

Sistema inteligente e otimizado para controle de semáforos de trânsito

BRUNO LIRA

Email: *ra00282593@pucsp.edu.br*

¹, **GUILHERME RANGEL**

Email: *ra00282589@pucsp.edu.br*

¹, **PAULO RESTAINO**

Email: *ra00274387@pucsp.edu.br*

¹, **VICTOR COUTO**

Email: *ra00274395@pucsp.edu.br*

1

¹PUC-SP - Pontifícia Universidade Católica de São Paulo *[†]

20 de junho de 2023

Smart Traffic Light Optimization Control System

*Professor - Orientador: André Luís Braga

[†]Professor - Orientador: David de Oliveira Lemes



ABSTRACT

This study addresses the implementation of an intelligent system to control traffic lights in a city, aiming to optimize traffic flow and reduce congestion. Given the problem of urban congestion, the use of fixed-cycle traffic lights has proven to be inefficient in dealing with heavy traffic. The objective is to develop a reinforcement learning model that adjusts traffic light timings based on traffic intensity on each street.

Using the SUMO simulator, an urban traffic simulation was created to collect data such as waiting time and vehicle volume. These data were used to train the reinforcement learning model. The results showed that the proposed model reduced the average vehicle waiting time by half compared to fixed traffic light timings.

In summary, this study presents an innovative approach to improve urban traffic flow, using data processing techniques and reinforcement learning. The results suggest that the implementation of an intelligent traffic light control system can significantly contribute to congestion reduction and improve traffic efficiency in cities, with potential implications for the quality of life of drivers and the economy of congestion-affected urban areas.

Keywords

Artificial Intelligence; Reinforcement Learning; SUMO; Traffic; Traffic Light

RESUMO

Este estudo aborda a implementação de um sistema inteligente para controlar semáforos visando otimizar o fluxo de tráfego e reduzir congestionamentos. O objetivo é desenvolver um modelo de aprendizado por reforço que ajuste os tempos de semáforo com base na intensidade do tráfego em cada rua.

Utilizando o simulador SUMO, foi criada uma simulação de tráfego urbano para coletar dados como tempo de espera e volume de veículos. Esses dados foram utilizados para treinar o modelo de aprendizado por reforço. Os resultados mostraram que o modelo reduziu o tempo de espera médio dos veículos pela metade em comparação aos tempos de semáforo fixos.

Em suma, este estudo apresenta uma abordagem inovadora para melhorar o fluxo de tráfego urbano, utilizando técnicas de processamento de dados e aprendizado por reforço. Os resultados sugerem que a implementação de um sistema inteligente de controle de semáforos pode contribuir significativamente para a redução de congestionamentos e melhorar a eficiência

do trânsito nas cidades, com potenciais implicações na qualidade de vida dos motoristas e na economia urbana afetada pelo congestionamento.

Palavras-Chave

Aprendizado por Reforço; Inteligência Artificial; Semáforo; Simulador; Trânsito

Sumário

1	Introdução	5
1.1	INTRODUÇÃO E CONTEXTUALIZAÇÃO DO TEMA	5
1.2	PESQUISAS REFERENTES AO TEMA	5
2	Metodologia	6
2.1	INTRODUÇÃO AO CAPÍTULO DE METODOLOGIA	6
2.2	TIPOLOGIA DE PESQUISA	6
2.3	COLETA DE DADOS	7
2.4	TRATAMENTO E ANÁLISE DE DADOS	7
2.5	APRENDIZADO POR REFORÇO	13
3	Resultados finais e Conclusão	15
4	Referências	20

Lista de Figuras

1	Estrutura da simulação criada no SUMO	8
2	Fluxo de veículos em cada via da simulação por hora do dia	9
3	Distribuição do fluxo de veículos em vias de três faixas	9
4	Distribuição do fluxo de veículos em vias de duas faixas	10
5	Tempo de espera total médio em simulações com tempos de espera fixos entre 15 e 90 segundos	11
6	Tempo de espera médio das vias do semáforo S1 na simulação com tempo fixo de 15 segundos	11
7	Tempo de espera médio das vias do semáforo S2 na simulação com tempo fixo de 15 segundos	12
8	Tempo de espera médio das vias do semáforo S3 na simulação com tempo fixo de 15 segundos	12

9	Tempo de espera médio das vias do semáforo S4 na simulação com tempo fixo de 15 segundos	12
10	Estrutura de aprendizado do modelo proposto	13
11	Tempo de espera médio total durante cada episódio do treinamento	16
12	Melhores resultados da tabela Q para os 12 níveis de tráfego	17
13	Tempo de espera médio das vias do semáforo S1 na simulação de teste do modelo treinado	18
14	Tempo de espera médio das vias do semáforo S2 na simulação de teste do modelo treinado	18
15	Tempo de espera médio das vias do semáforo S3 na simulação de teste do modelo treinado	18
16	Tempo de espera médio das vias do semáforo S4 na simulação de teste do modelo treinado	19

1 Introdução

1.1 INTRODUÇÃO E CONTEXTUALIZAÇÃO DO TEMA

Um dos maiores problemas das grandes cidades no mundo atual é a superlotação do fluxo de tráfego ao redor da cidade. Há uma quantidade extrema de veículos nas ruas e avenidas, o que causa enormes congestionamentos nas cidade. Um dos fatores que contribuem com o grande engarrafamento é a forma como os semáforos da cidade se comportam, muitas vezes de forma pouco inteligente.

