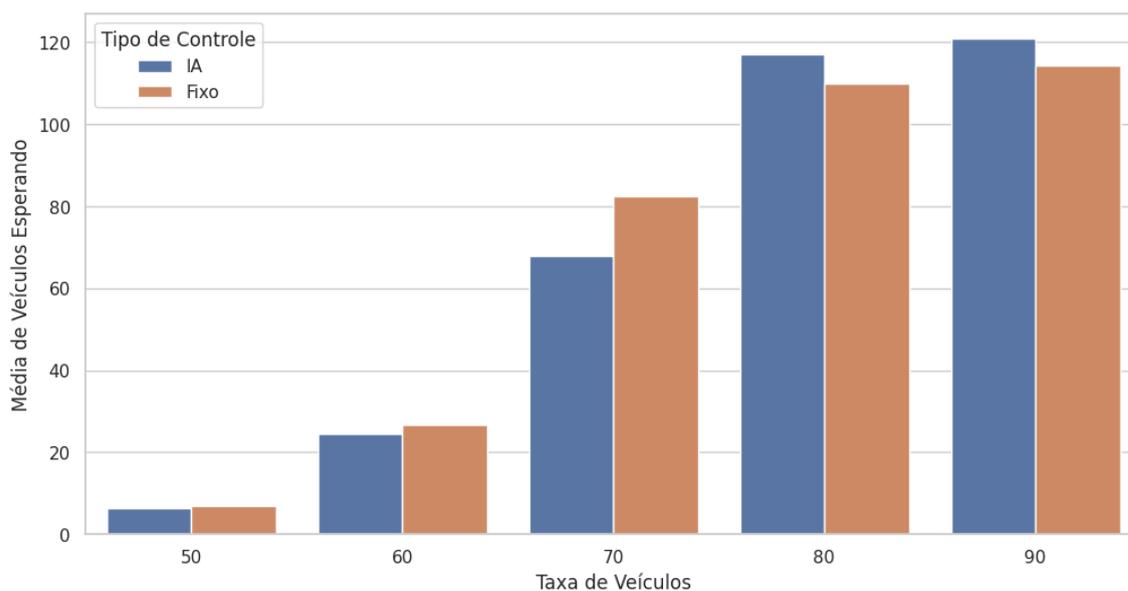
Na Figura 8, que apresenta a comparação entre a média de veículos esperando para cada tipo de controle ao longo das diferentes taxas de veículos, pode-se observar uma tendência clara de divergência entre os dois métodos, especialmente à medida que a intensidade do tráfego aumenta. Inicialmente, com uma taxa de veículos de 50 a 60 por unidade de tempo, ambos os tipos de controle apresentam desempenho semelhante, com uma média relativamente baixa de veículos esperando. Esse resultado indica que, em condições de tráfego leve, a capacidade de ambos os métodos de gerenciar o fluxo de veículos é quase equivalente, já que o volume não atinge um ponto crítico que exija adaptações mais complexas.

No entanto, quando a taxa de veículos passa de 60 por unidade de tempo, percebe-se que o controle baseado em IA começa a demonstrar uma vantagem considerável, com um aumento consistente no número de veículos passados. Em contraste, o controle de tempos fixos atinge um patamar e se mantém constante, sugerindo uma limitação na capacidade de lidar com o aumento da demanda. Esse comportamento demonstra que a IA é capaz de ajustar os tempos de sinalização de maneira mais eficaz, aumentando o fluxo de veículos à medida que a demanda cresce.

Este padrão se mantém em taxas de 80 e 90 veículos, onde o controle

baseado em IA apresenta um número maior de veículos passados em comparação ao controle fixo, refletindo a eficácia do controle adaptativo em cenários de tráfego intenso, enquanto o controle fixo demonstra limitações claras na capacidade de adaptação ao aumento da demanda.

Figura 9: Comparação da Média de Veículos Esperando Detalhada



Fonte: Autoria própria

A Figura 9 apresenta a média de veículos esperando normalizados para cada tipo de controle ao longo das diferentes taxas de veículos, utilizando um gráfico de barras que ilustra a quantidade de veículos aguardando para o controle fixo e o controle baseado em IA. Neste gráfico, observa-se claramente que o controle fixo apresenta uma média de veículos esperando consistentemente mais alta em todas as taxas de veículos simuladas, com uma diferença mais acentuada a partir de 70 veículos por unidade de tempo.

Enquanto o controle fixo tem um aumento significativo na média de veículos esperando à medida que a taxa de veículos aumenta, o controle adaptativo baseado em IA mantém um crescimento mais moderado, demonstrando uma gestão mais eficaz e uniforme do fluxo de tráfego, mesmo em condições de alta demanda. Esse comportamento sugere que a IA consegue adaptar os tempos dos sinais de forma a minimizar o acúmulo de veículos, especialmente em cenários de tráfego intenso.

