

NELSON MURCIA GARCÍA

Título

**Rede Neural Bio-Inspirada para o Controle Dinâmico de Múltiplas
Interseções**

São Paulo

2019

NELSON MURCIA GARCÍA

Título

**Rede Neural Bio-Inspirada para o Controle Dinâmico de Múltiplas
Interseções**

Versão Original

Dissertação apresentada à Escola
Politécnica da Universidade de São
Paulo para a obtenção do título de
Mestre em Ciências

Orientador:

Prof. Dr. André Riyuiti Hirakawa

São Paulo

2019

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Catálogo-na-publicação

Murcia García, Nelson

Rede Neural Bio-Inspirada para o Controle Dinâmico de Múltiplas Interseções / N. Murcia García -- São Paulo, 2019.

111 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Computação e Sistemas Digitais.

*Para minha família, porque sou fruto deles.
Mesmo estando longe sempre estiveram presentes.*

Resumo

Um dos principais problemas das grandes cidades hoje é, sem dúvida, o trânsito intenso de veículos que causa lentidão e engarrafamentos diários, principalmente nos horários de pico. Os pesquisadores têm desenvolvido vários estudos para buscar soluções para este problema, mas devido às características do sistema de trânsito, ainda não existe uma posição de consenso sobre qual é o melhor método a ser utilizado. Este trabalho apresenta uma melhoria do modelo de Redes Neurais Bio-Inspiradas desenvolvido anteriormente que se baseia em controle multiagente de semáforos, com uma abordagem distribuída para resolver o problema, na qual cada agente controla a sua interseção e envia e recebe informações de agentes de controle de interseções vizinhas. Baseado nesse modelo, o objetivo deste trabalho foi estender para incluir informações como: a distância entre as interseções, velocidade dos veículos e número de faixas da via comum entre essas interseções, diferenciando as relações existentes entre as interseções. Com esse objetivo, foram estudados três métodos para calcular o coeficiente de relação entre interseções vizinhas de forma off-line na fase de configuração do modelo. Os métodos de Regressão estudados foram validados por meio de um cenário real da cidade de São Paulo para estimar o impacto dos métodos e selecionar o método com melhor resultado. Os indicadores de desempenho utilizados nessa avaliação são: o Tempo Médio de Viagem dos veículos e o Nível de Ocupação das Vias. Nos resultados obtidos, o modelo de Rede Neural Bio-Inspirada com o método de Redes Neurais Artificiais para o cálculo do coeficiente de relação entre interseções vizinhas obteve resultados superiores quando comparado com o Modelo de Redes Neurais Bio-inspiradas inicialmente proposto em e com os outros dois métodos para o cálculo do coeficiente de relação e com o modelo sem diferenciar as relações, além de corroborar que o controle proposto é significativamente melhor que o controle atualmente utilizado na maioria das interseções da cidade.

Palavras chave: Controle de Trânsito Urbano. Controle de Semáforos. Controle de Agentes de Interseções. Inteligência Artificial. Redes Neurais Bio-Inspiradas. Fases Semafóricas. Tempo Médio de Viagem. Nível de ocupação das Vias.

Abstract

One of the main problems in big cities today is undoubtedly the heavy traffic that causes delays and daily traffic jams, especially at peak hours. Researchers have developed several studies to find solutions to this problem, but due to the characteristics of the transit system, there is still no consensus position on which method is best to use. This paper presents an improvement on the previously developed Bio-Inspired Neural Networks model that is based on multi-agent semaphore control with a distributed approach to solving the problem where each agent controls its intersection and sends and receives information from control agents, from neighboring intersections. Based on this model, the objective of this work was to improve the previous works to include information such as the distance between intersections, vehicle speed, and the number of lanes between these intersections, differentiating the relationships between intersections. For this purpose, three methods were studied to calculate the correlation coefficient between neighboring intersections, the methods were used offline in the model configuration phase. The regression methods studied were validated through a real scenario of the city of São Paulo to estimate the impact of the methods and select the method with the best result. The performance indicators used in this evaluation are the average travel time of vehicles and the road occupancy level. In the obtained results, the Bio-Inspired Neural Network model with the Artificial Neural Networks method for the calculation of the coefficient of relationship between neighboring intersections obtained superior results when compared to the Bio-Inspired Neural Network Model initially proposed and with the others two previous methods for calculating the relationship coefficient. The results corroborate that the proposed control is significantly better than the control currently used in most city intersections.

Keywords: Urban Traffic Control. Traffic Lights Control. Semaphore Control. Bio-Inspired Neural Networks. Semaphore Phases. Average Travel Time. Roads Occupancy Level.

LISTA DE ILUSTRAÇÕES

Figura 1 - Consumo de combustível com respeito à velocidade.....	9
Figura 2 - Interseção simples com duas fases e quatro semáforos.....	21
Figura 3 - Interseções vizinhas com fases comuns.....	22
Figura 4 - Análise submicroscópico.....	23
Figura 5 - Análise microscópico.....	23
Figura 6 - Análise Mesoscópico.....	24
Figura 7 - Análise macroscópico.....	25
Figura 8 - Modelo de rede neural com 3 neurônios de entrada e 1 neurônio de saída.....	35
Figura 9 - Modelo BiNN para controle de uma interseção.....	53
Figura 10 - Modelo BiNN para a coordenação entre interseções.....	62
Figura 11 - Cenário com duas interseções vizinhas e uma fase comum.....	62
Figura 12 - Modelo de Regressão.....	67
Figura 13 - Cenário utilizado para a coleta de dados.....	69
Figura 14. Melhores Coeficientes de Relação obtido em cada série.....	70
Figura 15 - Resposta do Modelo de Regressão com o método de Função Polinomial com uma variável de entrada (t_{min}).....	73
Figura 16 - Resposta do Modelo de Regressão com o método de Função Polinomial com duas variáveis de entrada (t_{min} e nf).....	75
Figura 17 - Variação do coeficiente de relação tendo em conta a variação do número de faixas	75
Figura 18 - Resposta do Modelo de Regressão com o método de Redes Neurais Artificiais com 3 variáveis de entrada (d , v , nf).....	77
Figura 19 - Comparação da resposta obtida no modelo de regressão (Redes Neurais Artificiais) com a resposta obtida na coleta de dados.....	77
Figura 20 - Mapa do cenário escolhido.....	81
Figura 21 - Cenário escolhido representado no simulador.....	81
Figura 22 – Trecho do cenário escolhido.....	84
Figura 23 - Tempo Médio de Viagem sob demanda baixa de veículos.....	90
Figura 24 - Tempo Médio de Viagem sob demanda média de veículos.....	91
Figura 25 - Tempo Médio de Viagem sob demanda intensa de veículos.....	93
Figura 26 - Nível de Ocupação das Vias sob demanda baixa de veículos.....	94
Figura 27 - Nível de Médio de Ocupação das Vias sob demanda baixa de veículos.....	94
Figura 28 - Nível de Ocupação das Vias sob demanda média de veículos.....	95
Figura 29 - Nível de Médio de Ocupação das Vias sob demanda média de veículos.....	96
Figura 30 - Nível de Ocupação das Vias sob demanda intensa de veículos.....	97
Figura 31 - Nível de Médio de Ocupação das Vias sob demanda intensa de veículos.....	97

LISTA DE TABELAS

Tabela 4-1. Valores das variáveis de entrada	68
Tabela 4-2. Valores iniciais dos parâmetros do algoritmo BiNN	69
Tabela 4-3. Resultados da série de simulação com $d = 50, v_{max} = 40, nf = 3$	70
Tabela 4-4. Dados obtidos na coleta	71
Tabela 4-5. Coeficientes obtidos da Função Polinomial de duas variáveis	74
Tabela 5-1. Valores iniciais dos coeficientes sinápticos	82
Tabela 5-2. Relações entre as intersecções.....	84
Tabela 5-3. Distância entre intersecções vizinhas (metros).....	85
Tabela 5-4. Velocidade máxima permitida na via (km/h)	85
Tabela 5-5. Número de faixas da via comum	85
Tabela 5-6. Tempos mínimos para o novo fluxo de veículos chegar na intersecção seguinte.	86
Tabela 5-7. Valores do CR calculados pelo método P1V	86
Tabela 5-8. Valores do CR calculados pelo método P2V	86
Tabela 5-9. Valores do CR calculados pelo método RNA	87
Tabela 5-10. Configuração das fases das intersecções para o CFP	88
Tabela 5-11. Descrição das simulações.	89

Sumário

Resumo.....	1
Abstract	3
LISTA DE ILUSTRAÇÕES.....	4
LISTA DE TABELAS.....	5
Capítulo 1.....	8
1 Introdução	8
1.1 Problema	10
1.2 Justificativa e Motivação	13
1.3 Objetivos.....	16
1.4 Hipóteses	16
1.5 Metodologia	18
1.6 Atividades	19
Capítulo 2.....	20
2 Fundamentação conceitual	20
2.1 Fundamentos em Controle de Trânsito Urbano	20
2.2 Níveis de análises em Controle de Trânsito Urbano	22
2.2.1 Nível Submicroscópico	22
2.2.2 Nível Microscópico	23
2.2.3 Nível Mesoscópico.....	23
2.2.4 Nível Macroscópico	24
2.3 Arquiteturas para o Controle do Trânsito Urbano	25
2.4 Parâmetros utilizados no Controle do Trânsito Urbano e na avaliação do desempenho. 26	
2.5 Fundamentos das técnicas aplicadas ao controle do trânsito urbano.....	27
2.5.1 Fundamentos teóricos de métodos baseados em Controle Ótimo	28
2.5.2 Fundamentos teóricos de métodos baseados em Inteligência Artificial	30
Capítulo 3.....	38
3 Trabalhos relacionados ao Controle de Trânsito Urbano	38
3.1 Primeiras abordagens.....	38
3.2 Controle multiagente de interseções.....	40
3.3 Metodologias aplicadas ao Controle do Trânsito Urbano.....	41
3.3.1 Trabalhos relacionados baseados em Controle Ótimo	42
3.3.2 Métodos baseados em Inteligência Artificial	46
3.4 Modelo de Redes Neurais Bio-Inspiradas.....	52
3.4.1 Estrutura e dinâmica	53

3.4.2	Princípios Fundamentais	54
3.4.3	Determinação dos parâmetros da rede e análise de estabilidade.....	58
Capítulo 4.....		60
4	Modelo proposto.....	60
4.1	Modelo de Rede Neural Bio-Inspiradas para o Controle Multiagente.....	61
4.1.1	Estrutura do modelo para o controle multiagente	61
4.1.2	Determinação dos parâmetros da Rede Neural Bio-Inspirada para a coordenação entre agentes.....	64
4.2	Coeficiente de Relação entre duas intersecções.....	66
4.2.1	Regressão	66
4.2.2	Coleta de dados	67
4.2.3	Cenário e Simulações.....	68
4.2.4	Dados coletados	69
4.3	Modelos de Regressão	72
4.3.1	Função Polinomial com uma variável.....	72
4.3.2	Função Polinomial com duas variáveis.....	74
4.3.3	Rede Neural Artificial.....	75
4.4	Algumas considerações sobre as funções de regressão	78
Capítulo 5.....		79
5	Prova de conceito	79
5.1	Cenário	79
5.2	Determinação dos parâmetros de controle	81
5.3	Cálculo dos parâmetros da extensão proposta ao modelo BiNN	83
5.4	Simulações.....	87
5.5	Avaliação dos indicadores de desempenho	90
5.5.1	Tempo Médio de Viagem (TMV) dos veículos.....	90
5.5.2	Nível de Ocupação das Vias (NOV).....	93
5.6	Considerações sobre os resultados	97
6	Conclusões.....	100
Referências		103

Capítulo 1

1 Introdução

O desenvolvimento e o crescimento das grandes cidades de hoje são governados pela economia e pelo desenvolvimento social. Isso explica como a população urbana aumentou significativamente nos últimos anos e de acordo com United Nations (2017). Segundo este relatório, em 2007, a população urbana excedeu à população rural, sugerindo que até o ano 2050, a população urbana vai representar 70% da população mundial. Deste modo, os pesquisadores procuram novas soluções que visam resolver os desafios trazidos pelo problema da superlotação nos grandes centros urbanos. Por esta razão, muitas pesquisas são realizadas para conseguir um desenvolvimento sustentável nas grandes cidades de hoje, em matérias tais como: energia, segurança, moradia, saúde e mobilidade (VIT et al., 2015; ARROUB et al., 2016; HERNAFI; AHMED; BOUHORMA, 2016).

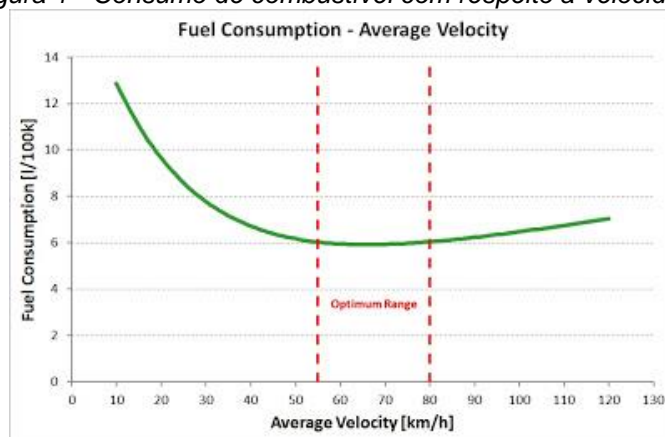
A mobilidade é uma questão fundamental para o desenvolvimento urbano das cidades. As soluções para os problemas relacionados com essa área ainda são um desafio para os pesquisadores. Quando o número de pessoas em um espaço aumenta, também aumenta a movimentação de pessoas para conseguir chegar em seus trabalhos, casas, etc., o que traz como consequência um aumento no trânsito de veículos, sendo um sério problema enfrentado hoje nas grandes cidades (VON STRITZKY; CABRERIZO, 2011).

O engarrafamento do trânsito provoca vários problemas tanto nos indivíduos quanto na sociedade. Segundo o estudo realizado por Alves Jr, (2012) os engarrafamentos de trânsito diários refletem diretamente na qualidade de vida dos indivíduos. O medo de ficar preso, impossibilitado de não conseguir se movimentar, somado às preocupações e horários a serem cumpridos no dia a dia, além dos fatores meteorológicos caracterizados pelo calor, frio, sol, chuva, neblina, etc., conduz o indivíduo à perda do humor, irritabilidade e extrema agressividade. Tudo colabora para o aumento do desgaste físico e mental, gerando ao longo do tempo sensações de desconforto. Dependendo

das características dos indivíduos, tais fatores são mais ou menos evidentes. Existe uma doença conhecida como “*Transtorno Explosivo Intermitente*” capaz de transformar o desconforto em agressividade, partindo muitas vezes para o corpo a corpo e a utilização de armas. Segundo este estudo nos últimos anos as patologias psiquiátricas, psicológicas e psicossomáticas referentes ao trânsito nos grandes centros aumentaram em 17% com respeito ao valor do ano 2000 (ALVES JR, 2012).