O objetivo do nosso projeto é criar um sistema inteligente para controlar os semáforos de trânsito de um bairro. Esse sistema irá controlar o tempo em que cada semáforo alterna entre as fases verde / vermelho de forma que o fluxo de trânsito seja o mais otimizado possível na região. Dessa forma, possibilitando um trânsito mais justo e eficiente.

Neste sistema serão elaboradas técnicas de processamento de dados que serão extraídos a partir da criação de um simulador no qual irá representar vias de trânsito de um determinado local. Nossa simulação conta com uma série de aspectos relevantes, como a configuração de rotas de trânsito, velocidade máxima das pistas, densidade do trânsito, a fim de torna-lo o mais próximo da realidade possível. Em uma segunda etapa, descrita posteriormente, os dados apresentados durante as simulações serão utilizadas pelo nosso sistema para atribuir um valor discreto referente ao nível do fluxo de trânsito (quanto maior o valor, mais elevado o trânsito) que ocorre num determinado momento nas vias. Valor esse que será importante para o treinamento do nosso modelo.

Por meio desse formato, a forma com que nosso modelo busca otimizar o fluxo de trânsito é da redução ao máximo do tempo de espera médio dos veículos presentes na simulação.

O modelo será treinado por meio da técnica de aprendizado por reforço, um método que possibilita a interação entre um determinado agente e ambiente, no qual esse agente realiza ações no ambiente, e aprende de acordo com os resultados de suas ações. O objetivo desse agente é maximizar as recompensas totais que o ambiente pode oferecer. Falaremos mais detalhadamente sobre o aprendizado por reforço e como ele se encaixa no treinamento do nosso modelo no capítulo de Metodologia.

1.2 PESQUISAS REFERENTES AO TEMA

Pesquisas indicam que o grande congestionamento de trânsito em grandes cidades atrapalham não apenas o tempo hábil de deslocamento dos cidadãos, como também interfere negativamente na economia das cidades como um todo. Em 2018, na cidade de Boston (Estados Unidos), por exemplo, estima-se que o congestionamento da cidade causou para os motoristas uma perda de 164 horas, em média, presos no trânsito, conseqüentemente causando uma perda econômica de 4,1 bilhões de dólares para a cidade. Além disso também há estudos que apontam que o extenso congestionamento afetam psicologicamente os motoristas, deixando-os mais

estressados no dia a dia e com comportamentos mais agressivos.

No Brasil, pessoas economicamente ativas nas capitais gastam diariamente cerca de 64,5 minutos em média presas em congestionamentos segundo o SEBRAE.

Um dos principais fatores que contribuem para esse cenário é o fato de que a maioria dos semáforos espalhados pelo mundo ainda utilizam o método do ciclo fixo. Neste método, é calculado manualmente e previamente um tempo fixo para cada semáforo transitar entre os modos verde e vermelho. Entretanto, essa forma, utilizada desde o início do século XX, é considerada ineficiente e contribuinte para a superlotação no fluxo de trânsito. Recentemente, passou-se a perceber uma nova perspectiva na forma com que os semáforos de trânsito atuam, e a partir disso começou a haver vários estudos para a criação de semáforos que consigam agir de forma inteligente, visando a otimização do fluxo de trânsito ao redor das cidades.

2 Metodologia

2.1 INTRODUÇÃO AO CAPÍTULO DE METODOLOGIA

Como dito no capítulo anterior, o objetivo é criar um sistema inteligente de controle de semáforos que saiba otimizar o tempo de alternância entre as fases verde/vermelho de cada semáforo, de forma em que o fluxo de trânsito de uma certa região seja o mais eficiente possível. Nesse capítulo de metodologia iremos demonstrar de maneira aprofundada o passo a passo feito para construção desse sistema.

2.2 TIPOLOGIA DE PESQUISA

Nesse tópico especificaremos os métodos que utilizamos para desenvolver nosso projeto, em termos de abordagem, pesquisa, fonte de dados e procedimentos.

A abordagem do projeto é do tipo quantitativa, pois realizamos uma análise objetiva com dados numéricos e gráficos para identificar os níveis de congestionamento presentes em determinada rua/avenida em um determinado instante.

Levando em conta os objetivos de pesquisa, nossa abordagem é do tipo exploratória, pois a pesquisa se baseia em um tema pouco explorado a nível global até o momento. Há muitas regiões ao redor do mundo que nunca implementaram sistemas de semáforos inteligentes em suas cidades, tampouco relataram pesquisas profundas sobre o assunto.

Em relação a fonte de dados a abordagem é do tipo laboratorial, pois estamos coletando nossos dados através de um simulador de trânsito (ambiente controlado) onde, apesar de determinados aspectos a respeito de sua estrutura serem definidos, as ações dos veículos são randômicas, a fim de aproximar o modelo simulado da realidade.

Por fim, levando em conta os procedimentos de pesquisa, desenvolvimento e conclusões que obtivemos, nossa abordagem é do tipo experimental, onde o objetivo de nosso trabalho se

baseia em treinar e otimizar um modelo de sistema inteligente de semáforos de modo que, para alcançar resultados otimizados, é necessário realizar experimentos diversos e, com os dados produzidos pelas experimentações, influenciar, de forma positiva ou negativa, ações a serem realizadas.

2.3 COLETA DE DADOS

Neste projeto, foi criada uma simulação de semáforos utilizando o simulador SUMO (Simulation of Urban MObility).