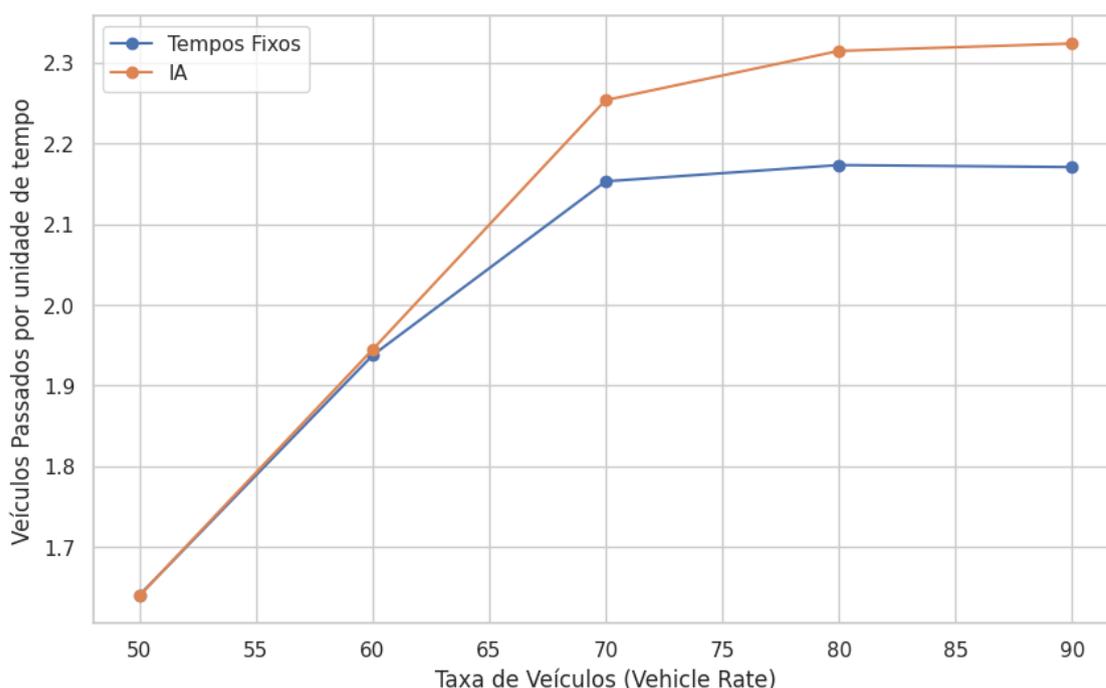
A diferença mais pronunciada entre os dois métodos ocorre nas taxas de 80

e 90 veículos, onde o controle fixo atinge níveis muito mais elevados de veículos esperando, enquanto a IA mostra uma capacidade superior de gerenciar o congestionamento, resultando em uma redução significativa no tempo de espera dos veículos nas interseções.

4.1.2 VEÍCULOS PASSADOS

A segunda métrica analisada foi a quantidade de veículos que conseguiram cruzar as interseções, representada de forma normalizada para facilitar a comparação entre os dois métodos de controle. A normalização dos dados permite que as diferenças sejam observadas de forma mais clara, destacando a eficácia de cada método em aumentar o fluxo de veículos durante os diferentes cenários de simulação.