Por outra parte, Jayasooriya e Bandara (2017) afirmam que o engarrafamento do trânsito nas vias interrompe e reduz o nível de produtividade e é um símbolo da depressão econômica. Nessa pesquisa o autor ressalta os dois fatores chaves derivados deste problema: perda de tempo de produtividade da força de trabalho e o custo operacional que se baseia no consumo excessivo de energia (combustível). O primeiro ponto provoca atrasos nos horários de chegadas de trabalhadores e mercadorias nos seus destinos, reduzindo o tempo de trabalho útil e a produção ou venda de bens. O consumo excessivo de energia pode se fundamentar com um estudo de consumo de combustível contra a velocidade média dos veículos realizado por Samaras (2012), no qual é apresentada a faixa de velocidade ótima para um consumo mínimo de energia, entre 55 e 80 km/h, Figura 1, enquanto veículos com velocidades médias menores do que 20 km/h estão no ponto de maior consumo de combustível. Conforme estudos anteriores, os veículos que ficam presos em engarrafamentos do trânsito não atingem velocidades médias superiores à 20 km/h (KHAMIS; GOMAA; EL-SHISHINY, 2012; MURCIA; HIRAKAWA; CASTRO, 2017).

Figura 1 - Consumo de combustível com respeito à velocidade.



Fonte: (SAMARAS, 2012)

Outra consequência provocada pelas situações dos engarrafamentos do trânsito nos grandes centros urbanos é a poluição do ar mediante a emissão de gases tóxicos como monóxido de carbono, óxidos de nitrogênio, hidrocarbonetos, metano, etc. Segundo Battista e Vollaro (2017), nos últimos anos muitos estudos epidemiológicos mostraram associações entre as concentrações de poluentes do ar e a saúde humana. Só em 2016, aproximadamente 3 milhões de mortes foram vinculadas à exposição da poluição do ar. Além disso, a crescente urbanização modificou as condições microclimáticas das cidades e, juntamente com o trânsito, levou a um desconforto das condições de vida. Por outra parte, um estudo realizado por Liu et al. (2017) demonstrou que nos períodos de ignição do motor e de aceleração dos veículos aumentam os picos máximos de ácidos nitrosos emitidos ao meio ambiente. Portanto, em condições de engarrafamento do trânsito, nas quais os veículos têm que acelerar e desacelerar continuamente, a emissão de poluentes na atmosfera pode se agravar.

Para resumir, podemos dizer que o problema do engarrafamento do trânsito é um desafio para a sociedade, tanto do ponto de vista individual com doenças físicas e psíquicas, quanto do ponto de vista financeiro e ambiental para a sociedade.

1.1 Problema

O aumento da infraestrutura de estradas e rodovias, o transporte público e o controle inteligente nas interseções das ruas são algumas das ações a serem executadas para resolver os problemas de mobilidade. A primeira solução requer grandes orçamentos para seu desenvolvimento, por exemplo, o orçamento inicial do trecho norte de 43 quilômetros do Rodoanel Mario Covas, no estado de São Paulo, foi de R\$ 6,11 bilhões segundo um relatório do Tribunal de Contas da União em 2013 (CARREIRO, 2013). A segunda solução é a principal para o desenvolvimento dos centros urbanos, mas os ônibus embora diminuam o trânsito de forma geral, também somam grandes quantidades de veículos às vias. Já os outros tipos de transporte públicos como

trens, metrô e trilhos precisam também de grandes orçamentos e um longo tempo para a construção da sua infraestrutura.

Portanto a terceira solução é uma alternativa econômica e rápida para melhorar a eficiência do sistema, ou seja, aumentar a capacidade de locomoção na cidade com a mesma infraestrutura urbana. Os fluxos de veículos otimizados reduzem as paradas de veículos nas interseções com sinais de trânsito, aumentando as suas velocidades médias de deslocamento e, portanto, os seus tempos médios de deslocamento, reduzindo os engarrafamentos.

Os semáforos são os dispositivos comumente utilizados para controlar interseções e regular os tempos que cada fase ficará ativa. Portanto, um ajuste ideal do tempo de cada fase pode ajudar consideravelmente na mobilidade das cidades, podendo evitar engarrafamentos nas vias (CASTRO; MARTINI; HIRAKAWA, 2014; DE OLIVEIRA; NETO, 2014; KAUR; AGRAWAL, 2014; ARAGHI; KHOSRAVI; CREIGHTON, 2015; XU et al., 2015; DIVEEV; SOFRONOVA; MIKHALEV, 2016; ELGAREJ; KHALIFA; YOUSSEFI, 2016). Para conseguir esse tempo ideal de ajuste de cada fase muitas pesquisas têm sido desenvolvidas. A maioria dos autores concorda em que se deve possuir um controlador presente em cada intersecção entre vias e receber informações de sensores sobre o nível de ocupação das vias em forma geral para determinar o tempo de duração do sinal verde, que significará a ativação da fase correspondente. Abordagens desenvolvidas tanto por métodos de Controle Ótimo quanto por métodos de Inteligência Artificial tem sido utilizadas pelos pesquisadores.

Segundo Srinivasan, Choy e Cheu (2006); Jin e Ma (2017) e Liu et al. (2017), o trânsito urbano é um sistema dinâmico complexo, com uma natureza imprevisível e estocástica, tornando a tarefa de otimizar um controle adequado bem mais difícil. Assim, encontrar uma solução definitiva que só possua vantagens em relação as outras pressupõe-se complicada demais. Na literatura podemos encontrar diversas definições de “sistemas dinâmicos complexos” como consequência das diferentes características que esses tipos de sistemas apresentam. Segundo Bresciani (2013) os Sistemas Dinâmicos Complexos (SDC) são aqueles com estruturas geralmente com elevado número de

agentes com relações e interconexões múltiplas e hierarquizadas entre eles e com o ambiente. Estas relações são caracterizadas pelo surgimento de novos padrões organizacionais, além de cada agente ter vários graus de liberdade e diferentes funcionalidades. Conseqüentemente, os sistemas complexos são representados na maioria dos casos por equações não lineares.

Há uma grande quantidade de áreas de pesquisas nas quais podemos encontrar este tipo de sistemas, alguns exemplos segundo Bresciani (2013), são:

- Física: mecânica quântica, dinâmica de polímeros, sistemas não lineares para compreender os princípios básicos da modelagem, matemática aplicada para sistemas biológicos, etc.
- Engenharia e Computação: modelagem baseada em agentes e computação evolucionária, reconhecimento de padrões, etc.
- Biologia: biologia celular e molecular, redes genéticas, etc.
- Economia: sistemas econômicos (como mercado de ações) com processos estocásticos, fenômenos sociais complexos.

Como foi apresentado anteriormente, o trânsito urbano é um sistema dinâmico complexo por cumprir todas as questões dessa definição, fazendo referência a sistemas dinâmicos estocásticos e não lineares, com variáveis dependentes do tempo, tanto do sistema quanto de entrada, e com agentes que possuem relações de interdependência.

Outra característica deste sistema é a sua dinâmica não linear, que se reflete na ativação e desativação de vias pelos semáforos, causando períodos de interrupção nos fluxos de veículos. Além de fatores como chuvas, alagamentos, buracos nas vias e frenagens inesperadas de veículos que tornam o sistema de trânsito estocástico.

Aliás, o trânsito urbano possui tanto observabilidade quanto atuação parcial, o que adiciona complexidade ao sistema, atrapalhando ainda mais a predição do seu comportamento. Essa característica corresponde ao fato de que as ações dos motoristas não podem ser antecipadas por simples observação, assim como a tomada de decisão dos controladores afeta o comportamento do sistema de forma indireta. O fato de um semáforo estar com

seu sinal verde não permite definir com exatidão o número de veículos que irão atravessar a intersecção por ele controlada.

Portanto não existe uma posição comum entre os autores sobre qual método de controle utilizar para obter a melhor resposta. Até agora nenhum método atende a todas as características e requisitos ou não tem a melhor resposta para os diferentes cenários. Podemos dizer que ainda existe muita discussão sobre qual método deve ser o indicado para o controle do trânsito urbano.

A seguir desenvolvem-se várias **perguntas para pesquisar e tentar solucionar a situação problema.**

- Existe um método para o controle do trânsito urbano capaz de atender a todos os requisitos?
- Qual método utilizar para tentar resolver todos os requisitos deste tipo de sistema?
- Que tipo de controle utilizar neste caso, distribuído ou centralizado?
- O tempo de resposta dos algoritmos poderá influenciar na hora de efetuar um controle efetivo?

1.2 Justificativa e Motivação

Em geral, segundo Jing, Huang e Chen (2017), as estratégias utilizadas para controlar o tempo de ativação das luzes verdes dos semáforos dividem-se em três tipos: tempo fixo, atuado e adaptativo. O controle do semáforo com tempo fixo utiliza os dados históricos de trânsito para determinar a configuração dos tempos e é predefinido por um estudo anterior das condições de cada via da interseção. Webster (1958) propôs uma fórmula baseada na taxa de fluxo de cada pista em uma interseção para resolver esse problema. Esta fórmula é útil para encontrar um ciclo ótimo e uma duração apropriada para o tempo verde em cada fase. No entanto, de acordo com Ni (2016), na realidade, a demanda de trânsito é imprevisível e flutua no tempo. Portanto as configurações de parâmetros com tempos fixos não podem atender ao requisito

de condições de trânsito que mudam rapidamente, como acidentes e outros distúrbios que podem modificar as condições de trânsito.

Enquanto isso, o controle de sinal atuado ou também chamado de acionados por veículos, é geralmente aplicado para interseções isoladas. Para esse tipo de controle precisa-se de uma coleta de dados do trânsito em tempo real por meio de sensores, como o tempo de separação entre um veículo e o próximo. Esses controladores alteram as temporizações das luzes dos semáforos com base em um conjunto de parâmetros estáticos predefinidos, como tempo mínimo e máximo de luz verde, duração total do ciclo de luzes verdes do semáforo e a sequência de fase. A detecção é útil para se ter uma ideia da eficiência do tempo de verde. A ativação do tempo de verde acaba quando o espaço entre os veículos é maior que o intervalo máximo do limiar (ZHAO-SHENG YANG et al., 2005).

As estratégias de controle adaptativas utilizam dados de sensores como o nível de ocupação das vias para estimar o fluxo de trânsito como entrada no sistema. Esta estratégia visa implementar uma temporização ideal para maximizar ou minimizar uma função objetivo (MCKENNEY; WHITE, 2013).

Porém as pesquisas anteriores relacionadas a estratégias de controle do tipo adaptativas para o Trânsito Urbano têm limitantes comuns, como: a simplificação dos dados e a linearização da sua dinâmica, além da discretização do problema em ciclos, trazendo como consequência a perda de dados importantes da dinâmica do sistema (ARAGHI; KHOSRAVI; CREIGHTON, 2015).

Os sistemas de controle adaptativos podem-se dividir em: controle preditivo, lógicas difusas e métodos de aprendizado e cada tipo de controle tem limitações particulares. Segundo Gokulan e Srinivasan (2010) os métodos preditivos falham em prever situações do trânsito, a maioria é pouco preciso, principalmente provocado pela complexidade do sistema e o número de incertezas que apresentam.

No entanto, métodos baseados no aprendizado, como redes neurais artificiais ou métodos de aprendizado por reforço, precisam de uma quantidade elevada de dados, normalmente impossível de se obter, além de um tempo de

treinamento para representar o comportamento de sistemas estocásticos e com grande número de variáveis com fidelidade e controlá-los com eficiência (GOKULAN; SRINIVASAN, 2010; TETTAMANTI et al., 2014).

O último grupo, controladores difusos ou baseados em lógica, apesar de não utilizar modelos matemáticos para prever o comportamento do trânsito, representam o conhecimento sobre o sistema de forma simples mas têm dificuldade em incorporar informações sobre a dinâmica do sistema devido à sua complexidade. Além disso, a definição das regras de controle e de seus parâmetros não é ótima, pois o ponto ótimo de operação dos sistemas complexos é variável e depende de variáveis externas não controladas que são captadas ineficientemente, pois as informações são incompletas e imprecisas (GOKULAN; SRINIVASAN, 2010; YU; WU; YANG, 2016).

Em decorrência das limitações anteriores, Castro, Martini e Hirakawa (2014) propuseram um modelo de Redes Neurais Bio-Inspiradas (BiNN) para o Controle de Trânsito Urbano, baseado em estudos anteriores deste tipo de modelo para o controle de robôs (NICHOLS; MCDAID; SIDDIQUE, 2013; YU et al., 2014). Estes modelos enfatizam as características biológicas de neurônios reais para melhorar o comportamento dinâmico geral, enquanto se concentram no aspecto de aprendizagem das redes neurais. De tal modo, os modelos BiNN geralmente não possuem um estágio de treinamento, em vez disso, escolhem seus pesos sinápticos para alcançar um comportamento desejado. Nichols, Mcdaid e Siddique (2013) e Yu et al. (2014) apresentaram resultados satisfatórios como: a estabilidade dinâmica frente a distúrbios e a capacidade de adaptação instantânea a mudanças no ambiente de atuação, características desejadas para o Controle do Trânsito Urbano.

O modelo proposto por Castro, Martini e Hirakawa (2014), consegue monitorar continuamente o status do sistema e tomar decisões, analisando o comportamento do sistema dinâmico complexo e avaliando seu desempenho de controle. Do mesmo modo, o modelo não apresenta uma ordem pré-fixada de fases de semáforo e, portanto, é capaz de alterar o comportamento de controle de acordo com o estado do trânsito urbano. A proposta foi melhorada por Castro et al. (2015) estabelecendo um conceito de sistema multiagente, permitindo o controle coordenado de vários cruzamentos. Para conseguir esse

objetivo, cada agente controla uma única intersecção e interage com os agentes vizinhos para obter um controle coordenado dos vários cruzamentos. A proposta impede a saturação das vias e coordena as atividades dos agentes vizinhos provocando ondas de luzes verdes nos semáforos.