O simulador SUMO (Simulation of Urban MObility) é uma ferramenta completa, aberta, e flexível para a simulação de tráfego urbano. Ele permite a criação de cenários complexos e realistas, considerando diferentes tipos de veículos, fluxos de tráfego e infraestrutura viária. Além disso, ele fornece uma ampla gama de informações e métricas para avaliar o desempenho do sistema de transporte, incluindo atrasos, tempos de viagem, consumo de combustível, emissões de poluentes, entre outros.

No entanto, neste projeto optamos por utilizar apenas carros e duas métricas principais para avaliar o desempenho do sistema de controle de semáforos: o tempo de espera e a quantidade de veículos em cada via. Essas métricas são consideradas importantes indicadores de desempenho para o controle de semáforos em cenários urbanos, pois ajudam a avaliar o congestionamento e o tempo de espera dos usuários. Ao utilizar essas métricas, nos aproximamos de um modelo real onde nosso modelo poderia atuar juntamente com modelos de visão computacional que podem fornecer esses dados em tempo real através câmeras posicionadas em semáforos.

Apesar de não utilizarmos todas as métricas disponíveis no SUMO, a ferramenta apresentou diversas vantagens para a simulação de tráfego urbano em nosso projeto. Uma dessas vantagens é a sua API Python que permite a integração com outras ferramentas e o desenvolvimento de algoritmos de aprendizado de máquina personalizados. Com a API Python do SUMO é possível criar scripts personalizados para a coleta de dados e avaliação do desempenho do sistema de controle de semáforos, como será apresentado a frente.

2.4 TRATAMENTO E ANÁLISE DE DADOS

Nossa simulação consiste em um cenário urbano formado por quatro cruzamentos interligados (S1, S2, S3 e S4). Os cruzamentos são formados por duas vias horizontais de três faixas cada (A e C) e duas vias verticais de duas faixas cada (B e D). Esse tipo de configuração é bastante comum em áreas urbanas onde o tráfego pode se tornar bastante intenso durante os horários de pico.

A escolha desse tipo de configuração para nossa simulação se deve ao fato de que ela apresenta desafios interessantes para o controle de semáforos. Com várias ruas convergindo em

cada cruzamento, é preciso ajustar os tempos de sinalização de forma adequada para garantir a fluidez do tráfego e evitar congestionamentos.

Além disso, definimos que a velocidade máximas das vias será de 40km/h (velocidade definida pelo Código de Trânsito Brasileiro - CTB para vias coletoras, como as simuladas) e os semáforos atuarão da seguinte forma: cada estágio amarelo terá duração fixa de 3 segundos e cada estágio verde/vermelho pode ter um valor variável entre 15 e 90 segundos. Essa faixa de duração é limitada devido a possível existência de pedestres atravessando ou aguardando para atravessar as vias.

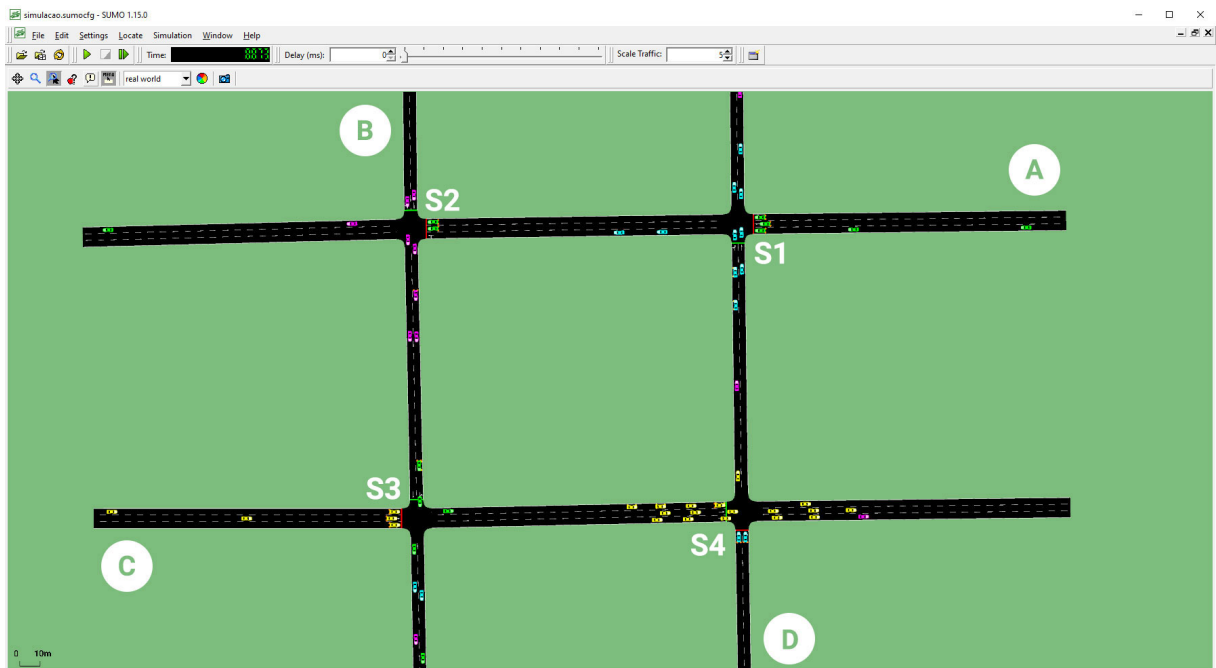


Figura 1: Estrutura da simulação criada no SUMO

Para gerar o tráfego de veículos nas ruas da simulação, utilizamos a configuração de "veículos por hora" em cada via. Essa configuração permite que definamos a quantidade de veículos que devem ser enviados por hora em cada via da simulação. Apesar do volume fixo de veículos por hora, a entrada deles na via é realizada de forma randômica. Buscando criar um modelo similar a realidade, levando em conta momentos de picos nas ruas, foi definido a quantidade de veículos da seguinte forma:




Figura 2: Fluxo de veículos em cada via da simulação por hora do dia

Em nosso ambiente simulado, os veículos que por ele circulam possuem mais de uma rota de saída possível. Essa configuração é importante para que se reflita na simulação as condições reais de tráfego em determinada área. Cada veículo possui uma de quatro possíveis rotas, como mostrado na imagem abaixo (Figura 4). Essas rotas foram cuidadosamente escolhidas de forma a refletir as condições reais de tráfego na área simulada.

O fluxo de veículos nas duas vias de três faixas (A e C) é distribuído da seguinte forma: 10% dos veículos viram na primeira direita, 66% continuam em linha reta até o fim da via, 14% viram na segunda esquerda e continuam em linha reta e os 10% restante viram na segunda esquerda, depois viram na primeira esquerda e seguem em linha reta em direção contrária a que estavam no início do percurso.




Figura 3: Distribuição do fluxo de veículos em vias de três faixas

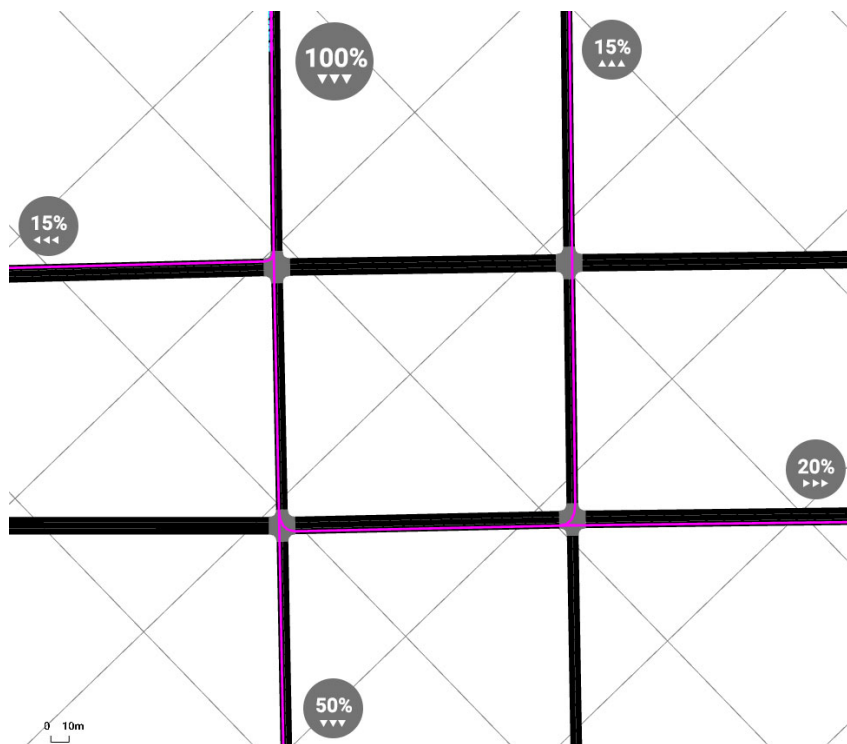


Figura 4: Distribuição do fluxo de veículos em vias de duas faixas

Nas duas vias de duas faixas (B e D) o fluxo é distribuído da seguinte forma: 15% dos veículos viram na primeira direita, 50% continuam em linha reta até o fim da via, 20% viram na segunda esquerda e continuam em linha reta e os 15% restante viram na segunda esquerda, depois viram na primeira esquerda e seguem em linha reta em direção contrária a que estavam no início do percurso.

Para testar a eficácia do modelo, realizamos uma série de testes com os tempos dos semáforo definidos previamente, como é utilizado em grande parte do mundo atualmente, variando entre 15 e 90 segundos.




Figura 5: Tempo de espera total médio em simulações com tempos de espera fixos entre 15 e 90 segundos

Em semáforos com tempos definidos previamente, o melhor resultado nos testes simulados foi o de 15 segundos em cada estágio de verde/vermelho. Nesta configuração o tempo de espera médio dos carros que passaram pelo ambiente durante um dia completo foi de 11,28 segundos. Podemos observar a seguir os tempos de espera médio das vias de cada semáforo.




Figura 6: Tempo de espera médio das vias do semáforo S1 na simulação com tempo fixo de 15 segundos




Figura 7: Tempo de espera médio das vias do semáforo S2 na simulação com tempo fixo de 15 segundos




Figura 8: Tempo de espera médio das vias do semáforo S3 na simulação com tempo fixo de 15 segundos




Figura 9: Tempo de espera médio das vias do semáforo S4 na simulação com tempo fixo de 15 segundos

2.5 APRENDIZADO POR REFORÇO

O aprendizado por reforço é uma abordagem de Inteligência Artificial em que um agente aprende a tomar decisões através de interações com um ambiente. Nesse processo, o agente recebe um feedback na forma de recompensas a cada ação tomada, com o objetivo de maximizá-la ao longo do tempo. Com base nas recompensas recebidas, o agente aprende a associar as ações aos melhores resultados a fim de tomar decisões mais acertadas no futuro.