Figura 10: Comparação de Veículos Passados



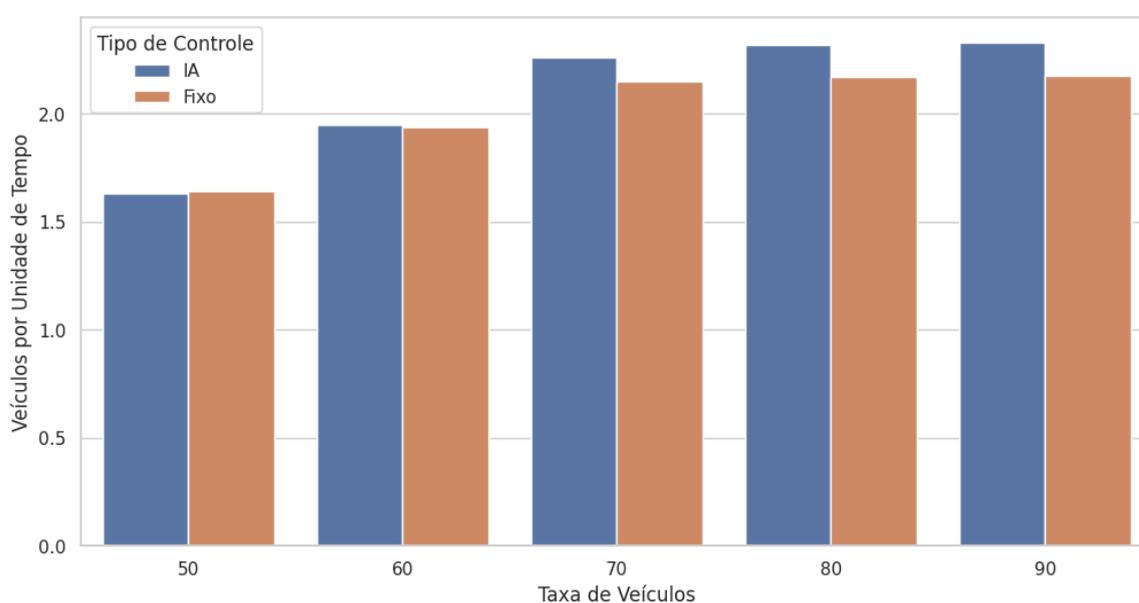
Fonte: Autoria própria

A Figura 10 mostra o número de veículos que passaram pelos semáforos em diferentes taxas de veículos, comparando o desempenho entre o controle fixo e o controle adaptativo com IA. Neste gráfico, é possível perceber que, à medida que a taxa de veículos aumenta, o controle adaptativo apresenta uma maior quantidade de veículos que cruzam a interseção. Isso é particularmente evidente nas taxas de 70 a 90 veículos por unidade de tempo, onde o controle fixo apresenta uma estabilidade

no fluxo de veículos passados, enquanto o controle com IA continua a aumentar o número de veículos que atravessam o semáforo.

Este resultado confirma a capacidade da IA de ajustar dinamicamente os tempos de sinal verde para otimizar o fluxo, mesmo em condições de tráfego intenso. A linha de tendência mais acentuada do controle adaptativo reflete sua habilidade de aumentar a capacidade da interseção, permitindo que mais veículos atravessem a cada ciclo semafórico.

Figura 11: Comparação de Veículos Passados Detalhada



Fonte: Autoria própria

A figura 11 é um gráfico de barras que ilustra o número médio de veículos que cruzaram as interseções por unidade de tempo para cada tipo de controle. Este gráfico oferece uma visão direta da quantidade de veículos processados pelo sistema em cada cenário de simulação, permitindo uma análise mais clara das diferenças entre os métodos de controle.

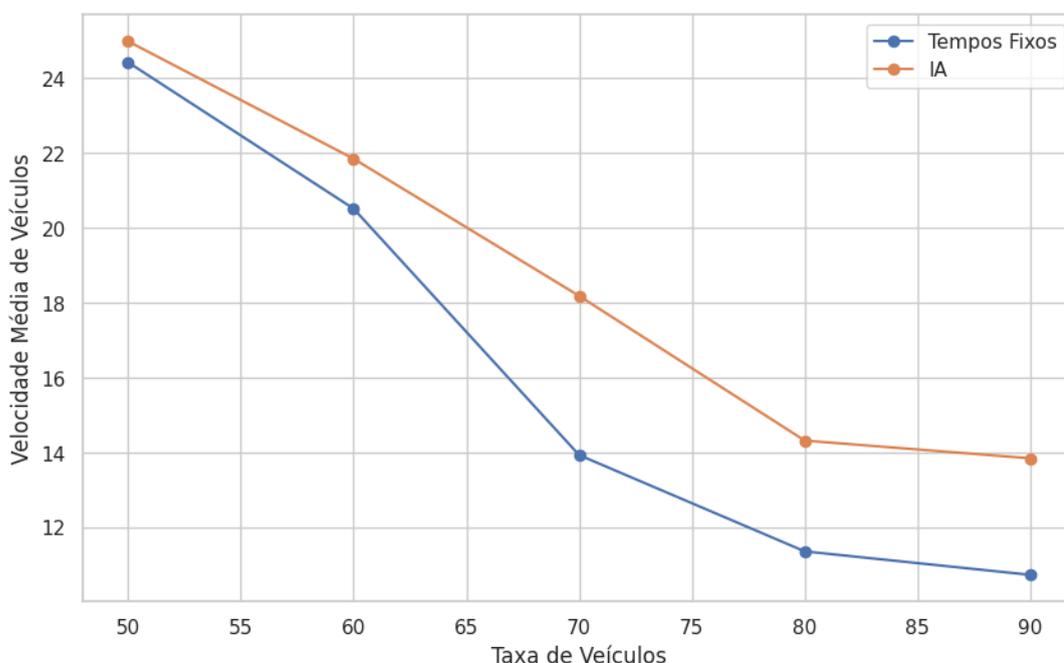
Os resultados mostrados no gráfico indicam que o controle adaptativo com IA consegue processar mais veículos em todas as taxas de tráfego simuladas, com destaque para as taxas mais altas. Enquanto o controle fixo apresenta um aumento mais gradual no número de veículos passados, a IA consegue aumentar esse número de forma mais expressiva, especialmente nas taxas de 80 e 90 veículos por

unidade de tempo.