Um fator limitante daquela pesquisa encontra-se nos coeficientes utilizados para a coordenação entre os controladores de semáforos nas interseções. No modelo, os coeficientes de relação são todos iguais, não diferenciam como é a relação entre esses controladores. Lembrando que cada controlador controla uma interseção, esta relação pode variar dependendo das características físicas como: as distâncias entre as interseções, a configuração das interseções, as características da via comum entre essas interseções e a velocidade média atingida pelos veículos nessa via que pode influir no tempo de demora dos veículos para chegar na interseção vizinha. Esta primeira limitação conduz a uma segunda limitação: os cenários escolhidos para analisar os resultados do modelo exibem uniformidade nos seus desenhos (as distâncias entre as interseções são todas iguais), além de contar com um pequeno número de interseções com semáforos, bem distantes dos cenários reais encontrados nos grandes centros urbanos. Portanto não fornecem uma ideia real dos resultados que poderiam se conseguir levando a proposta à prática.

1.3 Objetivos

O objetivo deste trabalho é estender o modelo de Redes Neurais Bio-inspiradas anteriormente proposto, adicionando informações e o comportamento para torná-lo aderente às diferenças existentes entre as interseções do cenário real de trânsito. Para isso, considera-se a inclusão, ao modelo, dos fatores: distância entre as interseções, velocidade dos veículos e número de faixas da via comum entre essas interseções.

1.4 Hipóteses

A partir das revisões bibliográficas realizadas, a pesquisa teórica e os objetivos traçados, estabeleceu-se as seguintes hipóteses:

1. As grandes cidades apresentam sérios problemas de congestionamento do trânsito, o qual pode ser aliviado com o controle de semáforos, isto diminuiria o tempo de espera nas filas do semáforo dos veículos e aumentaria a sua velocidade média.
2. A natureza imprevisível e estocástica da demanda do trânsito torna difícil a tarefa de encontrar e otimizar um controle adequado das fases do semáforo.
3. As pesquisas encontradas na bibliografia apresentam limitações, nenhum método atende a todas as características e requisitos para este tipo de sistemas.
4. Na atualidade as pesquisas referentes ao controle do sinal do semáforo estão divididas principalmente em dois grupos: Controle Ótimo e Inteligência Artificial. Até este momento os métodos utilizados apresentam deficiências, como:
 - A análise realizada do ponto de vista independente de cada semáforo, não analisando a inter-relação que existe entre os agentes que controlam cada semáforo;
 - Os algoritmos que se baseiam em equações lineares finitas limitam-se em realizar um cálculo para obter os parâmetros, provocando um aumento da complexidade computacional, resultando em um tempo longo para a resposta;
 - As limitações dos algoritmos baseados em redes neurais e lógica difusa não incluem um tratamento diferenciado para cada intersecção. Não consideram os parâmetros individuais dos semáforos para construir os modelos, como: quantidades de faixas na via, opções que têm os motoristas na intersecção (seguir em frente, virar à esquerda ou direita, etc.), quantidade de fases da intersecção, etc.
5. O modelo BiNN propõe um modelo dinâmico do trânsito com controle distribuído, coordenação entre os agentes de cada intersecção e o cálculo individualizado dos parâmetros desses agentes de controle das intersecções, em dependência das variáveis de entrada, como resposta às características estocásticas deste problema.

6. O modelo BiNN consegue eliminar a maioria das limitações das pesquisas anteriores, mas ainda apresenta algumas. Este modelo não analisa a relação entre os agentes de forma particular, ele observa este problema de forma geral, mas esta relação varia entre interseções dependendo das suas características físicas, como: as distâncias entre as interseções, a configuração das interseções, as características da via comum entre essas interseções e a velocidade média atingida pelos veículos nessa via que pode influir no tempo de demora dos veículos para chegar na interseção vizinha.
7. Se obtiver um coeficiente de relação que consiga descrever a relação entre os agentes de controle de cada interseção, analisando as suas características físicas individuais, conseguimos melhorar a resposta do modelo, melhorando parâmetros como: o tempo médio de viagem dos veículos e o nível de ocupação das vias, diminuindo o problema do congestionamento nos grandes centros urbanos.

1.5 Metodologia

A metodologia deste trabalho compreende a utilização do Modelo de Redes Neurais Bio-Inspiradas proposto anteriormente no grupo de pesquisa. O modelo BiNN proposto por Castro, Martini e Hirakawa (2014) consegue trabalhar com as características dinâmicas do fluxo de veículos e utiliza uma abordagem distribuída com controle multiagente. A proposta adota uma abordagem modular, na qual o modelo geral para o controle das fases semaforicas de uma intersecção pode ser aplicado em todas as intersecções. Existindo apenas diferenças estruturais na BiNN aplicada a cada intersecção, o que é reflexo das características específicas de cada intersecção.

Partindo do modelo BiNN, esta proposta adiciona características da rede de trânsito tais como: a distância entre as interseções, velocidade dos veículos e número de faixas da via comum entre essas interseções para diferenciar as relações de coordenação entre as interseções. A principal tarefa baseia-se no estabelecimento de uma forma de incorporar essas informações sem modificar

o comportamento do modelo como a estabilidade da rede neural e a complexidade computacional escalar demonstradas por Castro et al. (2015).

Para adicionar essas características ao modelo e diferenciar a relação de coordenação entre interseções realiza-se um estudo para determinar quanto influi cada fator no atraso médio do fluxo de veículo entre duas interseções, que é o tempo que demoram os veículos para sair de uma interseção e chegar até a interseção vizinha. Como a distância entre as interseções, a velocidade média dos veículos, e o número de faixas da via comum entre essas interseções não mudam com respeito ao tempo, pode-se realizar um cálculo off-line para obter esse valor. Portanto, este parâmetro será utilizado para obter um coeficiente de ativação da fase comum de uma interseção vizinha.

Para analisar e validar a extensão proposta ao modelo, simulações são realizadas em um cenário réplica de um cenário real do centro da cidade de São Paulo com a ajuda de um software de simulação microscópica de trânsito (SUMO). Tanto o cenário quanto as demandas de veículos utilizam informações provenientes dos órgãos do setor de trânsito da cidade.

1.6 Atividades

Partindo da metodologia proposta e para atingir os objetivos e validar as hipóteses foi estabelecida a seguinte lista de atividades:

1. Realizar um estudo sobre as limitações e competências dos trabalhos relacionados ao controle do trânsito urbano.
2. Definir o quanto afeta cada característica da rede de trânsito na relação de coordenação entre os agentes de controle das interseções.
3. Determinar um coeficiente que defina essa relação entre os agentes vizinhos, tendo em conta características físicas da rede de trânsito urbano.
4. Modelar um cenário adequado com características semelhantes a cenários reais para avaliar o modelo proposto.
5. Realizar a simulação do modelo proposto no cenário criado para analisar os resultados obtidos nessas simulações.

Capítulo 2

2 Fundamentação conceitual

Neste capítulo são revisados alguns conceitos fundamentais necessários para a compreensão das discussões realizadas ao longo do trabalho. São apresentados os conceitos relacionados ao Controle de Trânsito Urbano, os níveis utilizados para o seu estudo, as arquiteturas encontradas na bibliografia para o controle deste tipo de sistema, os parâmetros de controle e os parâmetros utilizados para avaliar o desempenho, além das noções teóricas sobre os diferentes métodos encontrados na bibliografia, utilizados para tratar o Controle de Trânsito Urbano.

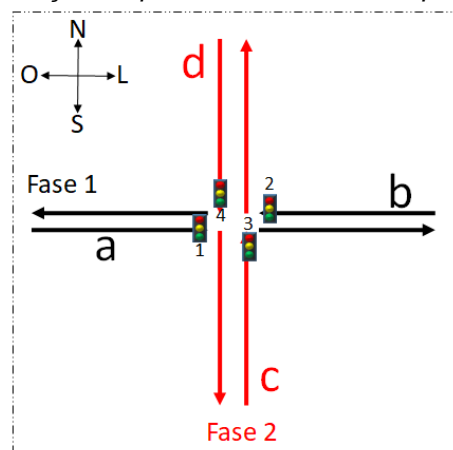
2.1 Fundamentos em Controle de Trânsito Urbano

Para entender como o desenvolvimento do Controle do Trânsito Urbano, apresentam-se a seguir alguns conceitos utilizados neste trabalho.

Uma interseção é o espaço físico onde existe um cruzamento entre vias (Figura 2). As interseções, dependendo do nível de trânsito e da prioridade das vias podem utilizar, semáforos ou não, para controlar o trânsito. Cada semáforo controla normalmente um ou vários sentidos (uma fonte para um destino ou uma fonte para vários destinos) do movimento dos veículos (semáforos 1, 2, 3 e 4 da Figura 2). Em cada interseção os semáforos precisam agir com sincronização (liberar ou fechar o movimento dos veículos das diferentes vias no momento preciso) para não provocar um caos no trânsito. A sincronização e o ajuste ideal do tempo desse conjunto de semáforos, em uma interseção, é controlada por um agente de controle de interseções, sendo este o responsável pelos ciclos semaforicos de cada interseção. Um ciclo semaforico compreende o conjunto de fases que podem se tornar ativas em uma interseção. As fases de um ciclo semaforico são definidas como uma unidade temporizada, associada ao controle de um ou mais movimentos do veículo previamente configurados. Cada fase ativa significa uma configuração de luzes no conjunto de semáforos de uma interseção, que liberam o movimento dos veículos de uma via para outra, além de fechar o movimento para o deslocamento de

outros veículos. Em uma interseção, apenas uma fase pode estar ativa por vez, portanto no exemplo da Figura 2, o ciclo semaforico tem duas fases, a fase 1 libera o movimento dos veículos tanto no sentido oeste-leste (a) quanto leste-oeste (b), enquanto a fase 2 desta interseção libera o movimento dos veículos nos sentidos sul-norte (c) e norte-sul (d). Por último, a fase principal de uma interseção é aquela que apresenta, historicamente, um maior fluxo de veículos. O restante das fases são chamadas secundárias.

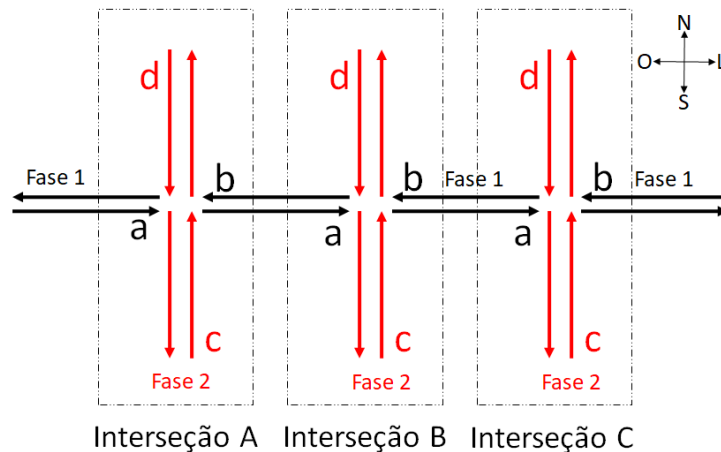
Figura 2 - Interseção simples com duas fases e quatro semáforos



Fonte: autor

Como foi apresentado anteriormente, cada interseção é controlada por um agente, mas além disso, cada interseção (agente) interage com as suas interseções vizinhas (agentes vizinhos), tanto recebendo quanto enviando informações de fluxos de veículos por meio das vias que as interconectam (vias comuns entre interseções vizinhas). Um exemplo, na Figura 3 a interseção A é vizinha da interseção B e vice-versa, portanto, a interseção B é vizinha da interseção C e vice-versa também. Aliás, as fases que ativam o movimento de veículos pelas vias comuns entre interseções vizinhas são chamadas de fases comuns entre duas interseções, (a fase 1 é comum nas interseções A, B e C, no entanto a fase 2 não é uma fase comum entre essas interseções porque os veículos não deslocam-se por vias comuns entre essas interseções). Por último, para provocar ondas de luzes verdes em interseções vizinhas, as fases comuns devem-se sincronizar para se tornarem ativas em um instante semelhante. Na Figura 3, as fases 1 das interseções A, B e C devem-se sincronizar.

Figura 3 - Interseções vizinhas com fases comuns.



Fonte: autor


2.2 Níveis de análises em Controle de Trânsito Urbano

Segundo Kumar et al. (2014), os modelos para o Controle de Trânsito Urbano podem ser classificados de acordo com o nível de detalhes para representar o sistema, dependendo do nível de descrição da informação nos modelos. Com base nessa análise, os modelos de trânsito podem ser categorizados em quatro tipos: submicroscópico, microscópico, mesoscópico e macroscópico. A diferença entre esses níveis de análise é a forma como os veículos são matematicamente modelados para representar seu papel no sistema de trânsito. Cada nível de análise predomina em um campo de aplicação. Os níveis macro- e mesoscópico são mais utilizados em sistemas de controle por causa de sua simplicidade matemática, enquanto os níveis micro- e submicroscópicos são predominantes em sistemas de simulação, por causa de uma maior fidelidade à dinâmica real dos veículos.

2.2.1 Nível Submicroscópico

No nível submicroscópico (Figura 4) estuda-se a dinâmica do veículo em particular e a dinâmica muda em resposta às características intrínsecas do veículo como: dimensões, número de rodas, tipo de motor, desenho do veículo. Mas também essa dinâmica é regulada por variáveis como aceleração, frenagem, direção do movimento e comportamento do motorista. Neste nível analisam-se as dinâmicas como: a tração aplicada às rodas do veículo, o deslizamento, a direção da roda e a dinâmica longitudinal, lateral e de giros de um veículo em particular (LAMOTTE et al., 2010).

Figura 4 - Análise submicroscópico.




Fonte: autor

2.2.2 Nível Microscópico

No nível microscópico do fluxo de trânsito são analisadas as interações entre os veículos. É um modelo de acompanhamento de veículos, no qual o veículo líder influencia o comportamento do veículo que o segue na fila de veículos. Como mostrado na Figura 5, o veículo líder é n , e o veículo seguidor é $n+1$; x_n e x_{n+1} representam as posições dos veículos líder e seguidor, respectivamente, em relação a um quadro de referência. L_n e L_{n+1} representam os comprimentos dos veículos líder e seguidor, respectivamente. O movimento relativo do veículo seguidor depende do movimento do veículo líder, e o veículo seguidor sempre tenta manter uma separação segura mínima (inter distância s) com o veículo líder (FANG; SHI; CAO, 2015).

Figura 5 - Análise microscópico.




Fonte: autor

2.2.3 Nível Mesoscópico

No nível mesoscópico do fluxo de trânsito os veículos não são vistos como entidades separadas e o efeito agregado de cada um deles é analisado do ponto de vista de fila de veículos para calcular os valores médios das variáveis macroscópicas para o trânsito (fluxo, velocidade média e densidade), Figura 6 (x_1 , v_1 , a_1). Essas variáveis normalmente são medidas ao longo de um comprimento. Um exemplo dessa modelagem foi proposta por Peng, Liu e Tuo

(2015) por meio da qual analisa-se a probabilidade da interrupção do trânsito em um modelo de rede com uma estrada de duas pistas.