Em nosso modelo, utilizaremos a abordagem para definir os tempos de cada estágio dos semáforos com base em interações com o ambiente simulado. Através dessa técnica o modelo será capaz de processar informações espaciais e temporais relevantes para o tráfego urbano, permitindo aprender padrões complexos e tomar decisões ótimas em tempo real.

Nesse contexto, as ações são as diferentes combinações de tempos de semáforo em que o modelo pode escolher (em nosso caso 15 a 90 segundos) e as recompensas são valores numéricos resultantes do tempo de espera e a quantidade de veículos em cada cruzamento após a realização de determinada ação.

A abordagem é ilustrada abaixo:

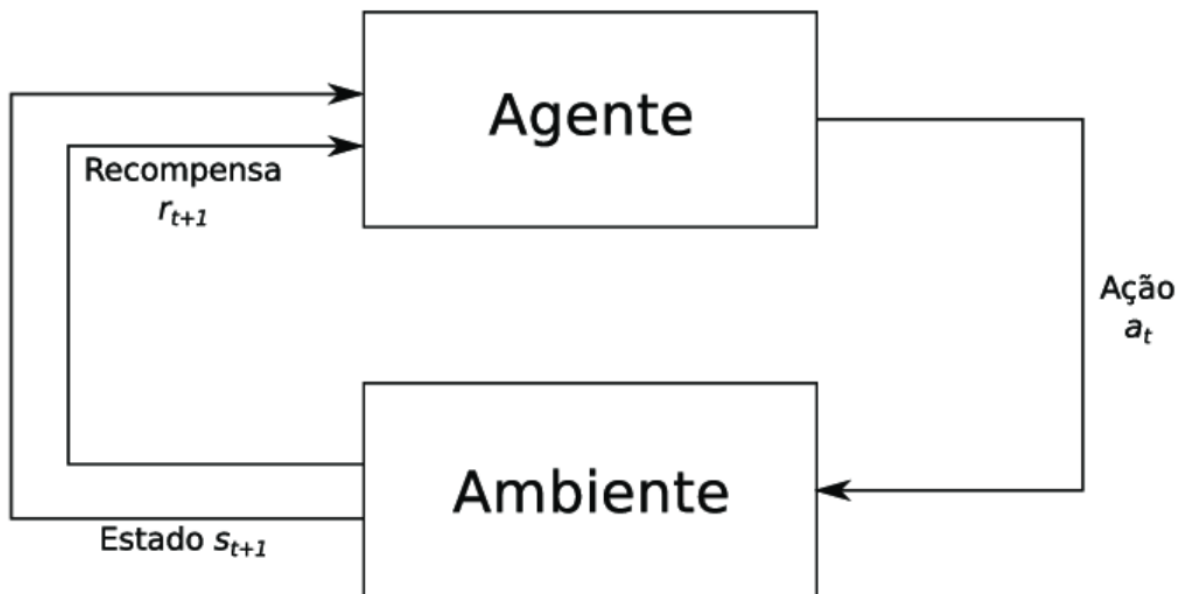


Figura 10: Estrutura de aprendizado do modelo proposto

O estado (S) é uma representação do ambiente em um determinado momento, no caso o inteiro mais próximo do resultado da quantidade total de veículos parados (qvp) dividido por 5.

A recompensa (R) é um valor numérico que indica a qualidade/desempenho de uma ação tomada pelo agente em um determinado momento t . Seu valor consiste pelo inteiro mais próximo da adição de 10 ao tempo total de espera dos veículos ($ttev$) dividido pela quantidade total de veículos parados (qvp) vezes -1 se qvp for maior que 0, senão 0.

Para o cálculo da ação (A), o tempo de duração dos estágios do semáforo, introduziremos uma nova variável em nosso modelo: o épsilon (ϵ). Seu valor é utilizado para controlar a taxa de exploração do agente durante o processo de escolha de ações. Épsilon é um parâmetro que determina a probabilidade de o agente realizar uma ação aleatória ao invés da escolha de uma ação de maior qualidade testada anteriormente. Inicialmente, definiremos seu valor como 0,7 e, a cada episódio, reduziremos seu valor gradualmente em 0,5%, permitindo que o agente confie mais nas estimativas presentes em seu banco de dados. Por fim, o valor da ação é definido da seguinte forma:

1. Se o valor de épsilon (ϵ) for maior que um valor aleatório (X) ou o estado (S) não estiver sido inicializado no banco de resultados, é escolhida uma ação aleatória entre as possíveis (15 a 90 segundos de tempo de esperado).
2. Senão, é escolhido o tempo de duração com melhor qualidade testado anteriormente.

$$S = \left\lfloor \frac{qvp}{5} \right\rfloor \quad (1)$$

$$R_t = \begin{cases} \left\lfloor \frac{tev}{qvp} \times -1 + 10 \right\rfloor, & \text{se } qvp > 0, \\ 0, & \text{caso contrário.} \end{cases} \quad (2)$$

$$A_t = \begin{cases} \text{rand } A, & \text{se } X < \epsilon \mid s \notin Q^*, \\ \max_s Q(s), & \text{caso contrário.} \end{cases} \quad (3)$$

De forma simplificada, nosso modelo consiste em uma comunicação de mão dupla entre o agente (modelo definidor de tempos) e o ambiente (semáforos):

1. Analisando o ambiente, o agente envia uma ação para o ambiente (definir um tempo específico para o estágio verde/vermelho do semáforo).
2. Após o ambiente realizar a ação (finalizar o estágio solicitado), é retornado para o agente dois valores resultantes: o estado (situação dos veículos nas vias ao final do processo) e a recompensa (qualidade da ação realizada).
3. O processo é iniciado novamente.