4.1.3 VELOCIDADE MÉDIA

A terceira métrica analisada foi a velocidade média dos veículos ao atravessarem as interseções, que oferece uma visão clara sobre a fluidez do tráfego sob os diferentes métodos de controle. A comparação entre o controle fixo e o adaptativo com IA revela o impacto de cada método em manter a velocidade dos veículos, especialmente em cenários de alta densidade de tráfego.

Figura 12: Comparação de Velocidade Média de Veículos



Fonte: Autoria própria

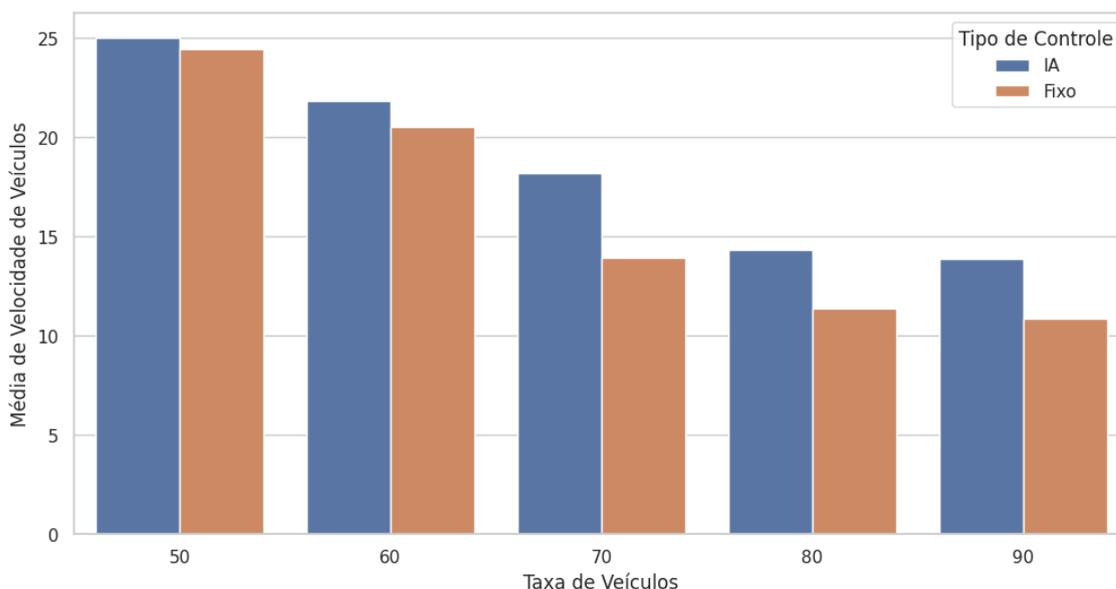
Na Figura 12, observa-se que, conforme a taxa de veículos aumenta de 50 a 90 veículos por unidade de tempo, a velocidade média dos veículos tende a diminuir em ambos os métodos de controle. No entanto, o controle adaptativo com IA consegue manter uma velocidade média mais alta em comparação com o controle fixo. Este efeito é mais notável nas taxas de veículos mais elevadas (80 e 90 veículos por unidade de tempo), onde o controle fixo apresenta uma queda mais acentuada na velocidade média, enquanto o controle adaptativo com IA mantém uma redução mais gradual.

Esse comportamento sugere que a IA é capaz de ajustar dinamicamente os tempos de sinal verde, permitindo um fluxo mais constante de veículos e reduzindo a necessidade de paradas e retomadas frequentes, que impactam negativamente na velocidade média. Em contrapartida, o controle fixo não se adapta às condições variáveis do tráfego, resultando em uma queda mais abrupta na velocidade média dos veículos em condições de maior congestionamento.

A Figura 13 apresenta uma análise detalhada em formato de barras da velocidade média dos veículos por tipo de controle para cada cenário de simulação. Essa visualização permite observar as diferenças específicas entre o desempenho dos métodos de controle em cada taxa de veículos, reforçando que o controle adaptativo com IA proporciona uma velocidade média consistentemente superior, especialmente nos cenários de tráfego intenso.

Os resultados indicam que o controle adaptativo com IA não apenas otimiza o fluxo de veículos, mas também melhora a fluidez do tráfego ao manter uma velocidade média mais elevada. Essa vantagem é crítica para cenários urbanos de alta densidade, onde a capacidade de adaptar os tempos de sinal pode reduzir os atrasos e melhorar a experiência de mobilidade.