2.2.4 Nível Macroscópico

Segundo Lin, Xi e Yang (2008), a análise macroscópica do sistema de trânsito urbano estuda o sistema como a inter-relação entre as vias por onde circulam os veículos e as interseções, as quais são tratadas como nós nas redes urbanas, Figura 7. Nesse sistema consideram-se como variáveis a quantidade de veículos em cada nó q (interseção) e os fluxos de veículos entre os nós f . Para este tipo de sistema Wen, Qu e Zhang (2009) apresentaram a equação de conservação de veículos para o processo de fluxo de trânsito associado a qualquer fluxo de movimento em uma interseção que é amostrada a cada Δt segundos como apresentada na equação (1). Nessa equação, a quantidade de veículos q de um nó em um instante $t+1$ é dada pela soma da quantidade de veículos presentes no instante t com os fluxos de veículos que chegam ao nó, f_i , subtraído dos fluxos de veículos que partem dele, f_j . Dessa maneira, os veículos se deslocam de nó em nó e a quantidade total de veículos na rede é conservada.

Figura 7 - Análise macroscópica.



Fonte: autor

$$q^{t+1} = q^t + \sum_i^N f_i - \sum_j^M f_j \quad (1)$$

2.3 Arquiteturas para o Controle do Tráfego Urbano

Segundo Vrancken e Dos Santos Soares (2007), sistemas com subsistemas podem ser utilizados, para o controle, em uma abordagem com arquiteturas: centralizada, hierárquica ou distribuída. No caso do sistema de tráfego urbano, analisa-se o problema de forma que a unidade básica do sistema são as interseções entre vias, como tem sido apresentado por vários autores (SRINIVASAN; CHOY; CHEU, 2006; CASTRO et al., 2015; MURCIA et al., 2017).

Uma estrutura centralizada utiliza um controlador para cada unidade básica de controle (agente de controle para cada interseção) e esses controladores comunicam-se com um controlador central, o qual responsabiliza-se pela tomada de decisão. Enquanto em uma estrutura do tipo distribuída, os agentes de controle de cada interseção podem-se comunicar com os agentes de interseções vizinhas. Nesta estrutura não existe um

controlador central, pois os agentes relacionam-se entre eles para obter um controle coordenado. Por último, na estrutura hierárquica, além de existir a inter-relação entre agentes vizinhos, também existem controladores de níveis intermediários, que têm a possibilidade de adicionar informações ao controle de tipos locais, regionais ou globais e desempenhar diferentes funções.

2.4 Parâmetros utilizados no Controle do Trânsito Urbano e na avaliação do desempenho.

No sistema de trânsito urbano os principais parâmetros utilizados para o controle são: o tempo do ciclo semaforico em uma interseção e o tempo de cada fase ativa (tempo de luz verde para cada fase) nesse ciclo semaforico, os quais conforme a pesquisa realizada por Zhao, Dai e Zhang (2012), são os fatores com maior influência no controle de uma interseção. Cada método de controle baseia-se em um conjunto de variáveis diferentes do sistema de trânsito urbano.

A variável mais utilizada na bibliografia é o cumprimento da fila de veículos em cada fase de semáforo, ou também chamado nível de ocupação da via (SRINIVASAN; CHOY; CHEU, 2006; HAMILTON et al., 2014; KAUR; AGRAWAL, 2014; DUSPARIC; MONTEIL; CAHILL, 2016). Uma outra variável relacionada e bem empregada nas pesquisas é o fluxo de veículos em cada fase (SRINIVASAN; CHOY; CHEU, 2006; WU; WANG, 2016). Também prevalece em menor medida a utilização de variáveis como: a taxa de veículos que saem da fila e atravessam a interseção, e a taxa de veículos que chegam na fila em cada fase (HAMILTON et al., 2014; DUSPARIC; MONTEIL; CAHILL, 2016) e a densidade de veículos em cada fase (WU; WANG, 2016). Além disso, alguns métodos que controlam a coordenação entre as interseções, ou redes urbanas de um ponto de vista geral, determinam também atrasos entre interseções (tempo para a fila de veículos chegar de uma interseção até outra) para sincronizar suas fases e formar ondas verdes (DE ABREU BATISTA; COUTINHO, 2013).

Aliás, com o objetivo de avaliar o desempenho dos métodos utilizados, nas pesquisas comparam-se os resultados obtidos por cada método de

controle em relação a diferentes parâmetros. A seguir, são apresentados os parâmetros utilizados para avaliar o desempenho dos métodos.

- Tempo médio de viagem: tempo necessário para os veículos percorrerem os seus trajetos (MURCIA; HIRAKAWA; CASTRO, 2017).
- Velocidade média dos veículos: velocidade média atingida pelos veículos calculada como o tempo médio de viagem entre distância a percorrida (DAI; ZHAO; YI, 2010).
- Número de veículos que finalizaram o trajeto: quantidade de veículos que chegam nos seus destinos no tempo de simulação do cenário (SALKHAM et al., 2008).
- Tempo de espera médio: tempo gasto nas interseções pelos veículos esperando pela ativação da fase correspondente (SALKHAM et al., 2008).
- Nível de ocupação das vias: quantidade de veículos existentes nas vias (MURCIA; HIRAKAWA; CASTRO, 2017).
- Número médio de paradas na viagem: quantidade de paradas feitas nas interseções pelos veículos (YE et al., 2014).
- Tamanho da fila em cada fase da interseção: Quantidade de veículos existentes nas filas de cada via nas interseções (PACHECO; ROSSETTI, 2010).

2.5 Fundamentos das técnicas aplicadas ao controle do trânsito urbano

Como foi apresentado anteriormente, o trânsito urbano é um sistema dinâmico complexo, não linear, com uma natureza imprevisível e estocástica, além disso, possui tanto observabilidade quanto atuação parcial, o que atrapalha ainda mais na hora de prever o seu comportamento. Portanto, ainda existem incertezas entre os pesquisadores sobre como enfrentar o controle neste tipo de sistema. Como consequência encontramos na literatura os algoritmos e métodos mais variados, embora atualmente o Controle de Trânsito Urbano moderno possa ser dividido em dois grupos: teoria do Controle Ótimo e Inteligência Artificial (CASTRO et al., 2015). A seguir são

apresentados os fundamentos teóricos dos métodos mais comumente utilizados na bibliografia para o Controle do Trânsito Urbano.

2.5.1 Fundamentos teóricos de métodos baseados em Controle Ótimo

Segundo Castro, Hirakawa e Martini (2017), na teoria de controle ótimo propõe-se descrever sistemas dinâmicos com equações diferenciais para posteriormente minimizar funções de custo como forma de atingir a eficiência ótima de controle de cada sistema de acordo com seus objetivos. Os métodos baseados em teoria de controle ótimo para os sistemas de trânsito urbano mais utilizados na bibliografia são: Programação Dinâmica, Controle Preditivo baseado em modelo e a Contrapressão.

Programação dinâmica

Programação Dinâmica é um método usado comumente na construção de algoritmos para a resolução de problemas computacionais, em especial os de otimização combinatória. Ela é aplicável a problemas nos quais a solução ótima pode ser computada a partir de uma solução ótima previamente calculada e memorizada de outros subproblemas que compõem o problema original. É um algoritmo recursivo, no qual cada instância do problema é resolvida a partir da solução de instâncias menores, ou melhor, de subinstâncias da instância original. A característica distintiva da Programação Dinâmica é a tabela que armazena as soluções das variáveis das subinstâncias (FEOFILOFF, 2018).

O principal aspecto da Programação Dinâmica é uma equação diferencial parcial, apresentada por Hamilton–Jacobi–Bellman (BELLMAN, 1957), que provê o valor ótimo da função de custo na otimização de um sistema dinâmico (HEYDECKER; CAI; WONG, 2007). Na Programação Dinâmica calcula-se esta equação de forma recursiva tendo em conta todas as etapas do problema de otimização para obter as ações que levam o sistema de um estado atual a um estado desejado. No Controle de Trânsito Urbano, a função de custo é determinada por um modelo macroscópico do trânsito urbano e se desenvolve utilizando um parâmetro de desempenho, como o nível de ocupação das vias. Porém, como a saída da equação de Hamilton–Jacobi–Bellman é infactível, por causa de sua complexidade computacional, para as aproximações e o controle em tempo real utilizam-se outras técnicas junto com os métodos de controle baseados em Programação Dinâmica (DAI; ZHAO; YI, 2010).

Controle Preditivo baseado em modelos

Os Controladores Preditivos baseados em modelos captam as interações dinâmicas e estáticas entre as variáveis de entrada, as variáveis de saída e as perturbações mediante previsões precisas e podem fornecer alertas antecipados de um possível comportamento das variáveis controladas. Este método utiliza um modelo para prever o comportamento de um sistema, portanto precisa-se de um mecanismo para obter o modelo, que deve ser o suficiente para capturar completamente a dinâmica do processo e permitir que as previsões sejam calculadas, e ao mesmo tempo, ser intuitivo e permitir a análise teórica. O uso do modelo do processo é determinado pela necessidade de calcular o resultado previsto em instantes futuros (CAMACHO; BORDONS, 1999). Este método minimiza uma função de custo ao longo de um horizonte finito e encontra uma estratégia de controle abaixo do ideal ao longo do horizonte de predição. Além disso, utiliza um modelo de previsão para estimar os estados futuros do sistema e os usa para resolver o problema de otimização. O sinal de controle sub-ótimo é implementado para uma etapa de tempo e, em seguida, o horizonte de previsão é deslocado mais para frente, realizando a próxima iteração. O controlador recebe os estados medidos do sistema e os utiliza como estados iniciais do problema de otimização para resolver o problema novamente. Por considerar um horizonte de predição, o Controle Preditivo baseado em modelo é formulado como uma sequência de problemas de otimização, como é feito na Programação Dinâmica (JAMSHIDNEJAD et al., 2016). No sistema de trânsito urbano, um modelo matemático preciso de fluxo de veículos fornece uma previsão ou estimativa dos valores de controle ideais e a tomada de decisão para ativação das fases dos semáforos.

Contrapressão

O método de Contrapressão foi originalmente desenvolvido para maximizar o rendimento em redes de comunicação, otimizando os fluxos de dados (WONGPIROMSARN et al., 2012). O conceito central da proposta é priorizar fluxos com alta pressão em sua origem e baixa pressão no seu destino, evitando a formação de gargalos e garantindo um fluxo global melhor. Para o Controle de Trânsito Urbano este algoritmo calcula o peso de uma fase

como a “pressão de retorno” máxima, ou seja, o comprimento da fila no caso de sistemas de trânsito urbano. Portanto a fase com maior peso é ativada no ciclo semaforico. Este algoritmo apenas requer informações locais em cada interseção e maximiza a taxa de transferência de veículos (DAKIC; STEVANOVIC; STEVANOVIC, 2015).

O algoritmo de Contrapressão, no caso do trânsito urbano, calcula inicialmente a “pressão” de todas as vias entre as interseções do cenário. Posteriormente, a pressão de cada fluxo de veículos W_{ab} , em um instante de tempo t , que atravessa a interseção controlada é calculada pela diferença entre a pressão na via do fluxo de veículos de saída Q_a e a pressão do fluxo na via de destino Q_b , nesse instante de tempo, conforme representado na eq. (2) (WONGPIROMSARN et al., 2012). O coeficiente (W_{ab}) é utilizado para definir quais fluxos possuem maior pressão e são prioritários e, por conseguinte, que fase semaforica deve ser ativada. Dessa maneira, a fase semaforica ativada é a que permite o maior alívio de pressão na interseção em questão.

$$W_{ab}(t) = Q_a(t) - Q_b(t) \quad (2)$$

2.5.2 Fundamentos teóricos de métodos baseados em Inteligência Artificial

A inteligência artificial é um campo amplamente explorado no Controle de Trânsito Urbano. A ideia comum dos métodos de Inteligência Artificial é simular a inteligência da natureza até certo ponto pelo uso de métodos computacionais. O objetivo destes métodos é aumentar a velocidade da tomada de decisão e, por conseguinte, melhorar a eficiência de controle e a sua principal vantagem é que dispensam um modelo do sistema controlado. Estes métodos podem-se dividir em: sistemas com lógica difusa, algoritmos evolucionários, aprendizado por reforço e redes neurais artificiais (ZHAO; DAI; ZHANG, 2012).

Lógica Difusa

Este método de controle, chamado de Lógica Difusa, ou *Fuzzy Logic*, foi introduzido por Zadeh (1965) e aborda o aspecto impreciso da ação dos seres humanos com respeito ao mapeamento de variáveis em termos linguísticos da informação obtida do ambiente em valores numéricos. A lógica clássica apenas

permite conclusões que são verdadeiras ou falsas. No entanto, existem também proposições com respostas variáveis, em tais casos, a verdade aparece como resultado do raciocínio do conhecimento inexato ou parcial, no qual as respostas da amostra são mapeadas em um espectro. Enquanto as variáveis em matemática geralmente usam valores numéricos, em aplicações de lógica difusa, valores não numéricos são frequentemente usados para facilitar a expressão de regras e fatos. Os graus de verdade e probabilidades variam entre 0 e 1 e, portanto, podem parecer semelhantes à primeira vista, mas a lógica difusa utiliza graus de verdade como um modelo matemático de imprecisão, enquanto a probabilidade é um modelo matemático de ignorância (ZADEH; KLIR; YUAN, 1996).

Conforme apresentado por Mamdani (1974), um sistema difuso de controle inclui três etapas: fuzzificação, inferência de regras e uma última etapa de defuzzificação. Na etapa de fuzzificação determina-se o grau de pertinência de cada parâmetro numérico do sistema em relação a cada termo linguístico. Para atingir esse objetivo, utilizam-se funções de pertinências que podem ser definidas como curvas triangulares, trapezoidais ou funções sigmóides, entre outras. A escolha de qual tipo de função de pertinência utilizar depende de quantos termos linguísticos são desejados e qual é a relação entre a variável de entrada e os termos linguísticos adotados. A segunda etapa, a partir do grau de pertinência de cada variável, um mecanismo de inferência emula a decisão do conhecimento especializado com base em um conjunto de regras, cujo resultado é composto por termos linguísticos decorrentes do conjunto de regras lógicas pré-formuladas. Na última etapa, a de defuzzificação, ocorre um processo similar, mas inverso ao ocorrido na primeira etapa, pois converte-se os graus de pertinência dos termos linguísticos de saída em valores numéricos, tratáveis pelo sistema de controle. Portanto, também se utilizam funções de pertinência para determinar o valor numérico das variáveis de saída. De acordo com Bede (2013), podemos encontrar métodos de defuzzificação como: o de centro de gravidade, o de centro da área, o do valor esperado, e o da média dos máximos, os quais ponderam os graus de pertinência e as funções de pertinência para determinar a saída numérica do sistema.