A final de cada ação realizada no contexto do aprendizado por reforço é realizado o cálculo e atualização dos valores Q . Os valores Q representam as estimativas da qualidade de uma ação em um determinado estado, indicando o valor esperado de recompensas futuras que podem ser alcançadas ao realizar essa ação.

Durante o teste o agente interage com o ambiente tomando ações com base na política de decisão estabelecida. Após realizar uma ação e observar o próximo estado e a recompensa recebida, o agente utiliza essas informações para atualizar o valor Q correspondente à ação tomada no estado anterior. Ações que resultaram em menor quantidade de carros parados resultam em melhores valores Q.

O cálculo do valor Q é realizado utilizando uma fórmula que combina a taxa de aprendizado α com a recompensa imediata e o valor Q estimado do próximo estado, ponderada pelo fator de desconto γ . O fator de desconto é um parâmetro que indica a importância relativa das recompensas imediatas em comparação com as recompensas futuras.

Inicialmente, todos os valores Q são definidos como 0. A atualização do valor Q é realizada constantemente ao longo dos testes, permitindo ao agente refinar suas estimativas e melhorar a qualidade das ações tomadas. Conforme o agente continua a interagir com o ambiente e coletar mais experiências, os valores Q se aproximam dos valores ótimos, refletindo a ação que leva à maior recompensa esperada em cada estado.

$$Q(S, A_t) = Q(S, A_t) + \alpha[R_{t+1} + \gamma \max_a Q(S_{t+1}, A_t) - Q(S, A_t)] \quad (4)$$

3 Resultados finais e Conclusão

Para treinar o modelo de aprendizado por reforço no controle do tempo de semáforos utilizamos uma máquina virtual da Amazon Web Services (AWS), especificamente a instância Inf1. Essa máquina possui recursos otimizados para tarefas de inferência em aprendizado de máquina e foi escolhida devido à sua capacidade de processamento acelerado. Todos os parâmetros utilizados na versão satisfatória do modelo são apresentados Tabela 1 (abaixo). O treinamento completo simulou 200 episódios, ou seja, 200 dias completos, realizando testes e ajustes dos dados. O tempo de treinamento total foi de 3 horas e 52 minutos.

Parâmetros	Valor
Episódios	200
Épsilon ϵ	0,7
Decaimento de épsilon	0,995
Fator de desconto γ	0,9
Taxa de Aprendizado α	0,03

Tabela 1: Parâmetros utilizados para o treinamento do modelo

Durante o treino, observamos uma melhora constante dos resultados e um aumento contínuo das recompensas obtidas pelo modelo de aprendizado por reforço (Figura 11). Essa

evolução gradual foi um indicativo claro de que os agentes estavam aprendendo a tomar decisões mais eficientes no controle do tempo de semáforos.

Conforme as iterações do treinamento prosseguiam, os agentes demonstraram uma maior capacidade de antecipação e adaptabilidade diante de diferentes situações de tráfego. Foram gerados 12 níveis de tráfego, variando desde o menor, representando menos veículos, até o maior, representando um fluxo mais intenso.

A habilidade dos agentes em identificar e responder adequadamente a diferentes níveis de tráfego é um dos pontos fortes da abordagem de aprendizado por reforço. Essa flexibilidade adaptativa permitiu que os agentes aprendessem a lidar com uma ampla gama de cenários de tráfego, preparando-os para enfrentar situações reais com eficiência e eficácia.




Figura 11: Tempo de espera médio total durante cada episódio do treinamento

Para cada um dos 12 níveis de tráfego, os agentes conseguiram alcançar valores ótimos na tabela Q, representando a aprendizagem das melhores ações a serem tomadas em cada estado bem-sucedida (Figura 12). Essa capacidade de adaptação e generalização é crucial para a eficácia do controle do tempo de semáforos, pois permite melhorias significativas na redução de congestionamentos, diminuição dos tempos de espera e otimização do uso das vias, independentemente do nível de tráfego enfrentado.




Figura 12: Melhores resultados da tabela Q para os 12 níveis de tráfego

Após o treinamento dos agentes de controle de semáforos utilizando o aprendizado por reforço, realizamos testes para avaliar o desempenho do modelo treinado. Os resultados foram impressionantes, com um tempo de espera médio total nos semáforos de apenas 5,79 segundos. Esse valor representa uma redução significativa de 48,7% em relação ao melhor resultado obtido nos testes com tempos fixos (11,28 segundos).

A comparação com os testes de tempos fixos é fundamental para validar a eficácia do modelo treinado. Os tempos fixos são baseados em padrões predefinidos e não são capazes de se adaptar às mudanças no tráfego em tempo real. No entanto, com o aprendizado por reforço, os agentes foram capazes de aprender a ajustar dinamicamente o tempo de abertura dos semáforos com base nas condições de tráfego em cada momento.

Abaixo é possível observar o tempo de espera médio nos semáforos. Comparando com o melhor resultado das simulações com tempos fixos, é possível observar uma grande melhora durante todos os períodos do dia, especialmente entre os com maior fluxo de veículos.