Figura 13: Comparação de Velocidade Média de Veículos Detalhado



Fonte: Autoria própria

4.2 LIMITAÇÕES E PONTOS FORTES DA SIMULAÇÃO

A simulação de tráfego desenvolvida para este trabalho apresenta alguns pontos fortes importantes, como a possibilidade de modelar uma variedade de rotas, ajustar a taxa de veículos e utilizar algoritmos adaptativos para a sinalização de trânsito, que permitem testar o modelo sem a necessidade de experimentos no mundo real. No entanto, essa implementação possui algumas limitações, que restringem sua capacidade de refletir com precisão as dinâmicas complexas do tráfego urbano.

Dentre os pontos fortes podemos citar:

- **Flexibilidade na Configuração de Estradas e Rotas:** A simulação permite a criação de várias rotas e interseções com diferentes configurações de tráfego. Essa flexibilidade é essencial para ajustar e testar o algoritmo de controle de tráfego em uma variedade de cenários sem a necessidade de intervenção física ou testes no ambiente real. Isso representa uma vantagem significativa em termos de custos e segurança.
- **Controle Adaptativo da Sinalização:** A implementação utiliza um modelo de redes neurais treinado para prever a duração dos ciclos semaforicos com base no volume de tráfego e na quantidade de veículos aguardando. Essa abordagem permite ajustar os ciclos dos sinais em tempo real, refletindo condições dinâmicas do tráfego e aprimorando a fluidez, especialmente em momentos de alta demanda. Além disso, o armazenamento de dados detalhados e a capacidade de salvar essas informações em um arquivo CSV para posterior análise facilita a revisão e o aprimoramento contínuo do algoritmo.

Podemos citar de limitações e Pontos de Melhoria para o sistema:

- **Ausência de Modelagem de Pedestres e Ciclistas:** A simulação atual considera apenas veículos automotores, o que limita a representação do ambiente urbano, onde a presença de pedestres e ciclistas pode impactar significativamente o fluxo e a sinalização. Para uma simulação mais completa, seria importante incluir a possibilidade

de modelar trajetos para pedestres e ciclistas, assim como configurar sinais específicos para pedestres em cruzamentos. Isso permitiria estudar o impacto de pedestres no tempo de sinalização e nas pausas necessárias para garantir a segurança.

- **Falta de Interação com Variáveis Climáticas e Ambientais:** A simulação não incorpora variáveis climáticas, como chuva ou neblina, que podem alterar o comportamento dos motoristas e a velocidade média dos veículos. Condições adversas frequentemente levam a uma redução nas velocidades e a maior cuidado na circulação, o que impacta o tempo ideal dos ciclos semaforicos. A introdução de parâmetros ambientais poderia enriquecer a simulação, permitindo que o modelo adaptasse as durações dos sinais em função do clima, além de ajustar a velocidade máxima dos veículos para refletir cenários de baixa visibilidade.
- **Ausência de Veículos de Emergência e Transporte Público:** A simulação carece de uma modelagem para veículos de emergência e de transporte público, que frequentemente necessitam de prioridade nas vias. Incluir a simulação de veículos como ambulâncias e ônibus permitiria ao sistema simular condições reais onde esses veículos recebem prioridade de sinalização, essencial para reduzir o tempo de resposta em emergências e melhorar a eficiência do transporte público.
- **Simulação de Comportamento dos Motoristas:** O modelo atual assume um comportamento padrão para todos os motoristas, o que pode simplificar demais a simulação, ignorando variações reais como mudanças de faixa e velocidade. Adicionar diferentes perfis de motoristas, simulando características como motoristas mais cautelosos ou mais apressados, poderia melhorar a representatividade do fluxo de tráfego simulado.

Com base nos pontos fortes e nas limitações apontados, é possível concluir que a simulação de tráfego desenvolvida oferece uma base sólida para estudos de controle de tráfego adaptativo, trazendo benefícios significativos em termos de flexibilidade e controle dos ciclos semaforicos. A capacidade de modelar diferentes

rotas e configurações de interseções, aliada ao uso de redes neurais para a previsão e ajuste dos tempos de sinalização, representa um avanço na pesquisa de soluções para o trânsito urbano, contribuindo para a criação de modelos que refletem a realidade de maneira prática e segura.

No entanto, a ausência dos elementos adicionais citados pode acabar limitando a precisão da simulação em capturar todas as variáveis presentes em ambientes urbanos complexos. Essas limitações sugerem a necessidade de aperfeiçoamentos que permitam à simulação refletir melhor as nuances de um sistema de tráfego real, proporcionando insights mais amplos para o desenvolvimento de algoritmos de controle semafórico mais robustos e eficazes.