No Controle de Trânsito Urbano, controladores baseados em lógica difusa são utilizados frequentemente. De forma geral, as variáveis de entrada são o nível de ocupação das vias de uma interseção para posteriormente passar por uma fase de inferências e, em seguida, ativar a fase semafórica que vai permanecer ativa nesse instante de tempo. No próximo capítulo deste documento são apresentadas algumas abordagens da aplicação da lógica difusa no Controle de Trânsito Urbano.

Algoritmos evolucionários

De acordo com Zitzler e Thiele (1999), algoritmos evolucionários, ou algoritmos genéticos, são uma abordagem baseada em heurística para resolver problemas que não podem ser facilmente resolvidos em tempo. Algoritmos evolucionários costumam ser adequados para problemas de otimização envolvendo vários objetivos, muitas vezes conflitantes, pois processam um conjunto de soluções em paralelo, possivelmente explorando semelhanças de soluções por recombinação. Quando usados sozinhos eles são tipicamente aplicados a problemas combinatórios; no entanto, os algoritmos genéticos são frequentemente usados em conjunto com outros métodos, agindo como uma forma rápida de encontrar um ponto inicial ideal para outro algoritmo funcionar (ZHAO; DAI; ZHANG, 2012).

A premissa de um algoritmo evolucionário é semelhante ao processo de seleção natural. Um algoritmo evolucionário contém quatro etapas gerais: inicialização, seleção, operadores genéticos e terminação (SONI, 2018). De modo geral, nesse tipo de algoritmo, os membros aptos (soluções aptas) sobreviverão e proliferarão, enquanto membros inaptos (soluções inaptas) morrerão e não contribuirão para o conjunto genético de novas gerações.

A primeira etapa consiste em criar uma população inicial de soluções. Normalmente a população inicial deve abranger uma ampla gama de soluções iniciais para conseguir explorar uma ampla gama de possibilidades. Posteriormente avaliam-se os membros de acordo com uma função de adequação (função fitness), na qual aceitam-se as características de um membro e gera-se uma representação numérica de quão viável é uma solução. Neste momento calcula-se a adequação de todos os membros e seleciona-se a parte dos membros de maior pontuação. Esses membros (genes) são usados

para criar a próxima geração no algoritmo. Usando as características dos pais selecionados, são criados novos filhos que são uma mistura das qualidades dos pais. Baseado em problemas combinatórios é possível misturar combinações e gerar combinações válidas a partir dessas entradas. Posteriormente, introduz-se a chamada mutação probabilística (é governada por uma distribuição de probabilidade) mudando uma pequena porção dos genes filhos de tal forma que elas não refletem mais perfeitamente os subconjuntos dos genes pais. O algoritmo termina quando atinge algum tempo máximo de execução ou atinge algum limite de desempenho. Neste ponto, uma solução final é selecionada e retornada (DEB et al., 2002).

Em geral, para o Controle de Trânsito Urbano, os algoritmos evolucionários são utilizados na procura de valores para otimizar os parâmetros de tempo no ciclo semaforico para o controle das interseções (ZHAO; DAI; ZHANG, 2012).

Aprendizado por reforço

Em algoritmos com aprendizado por reforço ou, *Q-learning*, um agente tenta aprender a política ótima a partir de sua história de interação com o ambiente, envolvendo um conjunto de estados s , na eq. (3), um conjunto de ações por cada estado a e criando uma tabela de possíveis ações para cada estado. Executando uma ação a , o agente transita de um estado s_n para um outro estado s_{n+1} . Executar uma ação em um estado específico fornece ao agente uma recompensa r (uma pontuação numérica) prefixada na tabela de possíveis ações. O objetivo do agente é maximizar sua recompensa total futura Q . O algoritmo realiza isso adicionando a recompensa máxima atingível do estado futuro à recompensa em seu estado atual, influenciando efetivamente a ação atual pela recompensa potencial no futuro. Essa recompensa é uma soma ponderada dos valores esperados das recompensas de todas as etapas futuras a partir do estado atual. Essas experiências serão os dados a partir dos quais o agente pode aprender o que fazer. Como no planejamento teórico da decisão, o objetivo é que o agente maximize seu valor (POOLE; MACKWORTH, 2010).

Mitchell (1997) apresentou a eq. (3), na qual determina-se o valor do coeficiente de reforço futuro Q compreendido pelo par de ação a e estado s . r representa o reforço imediato recebido pelo controlador pela execução da ação

a no estado s , enquanto γ é um parâmetro de desconto, cujo valor pode ser de 0 a 1, s' é o estado seguinte à execução da ação a e a' representa qualquer ação possível no estado s' . Valores altos de γ têm como consequência um aprendizado com foco maior no reforço futuro, enquanto valores mais baixos de γ focam mais no reforço imediato de cada ação.

$$Q(s, a) = r(s, a) + \gamma \max_{a'} Q(s', a') \quad (3)$$

Em geral, os métodos de aprendizado por reforço, ao contrário dos algoritmos evolucionários, atualizam-se em tempo real, portanto possibilitam a otimização do sistema dinâmico durante sua operação. Os algoritmos baseados em métodos de aprendizado por reforço atuam de acordo com o estado atual do sistema e com os estados anteriores, avaliando o impacto de suas ações, e recebem reforços positivos ou negativos por cada ação de acordo com o impacto causado ao sistema.


Redes Neurais Artificiais

As redes neurais artificiais, em geral, são sistemas de computação inspirados nas redes neurais biológicas que constituem o cérebro dos animais. Tais sistemas aprendem a executar tarefas considerando exemplos, geralmente sem serem programados com regras específicas de tarefas (ZHAO; DAI; ZHANG, 2012). Por exemplo, no reconhecimento de imagem, podem aprender a identificar imagens que contenham um padrão analisando imagens exemplos que tenham sido rotuladas manualmente como "com padrão" ou "sem padrão" e usando os resultados para identificar esse padrão em outras imagens. Os algoritmos baseados em redes neurais realizam essa tarefa sem nenhum conhecimento a priori sobre as características desse padrão. Em vez disso, eles geram automaticamente características de identificação do material de aprendizagem que processam.

A estrutura de uma rede neural artificial é baseada em uma coleção de nós conectados chamados neurônios artificiais que modelam vagamente os neurônios de um cérebro biológico (Figura 8). Cada conexão, como a sinapse de um cérebro biológico, pode transmitir um sinal de um neurônio artificial para outro. Um neurônio artificial que recebe um sinal pode processá-lo e depois

pode enviar essa informação para outros neurônios artificiais adicionais conectados a ele (ZHANG, 2000).

Figura 8 - Modelo de rede neural com 3 neurônios de entrada e 1 neurônio de saída.



Fonte: autor

Em geral, o sinal em uma conexão entre neurônios artificiais é um número real, e a saída O de cada neurônio artificial é computada por alguma função não linear que depende da soma ponderada de suas entradas I , eq. (4). Essas funções de ativação podem ser: função tangente, sigmoide hiperbólica, softmax ou retificadora (ROLLS; TREVES, 1998). As conexões entre os neurônios artificiais são chamadas de sinapses e geralmente têm um peso w que se ajusta à medida que a aprendizagem é realizada. O peso w aumenta ou diminui a intensidade do sinal em uma conexão. Os neurônios artificiais podem ter um limiar tal que o sinal é enviado somente se o sinal excede esse limiar. Normalmente, os neurônios artificiais são agregados em camadas. Diferentes camadas podem executar diferentes tipos de transformações em suas entradas. Os sinais viajam da primeira camada (a camada de entrada) até a última camada (a camada de saída), possivelmente ou não após atravessar várias camadas intermediárias ou também chamadas de camadas ocultas.

$$O_n = \sum_{i=1}^j I_j \cdot w_j \quad (4)$$

A topologia de uma rede neural artificial é definida com base no problema em questão. A complexidade do problema sempre será proporcional à quantidade de neurônios e camadas. De acordo com Cybenko (1989), uma rede com uma camada intermediária pode representar qualquer função

contínua e uma rede com duas camadas intermediárias pode representar qualquer função matemática. Aliás, conforme Cao et al. (2018), a quantidade de variáveis de entrada de um sistema impõe o número de neurônios de entrada de uma rede neural artificial. Igualmente, a quantidade de variáveis de saída do sistema impõe o número de neurônios de saída da rede neural artificial. A determinação do número de neurônios das camadas intermediárias é realizada comumente de forma empírica.

Uma vez que uma rede tenha sido estruturada para uma aplicação específica, essa rede está pronta para ser treinada. Este processo consiste em aplicar os passos ordenados necessários para ajustar os pesos e limiares sinápticos dos neurônios a fim de generalizar as soluções produzidas por suas saídas. Para iniciar esse processo, os pesos iniciais são escolhidos aleatoriamente, para então, o estágio de treinamento começar. Existem duas abordagens para o treinamento: supervisionado e não supervisionado. O treinamento supervisionado envolve um mecanismo para fornecer à rede a saída desejada, seja manualmente "classificando" o desempenho da rede ou fornecendo as saídas desejadas com as entradas. Aliás, o treinamento não supervisionado é no qual a rede deve entender as entradas sem ajuda externa (ZHANG, 2000).

O conjunto de etapas ordenadas usadas para treinar a rede é chamado de algoritmo de aprendizado. Durante a sua execução, a rede será capaz de extrair recursos discriminantes sobre o sistema, sendo mapeado a partir de amostras adquiridas do sistema e que são: variáveis de entradas e variáveis de saídas. Segundo Silva et al. (2017), o conjunto completo das amostras disponíveis é dividido em dois subconjuntos, que são chamados de subconjunto de treinamento e subconjunto de validação. O subconjunto de treinamento, composto por 60-90% das amostras aleatórias do conjunto completo, será usado essencialmente no processo de aprendizagem. Por outro lado, o subconjunto de testes, composto de 10% a 40% do conjunto completo de amostras, será usado para verificar se o erro na resposta da rede está dentro dos níveis aceitáveis, permitindo a validação ao tentar prever o comportamento do problema a partir de dados que não foram previamente apresentados à rede. O processo de treinamento termina quando o erro do

conjunto de validação converge para um valor mínimo, confirmando que o compromisso ideal entre convergência e generalização foi alcançado.

Capítulo 3

3 Trabalhos relacionados ao Controle de Trânsito Urbano

Muitos estudos têm sido propostos para controlar o tempo de cada fase em um ciclo semaforico. A natureza imprevisível da demanda de trânsito dificulta a tarefa de otimizar o controle, sendo um desafio encontrar uma solução satisfatória para o controle do sinal de trânsito devido à complexidade intrínseca do sistema. O trânsito urbano é um sistema dinâmico e tem natureza incerta, subsistemas interdependentes, não-linearidades e um número considerável de variáveis, como fluxos de veículos, filas de veículos e tempos de fase do semáforo.

Portanto, neste capítulo será realizada uma análise dos trabalhos relacionados e os modos de aplicar os métodos para o controle neste tipo de sistema. Serão expostas as metodologias iniciais pesquisadas na área de trânsito urbano. Após a análise das abordagens iniciais, será apresentado o conceito de controle multiagente no trânsito urbano, uma abordagem frequentemente utilizada atualmente. Em seguida, serão apresentados os trabalhos relacionados encontrados na bibliografia divididos pelos métodos apresentados anteriormente. Por último, será apresentado o Modelo de Redes Neural Bio-Inspirada, método no qual se baseia a proposta deste trabalho.

3.1 Primeiras abordagens

Esta seção apresenta uma análise cronológica das abordagens utilizadas no Controle de Trânsito Urbano.

Desde a introdução dos controladores automáticos simples de sinal de trânsito nos EUA no início do século passado, os sistemas de Controle de Trânsito Urbano passaram por melhorias contínuas. Os trabalhos de pesquisa teórica desses controladores datam de meados do século XX. A partir de então, os métodos passaram por três etapas: controle pré-fixado, acionados

por veículos e controle inteligente. Provocado pelo desenvolvimento das tecnologias avançadas de detecção e comunicação, as medições do trânsito em tempo real tornaram-se frequentemente disponíveis. Tanto o trabalho de pesquisa quanto as tecnologias avançadas constroem a base para o controle moderno deste tipo de sistemas em tempo real.

A abordagem utilizada inicialmente foi o método de controle de tempo fixo, adequado para fluxos de trânsito relativamente estáveis e regulares. Neste método pré-fixa-se o tempo para o ciclo semaforico e o tempo de ativação de cada fase que compõe esse ciclo semaforico. Webster (1958) apresentou uma pesquisa, na qual estabeleceu um modelo e um método para o cálculo do tempo das fases de um ciclo semaforico em uma interseção isolada, conseguindo obter um atraso mínimo médio nos veículos. Posteriormente, Robertson (1978) utilizou um algoritmo de otimização do tipo *hill-climbing* para determinar o melhor plano de tempos fixos a partir de variáveis de entrada como: topologia da rede urbana, fluxos de saturação das ruas, duração mínima do tempo de verde de cada semáforo, e um plano inicial de tempos fixos dos semáforos da rede urbana. Outra abordagem foi proposta por Little (1966) e estendida por Gartner et al. (1991) e baseou-se na determinação de tempos fixos com o objetivo de sintonizar a abertura dos semáforos vizinhos com pequenos atrasos em ruas principais, formando, assim, ondas verdes e reduzindo a quantidade de paradas dos veículos. Entretanto, nenhum desses métodos considera a condição real do trânsito, o que é uma limitação em termos de eficiência de controle, pois o trânsito é um sistema dinâmico e não segue padrões bem definidos.

Posteriormente, como o trânsito urbano é um ambiente dinâmico, abordagens adaptativas foram propostas para reduzir ainda mais o trânsito em grandes centros urbanos, reajustando os tempos de verdes do semáforo durante sua operação, em uma única interseção, sem informações das interseções vizinhas. Esses primeiros métodos de controle adaptativos também são chamados de acionados por veículos ou responsivos ao trânsito e adequam seu funcionamento de acordo com variações no volume de trânsito e em sua distribuição.