Figura 13: Tempo de espera médio das vias do semáforo S1 na simulação de teste do modelo treinado




Figura 14: Tempo de espera médio das vias do semáforo S2 na simulação de teste do modelo treinado




Figura 15: Tempo de espera médio das vias do semáforo S3 na simulação de teste do modelo treinado




Figura 16: Tempo de espera médio das vias do semáforo S4 na simulação de teste do modelo treinado

Os resultados obtidos neste projeto são altamente promissores e indicam a eficácia do uso de aprendizado por reforço para o controle do tempo de semáforos. A redução de 48,7% no tempo de espera médio total nos semáforos em comparação aos testes com tempos fixos é um indicativo claro da capacidade dos agentes treinados em otimizar o fluxo de veículos.

É importante ressaltar que os resultados obtidos nesse projeto não apenas demonstram a eficácia do aprendizado por reforço no controle do tempo de semáforos, mas também apontam para a necessidade de abordagens mais dinâmicas e adaptáveis nessa área. A gestão eficiente do tráfego urbano é fundamental para reduzir congestionamentos, minimizar o tempo de viagem dos usuários e promover uma mobilidade sustentável.

Embora esse projeto tenha alcançado resultados notáveis, é importante destacar algumas limitações e recomendações para trabalhos futuros. Por exemplo, é possível explorar a combinação de aprendizado por reforço com outras abordagens, como aprendizado supervisionado e redes neurais, para obter ainda melhores resultados. Além disso, é importante considerar a implementação prática desse modelo em um ambiente real, avaliando sua escalabilidade e interação com outros sistemas de controle de tráfego.

Um requisito essencial para a implementação efetiva do controle do tempo de semáforos através do aprendizado por reforço é a disponibilidade de dados precisos e em tempo real sobre o tráfego. Nesse sentido, a utilização de câmeras e algoritmos de visão computacional desempenha um papel fundamental. Essa tecnologia permite capturar imagens em tempo real das vias e, por meio de algoritmos avançados, processar essas imagens para extrair informações relevantes, como a contagem de veículos e seus estados nas vias. Essa tecnologia conta com pesquisas em estado avançado e sendo aplicada em algumas cidades ao redor do mundo. Além disso, outras tecnologias em desenvolvimento, como sensores ultrassônicos ou de visão dinâmica, se mostram capazes de fornecer os dados necessários com possíveis melhores resultados, devido a capacidade de funcionamento intermitente independente das condições meteorológicas das vias.

Todos os códigos utilizados no projeto podem ser acessados através do Github.

O texto foi elaborado por todos os autores em conjunto, como requisito para obtenção do título de Bacharel em Ciência de Dados e Inteligência Artificial pela Pontifícia Universidade Católica de São Paulo (PUC-SP), sob orientação do Prof. Dr. David de Oliveira Lemes.

4 Referências

Referências

- [1] Dex R. ALEKO and Soufiene Djahel. An efficient adaptive traffic light control system for urban road traffic congestion reduction in smart cities. *Information*, 11(2), 2020. <https://doi.org/10.3390/info11020119>.
- [2] Marina Barbosa. *População dos grandes centros perde em média 21 dias do ano no trânsito, aponta CNDL / SPC Brasil*, 2022. Available at <https://site.cndl.org.br/populacao-dos-grandes-centros-perde-em-media-21-dias-do-ano-no-transito-aponta>
- [3] Abdelkader Chabchoub, Ali Hamouda, Saleh Al-Ahmadi, and Adnen Cherif. Intelligent traffic light controller using fuzzy logic and image processing. *International Journal of Advanced Computer Science and Applications*, 12(4), 2021. <http://dx.doi.org/10.14569/IJACSA.2021.0120450>.
- [4] Bernardo Coutinho, Fernando Matsumoto, Ariel Guerreiro, Eduardo Eiras, and Pedro Rosa. *Workshop-de-Aprendizado-por-Reforco*, 2021. Available at <https://github.com/turing-usp/Workshop-de-Aprendizado-por-Reforco>.
- [5] Luis Cruz-Piris, Diego Rivera, Susel Fernandez, and Ivan Marsa-Maestre. Optimized sensor network and multi-agent decision support for smart traffic light management. *Sensors*, 18(2), 2018. <https://doi.org/10.3390/s18020435>.
- [6] Professor Rogério Nascimento da Silva de Jesus. *Entenda mais sobre a Metodologia do TCC, veja como fazer e os tipos existentes*, 2019. Available at <https://projetoacademico.com.br/metodologia-tcc/>.
- [7] David L. Wiesenthal Dwight A. Hennessy. Traffic congestion, driver stress, and driver aggression. *Department of Psychology and LaMarsh Centre for Research on Violence and ConflictResolution*, 25, 10 1999. [https://doi.org/10.1002/\(SICI\)1098-2337\(1999\)25:6<409::AID-AB2>3.0.CO;2-0](https://doi.org/10.1002/(SICI)1098-2337(1999)25:6<409::AID-AB2>3.0.CO;2-0).
- [8] Tyler Falk. *Los Angeles synchronizes all traffic lights*, 2013. Available at <https://www.zdnet.com/article/los-angeles-synchronizes-all-traffic-lights/>.