A integração de perfis de comportamento variados para os motoristas e a incorporação de variáveis ambientais e de transporte público, por exemplo, tornariam a simulação mais realista e útil para prever situações de tráfego complexas. Esses avanços enriqueceriam a plataforma como uma ferramenta completa de experimentação e inovação, com potencial para apoiar o desenvolvimento de sistemas de controle de tráfego mais adaptáveis, eficientes e seguros, preparados para responder a um ambiente urbano em constante transformação.

4.3 DIFICULDADES NA IMPLEMENTAÇÃO NO MUNDO REAL

A implementação de sistemas inteligentes de controle de tráfego enfrenta diversos desafios, que vão desde a necessidade de infraestrutura avançada até questões de adaptação social e técnica. Um dos principais entraves é o custo elevado para modernizar os sistemas de sinalização já existentes, que podem durar até 30 anos quando bem conservados. Esse fator prolonga a permanência de sistemas tradicionais, pois a substituição completa por dispositivos inteligentes conectados é uma tarefa onerosa e que demanda planejamento de longo prazo (INTELLIAS, 2024).

Além disso, a adaptação dos sistemas de tráfego inteligentes exige uma infraestrutura tecnológica robusta e integrada. Sensores de IoT, câmeras de alta resolução e dispositivos de conectividade, como módulos *Wi-Fi*, *4G/5G* e sistemas de comunicação veicular (*V2X*), precisam ser instalados em cada unidade de sinalização. Estes dispositivos devem coletar dados em tempo real sobre o fluxo de

veículos, condições climáticas e até mesmo sobre a presença de pedestres e ciclistas. Esse conjunto de sensores requer uma plataforma de gerenciamento de tráfego baseada em nuvem para processar e armazenar as informações, o que representa um desafio tanto em termos de segurança quanto de integridade dos dados (INTELLIAS, 2024).

Outro desafio significativo na implementação de sistemas de tráfego inteligentes reside no desenvolvimento e treinamento de algoritmos de aprendizado de máquina e modelos preditivos capazes de adaptar-se em tempo real às condições variáveis do trânsito. Esses algoritmos, como o que foi proposto neste trabalho, desempenham um papel essencial na resposta adaptativa dos semáforos, ajustando os tempos de sinalização com base em variáveis como o fluxo de veículos, a presença de pedestres e até as condições climáticas. Porém, a criação de um algoritmo eficaz enfrenta a complexidade de integrar e processar dados de diferentes fontes, como sensores de IoT e câmeras de alta resolução, que fornecem informações em tempo real sobre o tráfego.

A coleta e o processamento desses dados em plataformas na nuvem ou em dispositivos de borda (*edge devices*) demandam altos padrões de segurança e consistência, além de uma capacidade robusta de comunicação em tempo real. Em cidades como Manchester, testes com dispositivos de borda e algoritmos adaptativos mostraram que a tecnologia 5G, combinada com sensores de alta precisão, pode suportar as necessidades de conectividade, embora o custo e a interoperabilidade entre diferentes dispositivos e fabricantes permaneçam como desafios significativos (INTELLIAS, 2024).

Além disso, algoritmos de controle adaptativo, como o proposto neste trabalho, precisam responder de forma precisa e otimizada a mudanças abruptas no tráfego, como o aumento de fluxo em horários de pico ou em emergências. Essa capacidade adaptativa, essencial para otimizar o controle de semáforos e promover fluidez no trânsito, requer uma modelagem complexa e robusta, para que o sistema identifique padrões e ajuste os tempos de sinalização sem comprometer a segurança e a eficiência do trânsito.

Outro obstáculo à efetividade dos sistemas inteligentes de tráfego está relacionado ao comportamento dos motoristas. Em muitos casos, práticas como o

cruzamento em sinal vermelho continuam sendo comuns, especialmente em horários de menor fiscalização. Esse comportamento pode reduzir a eficiência dos sistemas de controle adaptativo e expor motoristas e pedestres a riscos adicionais. Estudos indicam que fatores como o layout das interseções, a presença de contagens regressivas nos sinais e as condições climáticas contribuem para as taxas de desobediência às regras de sinalização. Isso representa um obstáculo extra para que os sistemas inteligentes consigam realizar o controle ideal do tráfego (INTELLIAS, 2024).

Portanto, a implementação de sistemas inteligentes de controle de tráfego exige um investimento substancial em infraestrutura, tecnologias avançadas de monitoramento e algoritmos sofisticados de análise de dados. Além disso, a mudança na percepção e no comportamento dos motoristas é um fator crucial para garantir que esses sistemas cumpram seu potencial de reduzir congestionamentos e melhorar a segurança no trânsito.