Peterson, Bergh and Steen (1986) e Peirce e Webb (1990) apresentaram os primeiros métodos baseados na ideia de modelos acionados por veículos chamados de LOVRA e MOVA, respectivamente. Esses métodos consistiram na extensão ou não do tempo de verde dos semáforos a partir da quantidade de veículos medida por sensores presentes nas ruas. Além disso, eles otimizam o controle das fases do ciclo semafórico em interseções isoladas, reduzindo atrasos e paradas e maximizando a capacidade durante períodos de pico. Outra pesquisa que faz parte dessa metodologia é o método SCOOT (*“Split, Cycle, Offset Optimization Technique”*), proposto por Hunt, Robertson e Bretherton (1982), que avalia a quantidade de veículos à uma distância da intersecção entre ruas e, com essa informação, prediz o perfil do fluxo de veículos que chegará aos semáforos. Nesse método, compara-se a predição do fluxo de veículos em todas as ruas da intersecção às estimativas dos fluxos de partida dos veículos quando a fase semafórica correspondente está ativada, e posteriormente, determina-se a variação dos tempos das fases semafóricas. A alteração desses tempos é pequena e gradual para garantir a adaptabilidade do sistema, mas sem provocar alterações bruscas nos fluxos de veículos e interferir, assim, nas previsões de intersecções vizinhas.

Em geral, estes são métodos de controle centralizados e o processo de tomada de decisão acerca da duração das fases dos semáforos realiza-se em interseções isoladas.

3.2 Controle multiagente de interseções

Como apresentado na seção anterior, as primeiras abordagens foram desenvolvidas para o controle de interseções isoladas. Mas de acordo com Balaji e Srinivasan (2010), devido ao comportamento estocástico e às características não estacionárias do fluxo de veículos deste tipo de sistemas, além do número de interseções em um determinado espaço, é difícil desenvolver um modelo matemático em uma intersecção para calcular o tempo ótimo das fases ativas em um ciclo semafórico para demandas específicas sem depender das relações com interseções vizinhas.

Zhao, Dai e Zhang (2012) afirmam que, para um sistema de Controle de Trânsito Urbano de grande escala, é difícil prever a mudança no estado do

trânsito devido à variação dos parâmetros de controle de acordo com o comportamento do fluxo de trânsito. Portanto, é necessário usar uma arquitetura de controle distribuída na qual cada interseção é controlada por um agente que decide a política de controle autônoma e se comunica com agentes vizinhos (controladores de interseções vizinhas) com o objetivo de trocar informações sobre o estado do trânsito e sobre suas decisões para, assim, melhorar a eficiência de controle do sistema. Segundo Balaji e Srinivasan (2010), o principal objetivo desta arquitetura é conseguir um controle de interseções coordenado para garantir níveis mais baixos de congestionamento em toda a rede, prevendo a demanda do trânsito futuro.

Araghi, Khosravi e Creighton (2015) e El-Tantawy, Abdulhai e Abdelgawad (2013) concluíram que a utilização de uma estrutura distribuída com controle multiagente pode ser mais eficiente e flexível do que estratégias centralizadas para reduzir o congestionamento de trânsito nas grandes cidades, pois consegue tratar adequadamente alguns problemas que ocorrem no controle desses grandes sistemas, por exemplo: complexidade computacional, múltiplos objetivos de controle, fraca robustez e incertezas.

Esse tipo de arquitetura tem sido comumente utilizado por vários pesquisadores do tema na literatura nos últimos anos, fornecendo melhores resultados. Na próxima seção serão revisadas soluções para o controle do sistema de trânsito urbano com a finalidade de analisar suas contribuições e possibilidades de melhora. Note-se que muitos dos trabalhos atuais encontrados na bibliografia analisam o problema por uma visão de controle multiagente, utilizando a coordenação entre os agentes de controle.

3.3 Metodologias aplicadas ao Controle do Trânsito Urbano

Como discutido no capítulo anterior, uma consequência do nível de complexidade do Sistema de Trânsito Urbano é o desenvolvimento de trabalhos de pesquisa dos mais variados tipos de algoritmos e métodos, embora o controle moderno destes sistemas possa ser dividido em dois grupos: Teoria do Controle Ótimo e Inteligência Artificial.

A seguir, apresenta-se um estudo dos trabalhos relacionados com o Controle de Trânsito Urbano divididos pelos principais métodos utilizados pelos pesquisadores.

3.3.1 Trabalhos relacionados baseados em Controle Ótimo

Este item apresenta a análise das principais pesquisas encontradas na bibliografia baseadas em Controle Ótimo. Essa análise será realizada dividindo os métodos em: programação dinâmica, controle preditivo baseado em modelos e contrapressão.

Programação dinâmica

Li (2011) baseou-se na hipótese da dificuldade de obter uma solução global ideal utilizando modelos de programação não linear, portanto, propuseram uma abordagem de modelagem por discretização, cujo tempo de ativação das fases e o volume de trânsito são divididos em um número finito de valores discretos. O problema de temporização do ciclo semaforico foi formulado como um programa inteiro binário e foram desenvolvidos dois algoritmos de programação dinâmica para reduzir o tempo computacional. O autor obteve soluções globais para todas as instâncias com relação às entradas geradas a partir da discretização. Uma limitação desse método é que requer até 12 horas de tempo computacional nas iterações necessárias para o cálculo do algoritmo se o intervalo de volume de trânsito e a variação de trânsito forem consideravelmente grandes. Outra limitação é que esse cálculo é realizado de forma off-line, portanto, para grandes variações futuras nas características do fluxo de veículos, o algoritmo não terá uma boa resposta.

Cai, Wong e Heydecker (2009) apresentaram um estudo sobre um controlador adaptativo do ciclo semaforico em uma interseção para a operação em tempo real com um algoritmo baseado em programação dinâmica aproximada. Essa abordagem conseguiu reduzir substancialmente a carga computacional usando uma aproximação da função de custo da programação dinâmica e uma técnica de aprendizado de reforço para atualizar a aproximação. Na etapa da simulação, os autores puderam concluir que os controladores ADP (*“Approximated Dynamic Programming”*) alcançam uma redução substancial nos atrasos dos veículos em comparação com

controladores de tempo fixo otimizados. O modelo foi desenvolvido apenas para o controle de uma interseção isolada.

El Moudni, Yin e Dridi (2015) apresentaram um novo algoritmo de busca direta baseado em programação dinâmica sob uma árvore de decisão e explora uma solução eficiente para a política de controle adaptativo de um ciclo semafórico em tempo real. Nessa pesquisa considera-se o controle semafórico tanto com casos de sequência de fase fixa quanto sequência de fase variável. Com a ajuda das propriedades da programação dinâmica e da otimização do processo de estados de trânsito repetidos ou inválidos, o algoritmo apresentado nesse trabalho consegue reduzir o número de estados e economiza muito tempo de computação. Para avaliar o método de controle, os autores o compararam em simulações a um método de controle com tempos de verde fixos, com um método de controle adaptativo e com um método de controle baseado em aprendizado por reforço. Os resultados mostram que o algoritmo proposto foi melhor em todos os cenários simulados.

Com os resultados obtidos, Cai, Wong e Heydecker (2009) concluíram que a forma de aproximação tem pouca influência na eficiência de controle dos sinais de trânsito, e que aproximações lineares, como as propostas deles e de Yin, El Moudni, Yin e Dridi (2015), são suficientes para atingir o desempenho de controle desejado, dispensando formas de aproximação não lineares. Cai, Wong e Heydecker (2009) concluíram também que métodos de otimização recursivos baseados em modelos simplificados, como no caso da programação linear, têm uma limitação no desempenho de controle por não considerarem o caráter estocástico dos sistemas dinâmicos complexos. Entretanto, Li (2011) ressalta a dificuldade de obter o ótimo global por meio de métodos de controle baseados em programação dinâmica em cenários com incertezas. Por último e de forma geral, pode-se afirmar que em todos os casos a programação dinâmica sofreu com dados de entrada com grandes intervalos.

Controle preditivo baseado em modelo

Zegeye et al. (2012) apresentaram um algoritmo baseado em modelos macroscópicos que adapta continuamente os parâmetros de controle dos ciclos semafóricos às condições de trânsito prevalentes e apresenta uma velocidade de computação mais rápida do que outros algoritmos convencionais

de controle preditivo baseado em modelos. Para isso, apresenta a abordagem de controle ótimo de malha aberta on-line usando o estado atual do sistema como o estado inicial. O processo de otimização produz uma sequência ótima de controle, e a primeira entrada de controle na sequência é aplicada no sistema, portanto esta abordagem não usa uma lei de controle pré-calculada (ou pré-projetada) para produzir os sinais de controle. Mas a principal limitação é que normalmente a complexidade computacional aumenta exponencialmente à medida que o número de entradas de controle (quantidade de interseções coordenadas e controladas) ou o horizonte de previsão aumenta (intervalo em que é calculado o comportamento futuro do processo).

Hajiahmadi et al. (2016) desenvolveram um modelo macroscópico e de controle distribuído que consegue controlar redes de vias de grande escala em tempo real. O modelo estendido é reformulado como um sistema de desigualdades lineares com variáveis binárias e reais mistas. Posteriormente, junto com a função objetivo, as equações que descrevem o problema foram linearizadas para serem mais tratáveis e de uma forma mais rápida do que o problema de otimização original. O método foi avaliado em um cenário real com características reais de demanda de veículos. As limitações deste trabalho encontram-se no tempo de resposta do algoritmo e a complexidade computacional quando for escolhido uma rede de vias consideravelmente grande e a resposta do algoritmo ante variações consideráveis (aumentos ou diminuições) na quantidade de veículos presentes na rede.

Zhou et al. (2017) propuseram uma estrutura de controle hierárquico de dois níveis para redes de trânsito urbano de larga escala. No nível superior utiliza-se um controlador para o balanceamento de demanda de trânsito usando o conceito de diagrama fundamental macroscópico. No nível mais baixo, o controlador com um modelo de fluxo de trânsito mais detalhado para cada sub-rede determina o tempo ótimo de fase semaforica dentro da região determinada sob a orientação do controlador de nível superior através da comunicação. Para a aplicação desta arquitetura em tempo real, a abordagem de controle preditivo baseado em modelo é utilizada para obter as melhores soluções para ambos os níveis. Além disso, para diminuir a complexidade computacional, um esquema de controle distribuído dentro de cada sub-rede é

desenvolvido no nível inferior. As limitações deste trabalho são: o cenário escolhido para validar a proposta é limitado, apresenta uniformidade no seu desenho (as distâncias entre as interseções são todas iguais). A atualização dos parâmetros de controle não é realizada de forma on-line, portanto, variações consideráveis na demanda do trânsito afetam o desempenho do algoritmo. O tempo de resposta e a complexidade ainda são altos, embora melhore com respeito a trabalhos anteriores e essa é uma limitação comum dos métodos baseados em modelos.

Contrapressão

Wongpiromsarn et al. (2012) propuseram uma primeira abordagem que utiliza o método de contrapressão aplicado ao controle do trânsito urbano. Os autores utilizaram uma arquitetura de controle distribuída e conseguiram reduzir a complexidade computacional do método de controle, pois segundo Gregoire et al. (2015), a complexidade computacional do método de controle de contrapressão é linear. Os autores também demonstraram que o algoritmo proposto garante o ótimo global do sistema, o que resulta em um fluxo de veículos máximo. Os resultados das simulações comparativas com um algoritmo de controle adaptativo anterior mostram que o método de controle é superior em termos de tamanho das filas de veículos na rede urbana. Uma questão para analisar é que o algoritmo pode não conseguir determinar as sequências periódicas de mudança de fases, a menos que uma previsão da próxima fase possa ser fornecida, pois não analisam o atraso adicional nas respostas dos motoristas aos sinais de trânsito.

Dakic, Stevanovic e Stevanovic (2015) propuseram dois algoritmos de controle de sinal baseados no modelo de contrapressão. Um dos objetivos era determinar se tais estratégias de controle podem levar ao máximo rendimento através de uma rede de trânsito urbano. Além disso, a avaliação dos dois algoritmos incluiu a comparação de seus desempenhos com os desempenhos das estratégias convencionais de controle de sinal em softwares de micro simulação. O algoritmo com melhor resposta resultou ser o VISGAOST em termos de: tempo total de atraso e tempo total de viagem, o que levou ao rendimento máximo da rede. O cenário escolhido também é limitado e ideal, portanto o desempenho obtido nesta pesquisa pode ser explicado pela

hipótese de que as filas de veículos não têm restrições no seu comprimento. No entanto, em condições reais, nas quais a fila de veículos é limitada pela capacidade da via entre interseções, esses resultados não podem ser atingidos.

Com base na ideia do método de contrapressão, Thunig e Nagel (2017) desenvolveram um método de controle de sinal que reage às mudanças no trânsito e considera a opção de rota dos veículos e sobressaturação das vias. Com este método, os autores conseguiram impedir o efeito de engarrafamento para demandas de trânsito inesperadas e também tem a possibilidade de lidar com situações de não engarrafamento. Os autores admitem que o cenário escolhido não fornece um caso de uso adequado para testar a abordagem de pressão de retorno, pois em cenários onde nenhum bloqueio de interseções pode ocorrer, a abordagem de contrapressão implementada claramente não é capaz de melhorar a situação. De fato, ele tem o potencial de piorá-lo à medida que se estende artificialmente a propagação dos veículos (efeito *spillover*) e bloqueia agentes que não seriam influenciados pelo engarrafamento do tipo gargalo. Isso pode ser útil para acionar agentes em usar alternativas, por exemplo, contornar a cidade, mas não ajuda quando não existem alternativas (boas).

3.3.2 Métodos baseados em Inteligência Artificial

A seguir serão analisadas as principais pesquisas encontradas na bibliografia baseadas em Inteligência Artificial. Essa análise será realizada dividindo os métodos em: Lógica Difusa, Algoritmos evolucionários, Aprendizado por Reforço e Redes Neurais Artificiais.

Lógica Difusa

Gokulan e Srinivasan (2010) adotaram uma abordagem multiagente distribuída para desenvolver um sistema de controle de sinal responsivo ao trânsito, nesse caso, um sistema multiagente de inferência difuso geométrico de dois estágios. Esse método foi capaz de lidar com os vários níveis de incerteza encontrados nas variáveis de entradas e na base de regras do controlador. Além disso, a coordenação entre agentes permitiu enviar aos agentes vizinhos o estado de congestionamento e foi utilizado para determinar internamente o nível de cooperação dentro da estrutura do sistema de decisão

do tipo 2. Os modelos foram testados em um cenário réplica de um cenário real da cidade de Cingapura. Análise e comparação foram realizadas em relação aos métodos desenvolvidos por Keong (1993) e Choy, Srinivasan e Cheu (2006), e o algoritmo proposto melhorou a resposta com respeito a esses métodos quando testado para cenários típicos de fluxo de trânsito. A limitação principal deste método está nas funções de associação e na base de regras adotadas para a inferência, pois devido à complexidade do sistema, não abrangem toda as suas características.