- [9] Geraldine P. Felicio, Lorelie C. Grepo, Vincent F. Reyes, and Lancelot C. Yupingkun. Traffic light displays and driver behaviors: A case study. *Procedia Manufacturing*, 3:3266–3273, 2015. <https://doi.org/10.1016/j.promfg.2015.07.879>.
- [10] Yevhen Fornalchyk, Ivan Kernytskyy, Oleh Hrytsun, and Yuriy Royko. Choice of the rational regimes of traffic light control for traffic and pedestrian flows. *Scientific Review Engineering and Environmental Sciences (SREES)*, 30(1):38–50, Mar. 2021. <https://doi.org/10.22630/PNIKS.2021.30.1.4>.
- [11] Ziyue Li, Qinghua Zeng, Yuchao Liu, Jianye Liu, and Lin Li. An improved traffic lights recognition algorithm for autonomous driving in complex scenarios. *International Journal of Distributed Sensor Networks*, 17(5):15501477211018374, 2021. <https://doi.org/10.1177/15501477211018374>.
- [12] Xiaoyuan Liang, Xunsheng Du, Guiling Wang, and Zhu Han. A deep reinforcement learning network for traffic light cycle control. *IEEE Transactions on Vehicular Technology*, 68(2):1243–1253, feb 2019. <https://doi.org/10.48550/arXiv.1803.11115>.
- [13] Mayara Lima, Marcela de Alcantara, Amauri Rosenthal, and Rosires Deliza. Effectiveness of traffic light system on brazilian consumers perception of food healthfulness. *Food Science and Human Wellness*, 8(4):368–374, 2019. <https://doi.org/10.1016/j.fshw.2019.10.001>.
- [14] Zibo Ma, Tongchao Cui, Wenxing Deng, Fengyao Jiang, and Liguozhang. Adaptive optimization of traffic signal timing via deep reinforcement learning. *Journal of Advanced Transportation*, 2021:1–14, 11 2021. <https://doi.org/10.1155/2021/6616702>.
- [15] Andrew McFarland. *Clearing the Air: A Proposal for a Congestion User Fee for the City of Boston*, 2018. Available at <https://www.proquest.com/openview/915628560aba47bdf8b33bdc13ed26a5/1?pq-origsite=gscholar&cbl=18750&diss=y>.
- [16] Sergio Nesmachnow, Renzo Massobrio, Efraín Arreche, Christine Mumford, Ana Carolina Olivera, Pablo Javier Vidal, and Andrei Tchernykh. Traffic lights synchronization for bus rapid transit using a parallel evolutionary algorithm. *International Journal of Transportation Science and Technology*, 8(1):53–67, 2019. <https://doi.org/10.1016/j.ijtst.2018.10.002>.
- [17] Sin-Chun Ng and Chok-Pang Kwok. An intelligent traffic light system using object detection and evolutionary algorithm for alleviating traffic congestion in hong kong. *International Journal of Computational Intelligence Systems*, 13:802–809, 2020. <https://doi.org/10.2991/ijcis.d.200522.001>.

- [18] Heriberto Pérez-Acebo, Xabier Otxoa-Muñoz, Mikel Marquina-Llaguno, and Hernán Gonzalo-Orden. Analysis of the efficiency of traffic lights turning red in case of exceeding speed limit. *Ingeniería e Investigación*, 41(1):e86047, Jan. 2021. <https://doi.org/10.15446/ing.investig.v41n1.86047>.
- [19] Zaman Ramadhan, Rasha Salman, Bahaa Kareem Mohammed, and Ali Alwaily. Design and implement a smart traffic light controlled by internet of things. *Periodicals of Engineering and Natural Sciences (PEN)*, 9:542–548, 10 2021. <http://dx.doi.org/10.21533/pen.v9i4.2351>.
- [20] Rajendran Sathiyaraj and A. Bharathi. An efficient intelligent traffic light control and deviation system for traffic congestion avoidance using multi-agent system. *Transport*, 35:1–9, 09 2019. <https://doi.org/10.3846/transport.2019.11115>.
- [21] T.J. Sejnowski. *A Revolução do Aprendizado Profundo*. Alta Books, 2020. <https://books.google.com.br/books?id=5HHJDwAAQBAJ>.
- [22] Ishu Tomar, Indu Sreedevi, and Neeta Pandey. State-of-art review of traffic light synchronization for intelligent vehicles: Current status, challenges, and emerging trends. *Electronics*, 11(3), 2022. <https://doi.org/10.3390/electronics11030465>.
- [23] Dr. K Wagh, Ashish Chauhan, Shraddha Bhandari, Aniruddha Langhe, and Nikhil Pawar. Dynamic traffic light optimization and control system. *International Journal of Future Generation Communication and Networking*, pages 472–481, 01 2020. Available at https://www.researchgate.net/publication/347902387_Dynamic_Traffic_Light_Optimization_and_Control_System.
- [24] Daniel Wright and Philippe Chouinard. Effects of multitasking and intention-behaviour consistency when facing yellow traffic light uncertainty. *Attention, Perception, & Psychophysics*, 81, 06 2019. <https://doi.org/10.3758/s13414-019-01766-9>.
- [25] Kento Yabuuchi, Masahiro Hirano, Taku Senoo, Norimasa Kishi, and Masatoshi Ishikawa. Real-time traffic light detection with frequency patterns using a high-speed camera. *Sensors*, 20(14), 2020. <https://doi.org/10.3390/s20144035>.
- [26] A'isya Yusuf, Ajib Arifin, and F.Y. Zulkifli. Recent development of smart traffic lights. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 10:224, 03 2021. <http://doi.org/10.11591/ijai.v10.i1.pp224-233>.