5. CONSIDERAÇÕES FINAIS

Este estudo teve como objetivo explorar o uso de redes neurais artificiais para o controle adaptativo de semáforos em ambientes urbanos, visando otimizar o fluxo de tráfego e reduzir o tempo de espera dos veículos. Através da simulação, foram testadas estratégias de controle semafórico com redes neurais, em comparação ao método tradicional de ciclos fixos. Os resultados indicaram que o modelo baseado em IA se mostrou eficaz na adaptação em tempo real, respondendo dinamicamente às variações no fluxo de tráfego. Essa abordagem adaptativa possibilitou um aumento significativo na fluidez do trânsito e uma redução no acúmulo de veículos em interseções, especialmente em cenários de tráfego intenso.

A implementação do controle adaptativo com redes neurais representa uma contribuição significativa para a mobilidade urbana, ao demonstrar que é possível ajustar os ciclos semafóricos de forma mais eficiente, utilizando dados em tempo real. Esse modelo tem o potencial de minimizar os impactos dos congestionamentos, melhorar a eficiência de sistemas de transporte urbano e contribuir para a sustentabilidade, reduzindo o consumo de combustível e as emissões de gases poluentes. Além disso, o trabalho evidenciou que, embora a complexidade e os requisitos de infraestrutura para essa tecnologia sejam desafios importantes, o controle adaptativo com IA pode se consolidar como uma solução promissora para cidades inteligentes.

As dificuldades encontradas na implementação prática desse sistema, como a necessidade de infraestrutura robusta e os altos custos associados, refletem desafios que serão cruciais para a evolução e popularização de sistemas de controle de tráfego inteligente. No entanto, a eficácia do modelo demonstrado na simulação reforça que, uma vez superados esses desafios, o controle adaptativo com redes neurais poderá ser uma ferramenta poderosa para a gestão de tráfego em cidades cada vez mais congestionadas.

5.1 PERSPECTIVAS PARA ESTUDOS FUTUROS

Para ampliar as contribuições deste estudo, alguns caminhos de investigação podem ser explorados no futuro, envolvendo tanto o aprimoramento

técnico quanto a integração com novas tecnologias de mobilidade. Em primeiro lugar, a adaptação do controle semaforico para integrar-se diretamente com redes de veículos autônomos apresenta um campo de grande potencial. À medida que os veículos autônomos se tornam realidade nas vias urbanas, surge a possibilidade de sincronizar o sistema de semáforos com esses veículos, permitindo que os ciclos sejam ajustados em tempo real de acordo com as demandas específicas do tráfego, promovendo maior fluidez e segurança no trânsito.

Além disso, a integração do controle semaforico adaptativo com aplicativos de navegação em tempo real, como o *Waze*, representa uma estratégia promissora para melhorar a gestão do tráfego urbano. Ao permitir que os dados de congestionamento e rotas sugeridas pelo *Waze* sejam compartilhados com o sistema semaforico, os semáforos poderiam ser ajustados dinamicamente para aliviar pontos de congestionamento, reduzindo os tempos de viagem e distribuindo melhor o fluxo de veículos. Essa comunicação bidirecional também poderia fornecer informações em tempo real para os motoristas, alertando sobre ajustes nos ciclos semaforicos e contribuindo para uma navegação mais eficiente e previsível.

Outro aspecto importante para estudos futuros é a incorporação de variáveis ambientais ao sistema de controle semaforico adaptativo. Fatores como chuva, neblina e outras condições climáticas adversas afetam diretamente o comportamento dos motoristas e a dinâmica do tráfego. Assim, a consideração dessas variáveis na adaptação dos ciclos semaforicos permitiria que o sistema respondesse de forma otimizada às diferentes condições do clima, ajustando os tempos dos sinais para aumentar a segurança e a eficiência do trânsito em qualquer situação ambiental.

A análise do comportamento dos motoristas diante de ciclos semaforicos variáveis também é uma perspectiva relevante para o aprimoramento da tecnologia. Compreender como diferentes perfis de condutores reagem ao controle adaptativo, assim como avaliar o impacto da inclusão de contagens regressivas nos sinais, pode fornecer informações valiosas para tornar o sistema mais eficiente. Ao considerar a resposta comportamental dos motoristas, o controle adaptativo pode ser ajustado para incentivar o respeito às sinalizações e otimizar o fluxo de veículos, promovendo uma condução mais segura e ordenada.