Jamshidnejad, de Schutter e Mahjoob (2015) desenvolveram um método baseado em lógica difusa com um sistema multiagente com uma arquitetura hierárquica, na qual um agente controla um conjunto de interseções (subáreas). A base da regra do controle é desenvolvida a partir de um conjunto de dados coletados e das suas matrizes origem-destino dos fluxos de veículos, posteriormente, agrupam essas matrizes com um algoritmo de *clustering* desenvolvido na mesma pesquisa. Finalmente, obtiveram conjuntos difusos de tipos triangulares. O método proposto requer um estágio inicial off-line para obter o conjunto de dados para conseguir controlar posteriormente cada subárea, pois os agentes precisam construir inicialmente as bases da regra da lógica difusa. Portanto, este método requer grande quantidade de dados iniciais de cada cenário, além de não possuir uma atualização em tempo real na base de regras do método difuso.

Sabetghadam et al. (2012) baseia-se em uma abordagem multiagente distribuída com lógica difusa de dois estágios para tratar as incertezas e as variações de parâmetros desse tipo de sistema. A variável de entrada do método é o fluxo de veículo nas vias, calculado como a diferença entre a quantidade de veículos que saem e chegam em cada via. A média dos dados coletados é enviada para o sistema de inferência de regras do tipo 2 para calcular o tempo de ativação de fase necessário para o próximo ciclo. No primeiro estágio são inferidas as regras da variável de entrada e no segundo estágio são inferidas as regras para a ativação das fases do ciclo semaforico. A avaliação dos resultados é realizada em um cenário ideal e comparado com um controlador de tempo fixo, portanto os resultados obtidos não podem ser conclusivos.

Em geral, os métodos baseados em Lógica Difusa precisam de estágios iniciais off-line para incorporar informações sobre a dinâmica do sistema para inferir a base de regras. Portanto, como esses dados são característicos de cada cenário em particular, cada rede de trânsito precisa de uma fase de coleta inicial de dados para criar e aplicar o método. Além disso, a definição das regras de controle e de seus parâmetros não é ótima, pois o ponto ótimo de operação, dado que o trânsito é um sistema complexo, é variável e depende de variáveis externas não controladas que são captadas ineficientemente, pois as informações são incompletas.

Algoritmos evolucionários

Huang (2015) propõe uma nova abordagem para a previsão em tempo real do fluxo de veículos em curto prazo combinando um modelo de regressão vetorial e um algoritmo evolucionário híbrido. Nessa pesquisa, o processo de previsão considera o fluxo de trânsito na via durante os primeiros intervalos de tempo, o fluxo de trânsito para a seção posterior da via e as condições meteorológicas. Os testes para verificar o desempenho da previsão do modelo proposto são realizados em um cenário réplica de um trecho de uma avenida principal da cidade de Banqiao, China. As limitações deste método encontram-se nos fatores de influência considerados, podendo estudar outros fatores de influência como horários, tipo de via, incertezas na condução dos motoristas, etc.

Segundo Araghi, Khosravi e Creighton (2015), técnicas de otimização podem desempenhar um papel central na determinação dos parâmetros de controle e gerenciamento de trânsito. Nesta pesquisa, os autores propõem um algoritmo genético, na qual partem de uma população inicial gerada aleatoriamente composta por soluções viáveis e utilizam funções de probabilidades que apresentam operações de seleção, cruzamento genético e mutação para calcular o tempo ótimo das fases de um ciclo semafórico em uma rede simples de duas interseções. Como é um algoritmo evolucionário, as iterações repetidas são necessárias, portanto o processo computacional é custoso por natureza, embora o paralelismo dos cálculos das funções durante a otimização evolucionária desempenhe um papel importante para aumentar a

eficiência da computação, mas resulta que a otimização para o controle de trânsito de uma pequena rede de vias demora várias horas.

Gokulan e Srinivasan (2014) propuseram um método de aprendizado evolucionário simbiótico para otimizar os parâmetros de um controlador difuso de dois estágios elaborado previamente por Gokulan e Srinivasan (2010). A base do aprendizado evolucionário simbiótico é desenvolver os parâmetros da função de associação e a base de regras da lógica difusa como dois grupos diferentes, em vez de realizar o método de aprendizado evolucionário para as regras individuais e atribuir os valores de adequação para cada regra. A utilização de métodos evolucionários forneceu melhores resultados quando comparado com a pesquisa anterior, a qual não utilizou o algoritmo genético.

Em geral, os métodos que utilizam algoritmos evolucionário, ou também chamados de algoritmos genéticos, possuem uma elevada complexidade e o tempo computacional elevado no processo de otimização on-line. Além disso, precisam de um pré-processamento de dados iniciais para criar um modelo, o que, como elucidado anteriormente, no caso de sistemas complexos como o trânsito urbano, não reflete a gama de comportamentos apresentados na realidade, limitando seu desempenho.

Aprendizado por Reforço

Jin e Ma (2015) propuseram um controlador com aprendizado por reforço com backups de várias etapas baseado em uma arquitetura distribuída com controle multiagente. Os agentes de controle, baseados nos estados de sistemas percebidos, realizam a tomada de decisões para a configuração do ciclo semaforico e enviam sinais de coordenação e sincronização entre eles. Os agentes atualizam, em tempo real, o seu conhecimento com base em uma sequência de estados durante o processo de aprendizado, e não apenas com base no estado anterior. O algoritmo apresentado é de natureza adaptativa e não requer informações de modelo da dinâmica do sistema de trânsito, mas requer uma estrutura de otimização inicial para pré-sintonizar os parâmetros do controlador.

El-Tantawy, Abdulhai e Abdelgawad (2013) adotaram uma abordagem de aprendizado por reforço com controle multiagente, na qual cada controlador

(agente) é responsável pelo controle de uma interseção e enviam sinais de coordenação para os agentes de interseções vizinhas. Portanto, cada agente aprende e converge para a melhor política de resposta às políticas de todos os vizinhos. O ambiente é modelado como um processo de decisão de Markov (HOWARD, 1960). Uma limitação observada é que assume que o ambiente subjacente é estacionário, o que significa que o estado do ambiente depende apenas das ações do agente, no entanto, neste trabalho já foi analisado que o sistema de trânsito é variável e com muitas incertezas adicionadas pelo comportamento dos motoristas. O método é testado em uma rede simulada de grande escala com 59 cruzamentos de um cenário real. Os testes mostram resultados superiores quando comparados com arquiteturas de controle centralizadas ou individuais.

Em geral, métodos de controle baseados em aprendizado por reforço requerem o armazenamento dos valores do coeficiente de reforço futuro em uma tabela, portanto, o crescimento exponencial de combinações de novos estados e ações restringe o desempenho do controle (ZHAO; DAI; ZHANG, 2012; ARAGHI et al., 2013). Além disso, os algoritmos de aprendizado por reforço precisam de um tempo para a convergência antes de se adaptarem a mudanças abruptas na dinâmica do sistema.

Redes Neurais Artificiais

Jiang et al. (2017) propuseram um algoritmo evolucionário com mutações e estratégias de seleção para encontrar os valores ideais dos pesos e os valores de limiar de uma rede neural composta de duas partes, que são a propagação direta do sinal de entrada e a propagação de retorno do sinal de erro. Desta forma, conseguiram melhorar a eficiência do treinamento, acelerar a taxa de convergência e evitar o treinamento da rede neural apenas para soluções ótimas locais. Este modelo requer dados histórico do cenário em questão para treinar a rede neural de forma off-line.

Kaur e Agrawal (2014) utiliza um algoritmo híbrido de Rede Neural junto com um Algoritmo Genético. O algoritmo fornece como entrada para a rede neural o tempo das fases do ciclo semafórico e a rede neural fornece o comprimento geral da fila como saída. Posteriormente, o Algoritmo Genético trabalha para otimizar o tempo do sinal, reduzindo o comprimento da fila, o que

reduzirá o congestionamento e aumentará a velocidade média dos veículos. Portanto, a duração das fases é adaptável, no entanto, depende apenas do número de veículos acumulados na fila. O objetivo do algoritmo, em geral, é diminuir o tamanho da fila de veículos em cada via das interseções. O aprendizado é realizado de forma off-line, portanto, um fluxo de veículo não analisado nesse momento, com fatores como chuvas, acidentes, buracos nas vias e frenagens inesperadas e outros comportamentos do tipo estocástico, podem ser nefastos para o controle. As simulações para a avaliação do algoritmo são realizadas em um cenário ideal com apenas duas interseções.

Srinivasan, Choy e Cheu (2006) concluíram que o controle em tempo real para uma interseção é parte integrante do sistema de Controle de Trânsito Urbano, e para uma grande rede de trânsito complexa, é um problema de controle distribuído extremamente desafiador. Para solucionar o problema proposto, eles adotaram uma abordagem de sistema multiagente e desenvolveram um modelo de controle distribuído e não supervisionado híbrido com redes neurais utilizadas para aprender o modelo e estimar parâmetros internos e controle difuso para a tomada de decisão. Nesta abordagem cada agente realiza um processo de aprendizado em tempo real com redes neurais em vários estágios para atualizar e adaptar sua base de conhecimento e seu mecanismo de tomada de decisão. A rede neural utiliza 5 camadas e divide-se em dois níveis paralelos, um para estimar os parâmetros da rede e o segundo para estimar o atraso dos fluxos de veículos para a coordenação entre agentes. O algoritmo utilizado para atualizar os pesos da rede é o método *backpropagation* (WIDROW; LEHR, 1990). O algoritmo desenvolvido foi avaliado em um cenário réplica do Distrito Central de Negócios de Cingapura usando um programa de simulação microscópica. Os resultados sugerem que o sistema multiagente híbrido baseado em redes neurais pode fornecer controle efetivo da rede de trânsito em larga escala quando a complexidade da simulação aumenta. A principal limitação deste modelo está no fato que a complexidade computacional e o tempo de resposta é relativamente alto.

Geralmente algoritmos baseados em redes neurais utilizam mais um método para a tomada de decisão como foi apresentado nos trabalhos anteriores, resultando em algoritmos híbridos.

3.4 Modelo de Redes Neurais Bio-Inspiradas

Castro, Martini e Hirakawa (2014) desenvolveram um modelo de redes neurais inspiradas nas redes neurais do cérebro humano para o controle do trânsito urbano baseado nos modelos de redes neurais bio-inspiradas da literatura (DESAI, 2003; MAO; MASSAQUOI, 2007; PELÁEZ; ANDINA, 2013). Tanto a estrutura da rede neural, quanto os modelos de neurônio e plasticidades adotados, definem seu comportamento e a maneira como ela incorpora o conhecimento sobre o sistema. Para o controle do trânsito urbano, os autores adotaram uma abordagem modular, na qual o modelo geral proposto para o controle das fases semaforicas de uma intersecção pode ser aplicado em todas as interseções, pois em cada semáforo existem diferenças estruturais na Rede Neural Bio-Inspirada aplicada, como a quantidade de fases semaforicas do ciclo semaforico e as vias. Portanto no início é preciso apenas configurar cada rede com as características específicas da intersecção que controla.

A abordagem do modelo concentra-se em como reagir aos estados atuais do trânsito com base nas implicações das possíveis ações em uma intersecção. Para alcançar esse objetivo, o modelo de controle permite a incorporação de conhecimento dos principais aspectos da dinâmica do trânsito identificados anteriormente. Para isso, o modelo beneficia-se do conhecimento dos aspectos microscópicos do fluxo de trânsito. Mas em vez de tentar modelar o comportamento humano, concentra-se em como reagir aos estados atuais do trânsito com base nas implicações das possíveis ações em uma intersecção.

Em geral, as principais características que diferem o modelo de controle baseado em Redes Neurais Bio-Inspiradas e os trabalhos relacionados no campo do Controle de Trânsito Urbano são:


- Concentra-se na dinâmica local em vez de uma rede urbana macroscópica.
- Baseia-se em equações analíticas em vez de algoritmos de otimização iterativa ou em conjuntos de regras e restrições.

- Usa informação adquirida para determinar uma estratégia de controle em vez de modelar e prever outras variáveis e, conseqüentemente, o comportamento humano.
- Não possui um estágio de treinamento, em vez disso, escolhe seus pesos sinápticos para alcançar um comportamento desejado.
- Apresenta resultados satisfatórios na estabilidade dinâmica frente a distúrbios e a capacidade de adaptação instantânea a mudanças no ambiente de atuação, como apresentado em Castro et al. (2015)

3.4.1 Estrutura e dinâmica

A estrutura mostrada na Figura 9 é usada para controlar cada uma das intersecções. Cada conjunto de neurônios (p, h, q) representa uma fase de semáforo. Considerando n fases no ciclo semaforico, toda estrutura de controle de intersecção terá n conjuntos de neurônios. Os neurônios $p_{1,2} \dots n$ são os neurônios excitatórios, $q_{1,2} \dots n$ são os neurônios sensoriais, $h_{1,2} \dots n$ são os interneurônios e $q_{a,b,c,d...y,z}$ são os receptores sensoriais, os quais medem o nível de ocupação das vias relativas a cada intersecção, representando as entradas do sistema.

Figura 9 - Modelo BiNN para controle de uma intersecção.



Fonte: autor

O modelo de controle proposto constitui uma rede neural competitiva, os neurônios p competem entre eles para ativar as suas respectivas fases e determinam o comportamento dos semáforos. Portanto, cada fase possível é representada por um neurônio. Os neurônios que representam as fases competem uns com os outros para determinar o vencedor e, portanto, a fase

ativa. Uma estrutura neural semelhante é usada para identificar e agrupar padrões em Meyer-Base e Thummler (2008) para ajudar o controle dinâmico de semáforos.

A estrutura matemática da rede é apresentada a seguir:

$$A_i^{t+1} = \sum_{j \in N_i} w_{xy} Q_j^t \quad (5)$$

$$O_i^{t+1} = \frac{1}{1 + e^{-m(A_i^t - s_i^t)}} \quad (6)$$

$$s_i^{t+1} = \frac{v O_i^t + s_i^t}{v + 1} \quad (7)$$

Cuja eq. (5) determina a ativação A de um neurônio i no instante de tempo $t+1$ com base na soma ponderada de suas n entradas Q .

A eq. (6) é uma função sigmoide cuja inclinação é determinada por m e representa a função de ativação dos neurônios. Concebe a saída O de um neurônio com base na sua ativação A e no deslocamento s da sua função de ativação, o que representa o mecanismo de adaptação do modelo (plasticidade intrínseca). O fator m representa da inclinação da curva.

A eq. (7) determina o deslocamento s da função de ativação de um neurônio i com base em sua saída e v é o coeficiente de adaptação que é uma constante de valor pequeno que determina a taxa de adaptação dos neurônios.