Adicionalmente, aprimorar a simulação utilizada para modelagem do trânsito é uma área promissora para avanços. A inclusão de pedestres, ciclistas e veículos de emergência na modelagem traria uma representação mais fiel do ambiente urbano, permitindo que o sistema respondesse às demandas de forma mais inclusiva e abrangente. Essa evolução da simulação possibilitaria a análise do impacto do controle adaptativo no tráfego urbano como um todo, garantindo um ambiente mais seguro e funcional para todos os usuários das vias.

Por fim, o uso de redes neurais mais avançadas, como redes neurais profundas ou convolucionais, poderia ser investigado como forma de aumentar a precisão e a eficiência do controle semafórico adaptativo. Embora o modelo atual baseado em redes densas (*fully connected*) forneça uma solução eficiente e de baixo custo computacional, redes mais avançadas podem identificar padrões complexos e relações contextuais em dados de tráfego de maneira mais detalhada, possibilitando ajustes ainda mais rápidos e precisos nos ciclos semafóricos. Com o aprimoramento da tecnologia e o avanço dessas técnicas, vislumbra-se um sistema de controle de tráfego urbano altamente eficiente e adaptável às condições em constante mudança do ambiente urbano.

Essas perspectivas para estudos futuros destacam o potencial de transformação que a inteligência artificial e as redes neurais oferecem para o controle semafórico adaptativo, permitindo que as cidades se movam em direção a um sistema de mobilidade mais inteligente, ágil e sustentável.

REFERÊNCIAS

ANDRADE, Josiane Nascimento et al. O conceito de smart cities aliado à mobilidade urbana. *Revista Hum@ nae*, v. 10, n. 1, 2016.

BILHIM. Traffic Simulator. Disponível em: <https://github.com/BilHim/trafficSimulator>. Acesso em: 3 out. 2024.

DE FREITAS, Paulo Vitor Nascimento et al. Mobilidade urbana sustentável: problemas e soluções. *Revista Científica ANAP S* auit*, v. 8, n. 12, p. 01-17, 2015.

DENATRAN. Manual brasileiro de sinalização de trânsito: volume V - Sinalização Semafórica. Brasília, DF: Ministério das Cidades, Departamento Nacional de Trânsito, 2013. Disponível em: https://www.sinaldetransito.com.br/normas/manual_de_sinalizacao_semaforica_DENATRAN.pdf. Acesso em: 16 mar. 2023.

GIL, Antônio Carlos. *Como Elaborar Projetos de Pesquisa*. 6. ed. São Paulo: Editora Atlas Ltda., 2017.

Goodfellow, I.; Bengio, Y.; Courville, A. *Deep Learning*. Cambridge, Massachusetts: The Mit Press, ISBN: 978-0262035613, 2016.

Haykin, S. (2000). *Redes Neurais: Princípios e Prática* (P. M. Engel, Trad.). (2ª ed.). Bookman.

INTELLIAS. Smart Traffic Signals. Disponível em: <https://intellias.com/smart-traffic-signals/>. Acesso em: 01 nov. 2024.

Lecun, Y.; Bengio, Y.; Hinton, G. Deep Learning. *Nature*, v. 521, n. 7553, p. 436–444, maio 2015. Doi: <https://doi.org/10.1038/nature14539>

Mitchell, T. M. *Machine learning*. New York: Mcgraw-Hill, ISBN: 0070428077, 1997.

RAJALINGAPPAA; SOLANKI, P., & Solanki, A. (2017). Artificial Intelligence: A Review. *International Journal of Computer Science and Information Technologies*, 8(4), 2003-2006.

ROSSI, Bruna Cavati; ROCON, Júlia Paulino. Mobilidade ou caos urbano no Brasil?. *Revista Pet Economia UFES*, v. 4, n. 1, p. 15-18, 2024.

RUSSEL, S.; Norvig, P. *Artificial Intelligence: A Modern Approach*. 4. ed. [s.l.] Prentice Hall, ISBN: 9780134610993, 2020.

SPÖRL, C.; CASTRO, E. G.; LUCHIARI, A. Aplicação de Redes Neurais Artificiais na construção de modelos de fragilidade ambiental. *Revista do Departamento de Geografia*, v. 21, n.1, p. 113-135, 2011.

TREIBER, M.; HELBING, D. Explanation of observed features of self-organization in traffic flow. Institute of Theoretical Physics, University of Stuttgart, 2008.

WAZLAWICK, Raul Sidnei. *Metodologia de Pesquisa para Ciências da Computação*. 2. ed. Rio de Janeiro: Elsevier, 2013.

ZAMIN, Luísa et al. Mobilidade urbana: compreender o trânsito e suas relações com o cidadão. 2018. Disponível em: <https://publicacoeseventos.unijui.edu.br/index.php/salaoconhecimento/article/view/9829/8479>. Acesso em: 9 abr. 2023.