3.4.2 Princípios Fundamentais

Os princípios fundamentais das redes neurais biológicas propostas pelos autores, e pesquisadas anteriormente na literatura, são utilizados para reagir aos estados de trânsito urbanos locais e alcançar o comportamento desejado do sistema em cada interseção (DESAI, 2003; MAO; MASSAQUOI, 2007; PELÁEZ; ANDINA, 2013). Esses princípios são:

- Inibição lateral
- Plasticidade intrínseca
- Plasticidade sináptica

Inibição lateral

Na Figura 9, os neurônios $h_{1,2...n}$ são os interneurônios que agem como inibitórios para cada fase semafórica. Esses neurônios inibem a atividade de outras fases semafóricas com uma dinâmica de inibição lateral, semelhante à investigada por Mao e Massaquoi (2007), garantindo que apenas uma fase semafórica esteja ativa em cada momento.

Aliás, o modelo apresenta mais dois tipos de inibição, a primeira, uma inibição por antecipação que são as sinapses inibitórias w_{qh} e conectam as entradas da rede diretamente aos interneurônios inibitórios h , antecipando variações na entrada e facilitando a transição de estados do neurônio. A segunda inibição, por realimentação, representada pelas sinapses w_{ph} , as quais refletem o estado atual dos neurônios p e mantém sua ativação ao inibir os outros neurônios p .

Um equilíbrio adequado entre inibição por antecipação e por realimentação gera uma dinâmica robusta inibitória. Por um lado, a inibição por antecipação antecipa o nível de excitação dos neurônios p , limitando as oscilações antecipatórias dramáticas. Por outro lado, a inibição por realimentação realmente reflete a ativação atual de neurônios p . Uma forte inibição por antecipação também faz com que o sistema responda excessivamente devagar. Assim, é desejável um equilíbrio entre ambos tipos de inibição (CASTRO; MARTINI; HIRAKAWA, 2014).

Plasticidade intrínseca

O estado intrínseco s é uma parte essencial do método de controle e é responsável pela inclusão de restrições e pelo surgimento do comportamento desejado do sistema: a sincronização de neurônios p e, portanto, as fases semafóricas. Se os estados intrínsecos s dos neurônios forem fixados (na eq. (7), $s_i^{t+1} = s_i^t$), resultaria em uma dinâmica na qual as fases com maior quantidade de veículos manter-se-iam sempre ativas.

No modelo proposto, a plasticidade intrínseca é utilizada para lidar com as restrições dinâmicas de forma simples, limitando a quantidade máxima de tempo que uma fase está inativa através da eq. (7) proposta por Pelaez e Andina (2013). O deslocamento s da função sigmoide de cada neurônio é

regulado de acordo com o último passo de mudança s_i^t e a saída do último passo O_i^t . Se um neurônio p está ativo e a sua saída O é alta, o processo de mudança da função sigmoide diminuirá lentamente sua saída para permitir que outro neurônio p ocupe seu lugar como fase ativa, evitando que as fases semafóricas com maior quantidade de veículos fiquem sempre ativas, cumprindo com a restrição da dinâmica de controle de uma interseção. Enquanto isso acontece, o mesmo processo irá transformar as ativações neurais dos neurônios p inativos em saídas maiores, ajudando-os a se tornarem ativos. Assim, a plasticidade intrínseca tem um papel central na mudança dinâmica da fase dos semáforos.

A taxa de deslocamento ν determina a taxa na qual a função sigmoide é deslocada e, portanto, o tempo máximo inativo de uma fase. A taxa de deslocamento ν , que resulta em um número máximo de etapas de iteração N_{max} para que qualquer ativação neural provoque uma saída, pode ser derivada da eq. (7). O valor do coeficiente ν foi pesquisado por Castro, Martini e Hirakawa (2014) e sua forma final é indicada na eq. (8).

$$\nu = 5^{\frac{1}{N_{max}}} - 1 \quad (8)$$

Cujo número máximo de fases ativas N_{max} é igual ao tempo máximo permitido que pode ficar uma fase ativa e depende das restrições da interseção T_{max} , entre o tempo de passo do algoritmo T_{step} .

$$N_{max} = \frac{T_{max}}{T_{step}} \quad (9)$$

Plasticidade sináptica

Uma das principais características do modelo proposto é a sua capacidade de incorporar facilmente o conhecimento sobre o sistema. Isso é possível pela flexibilidade das redes neurais para representar o conhecimento através das suas unidades básicas: os neurônios e as suas conexões sinápticas.

A primeira forma pela qual o modelo proposto incorpora conhecimento sobre a dinâmica do sistema de trânsito é através das conexões recorrentes dos neurônios p . O peso desta conexão recorrente atua como um ganho,

estabelecendo quanto tempo uma fase permanece ativa. Conforme modelo proposto por Prikryl (2013), o fluxo de veículos atinge seu valor máximo por apenas um certo período de tempo após a ativação da fase, devido à aceleração dos veículos. Castro, Martini e Hirakawa (2014) comprovaram que a velocidade do fluxo de veículos atinge seu valor máximo somente após 20 segundos da ativação da fase. Portanto, um tempo ativo mais longo otimiza o fluxo de trânsito, pois os fluxos máximos de veículos permanecem mais longos e o tempo de aceleração é proporcionalmente menor comparado com o tempo de ativação da fase.

Outra característica do modelo proposto é a priorização dos fluxos dos veículos através da plasticidade sináptica. O conhecimento sobre qual fase da intersecção deve ser priorizada pode ser representado pelos pesos sinápticos w_{mn} , atualizados pela regra de Hebbian, indicada na eq. (9). Nesta equação, ε é um pequeno fator que determina a taxa de atualização, I_m é a entrada da respectiva conexão sináptica, O_n é a saída neural do neurônio pós-sináptico e Δw_{mn} é o valor de atualização real. Em cada ciclo de controle os pesos sinápticos das conexões sinápticas excitatórias são atualizados de acordo com a eq. (10).

$$\Delta w_{mn} = \varepsilon I_m (O_n - w_{mn}) \quad (9)$$

$$w_{mn}^t = w_{mn}^{t-1} + \Delta w_{mn} \quad (10)$$

Ao contrário de outros algoritmos, neste caso, a plasticidade sináptica não é utilizada para identificar padrões, mas sim para refletir o volume de trânsito em cada direção e priorizar os fluxos críticos. As conexões sinápticas mais fortes dos fluxos de trânsito priorizados impõem uma resposta mais rápida aos aumentos bruscos no volume de trânsito. Como consequência, as fases com os fluxos de veículos priorizados tornam-se mais rápidas, inativando as demais, conforme demonstrado por Castro, Martini e Hirakawa (2014). Esta característica permite que as principais artérias das redes urbanas respondam imediatamente a altas demandas, em detrimento das ruas secundárias, que tendem a ter menos trânsito e dinâmicas mais lentas.

Em geral, o comportamento desejado da rede neural é conseguido principalmente através da combinação de inibição por realimentação, inibição

por antecipação e a plasticidade intrínseca. Portanto, a plasticidade intrínseca impõe as restrições das eq. (7) e eq. (8), enquanto que a inibição de antecipação permite uma antecipação do estado do trânsito para determinar a próxima fase ativa e a inibição por realimentação permite a inibição das outras fases do ciclo semafórico. Portanto, é desejável um equilíbrio entre estes mecanismos. Lembrando que o modelo analisado reflete a política ganhador-leva-tudo, na qual o neurônio p com maior ativação é o que ativa a fase do ciclo semafórico e os outros neurônios p da interseção competem entre eles para aumentar a sua ativação e ativar a fase correspondente.

3.4.3 Determinação dos parâmetros da rede e análise de estabilidade

A determinação dos parâmetros inclui encontrar os valores adequados para os 6 pesos das sinapses ($w_q, w_{qh}, w_{qp}, w_p, w_{ph}, w_h$) de cada fase semafórica. Um método efetivo foi apresentado por Castro et al. (2015), no qual define-se que o comportamento do agente pode ser caracterizado por três propriedades intrínsecas do modelo: frequência natural de oscilação Ω , sensibilidade de entrada S e grau de sincronia τ .

Nessa pesquisa infere-se que τ depende em grande medida de w_p e de v (taxa de deslocamento).

A sensibilidade de entrada S , que considera como as variações nas entradas do sistema afeta a transição entre as fases do semáforo, define-se como:

$$S = \frac{w_{qp} + w_{qh}}{w_p} \quad (11)$$

Na eq. (11), w_{qh} e w_{qp} devem ter valores iguais para garantir uma dinâmica inibitória balanceada.

Por último, o grau de sincronia de agente de T é diretamente determinado por seu fator de sincronização τ .

Castro et al. (2015) apresentaram um método para a análise de estabilidade deste modelo. Eles concluíram que o método apresentado pode ser aplicado a qualquer conjunto de parâmetros, revelando o comportamento dinâmico de um agente de maneira direta. Os neurônios usados para ativar as fases (p_1, p_2, \dots, p_n) complementam-se, quando um deles estiver em equilíbrio

ativo enquanto os outros estão em equilíbrio inativos. Portanto, quando um comportamento oscilatório é alcançado, os neurônios produzem saídas oscilatórias. Assim, o comportamento da rede neural é extrapolado do comportamento do neurônio p_1 , definindo como o agente controla suas fases de semáforo.

Capítulo 4

4 Modelo proposto

Este capítulo apresenta o modelo proposto nesta pesquisa que visa estender o Modelo de Redes Neurais Bio-Inspiradas proposto por Castro, Martini e Hirakawa (2014) para diferenciar as relações existentes entre as interseções, adicionando informações ao modelo tais como: a distância entre as interseções, velocidade dos veículos, tempo de demora dos veículos até a próxima interseção e número de faixas da via comum entre essas interseções de forma à incorporar os aspectos reais das vias.

Para esse propósito, trata-se o problema do trânsito urbano como um controle multiagente, no qual o modelo de rede utilizado para cada interseção interage com os outros agentes de interseções vizinhas, apresentando um controle coordenado para otimizar os fluxos de veículos, sincronizando as ativações de fases comuns nessas interseções vizinhas.

Com base na metodologia proposta, estabelece-se como incorporar as informações sobre as características entre as interseções para diferenciar as relações de coordenação. A proposta respeita os comportamentos do modelo propostos e corroborados por Castro et al. (2015), sobre a estabilidade da rede neural e a complexidade computacional linear.

Para adicionar essas características ao modelo e diferenciar a relação de coordenação entre interseções propõe-se realizar um estudo para determinar quanto influi cada característica no atraso médio do fluxo de veículo entre duas interseções. Como são características invariantes no tempo, esse coeficiente de relação entre interseções pode se obter realizando um cálculo inicial off-line. Portanto, pode se afirmar que o coeficiente de relação entre interseções relaciona o nível de ocupação da via de uma interseção (variável de entrada) com a ativação da fase comum da próxima interseção ou da interseção anterior.

Posteriormente, a avaliação do modelo será realizada em um cenário réplica de um cenário real da cidade de São Paulo com características

semelhantes às encontradas no controle de trânsito real, como a demanda de veículo, a localização dos semáforos e a distância entre eles, os tipos de ciclos semaforicos utilizados e o comportamento estocástico do sistema. Por último, analisam-se e comparam-se os resultados obtidos do modelo BiNN estendido nesta proposta, com resultados do modelo BiNN proposto por Castro, Martini e Hirakawa (2014) e com o controle de tempo prefixado do ciclo semaforico aplicado no mesmo cenário, método atualmente utilizado na maioria das intersecções com semáforos.

4.1 Modelo de Rede Neural Bio-Inspiradas para o Controle Multiagente

Depois de estudar e analisar as pesquisas e os trabalhos relacionados no campo do controle do trânsito urbano, o modelo para o controle multiagente deve realizar duas funções imprescindíveis para um controle coordenado efetivo entre os agentes que controlam as intersecções. A primeira função centra-se em armazenar a informação quando uma fase de um agente vizinho for ativada até que a fase comum do seguinte agente correspondente esteja pronta para se tornar ativa, provocando ondas de luzes verdes em fases comuns de agentes vizinhos. A segunda função do controle multiagente deve inibir a fase ativa atual de um agente nos casos em que o nível de ocupação dos veículos na via comum da próxima intersecção esteja alta, o que significa que essa via comum não está pronta para receber um fluxo de veículo porque está lotada, evitando engarrafamentos e permitindo que o agente em questão possa ativar uma outra fase com possibilidade de se tornar ativa. A seguir apresenta-se a estrutura do modelo proposto.

4.1.1 Estrutura do modelo para o controle multiagente

O modelo apresentado na Figura 10 reflete a coordenação entre dois agentes de controle de duas intersecções com uma via comum entre eles e, portanto, uma fase comum (e.g. Figura 11). Um modelo como o explicado a seguir é utilizado para a coordenação entre todas as fases comuns dos agentes vizinhos no método apresentado neste trabalho.

Figura 10 - Modelo BiNN para a coordenação entre interseções.


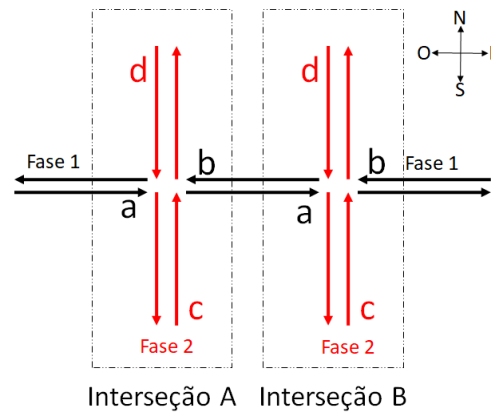


Figura 11 - Cenário com duas interseções vizinhas e uma fase comum.



A Figura 10 mostra o modelo para a coordenação entre as interseções - exemplos A e B do sistema de trânsito apresentado na Figura 11. No modelo, o neurônio $p_{1,A}$ representa o neurônio p (do modelo de controle para agentes individuais) da fase 1 do agente de controle da intersecção A, enquanto o neurônio $p_{1,B}$ representa o neurônio p da fase 1 do agente de controle da intersecção B. Desta forma, as fases comuns 1 das interseções vizinhas (com vias comuns) são coordenadas. Além disso, $q_{a,B}$ é o receptor sensorial q_a da intersecção B. Todos os outros neurônios (a_{A-B} , b_{A-B} , c_{A-B} e h_{A-B}) não fazem parte do modelo responsável pelo controle individual das interseções, apresentado no capítulo anterior, e serão explicados posteriormente.

A segunda função do modelo de coordenação de interseções, a inibição da fase ativa atual de um agente nos casos em que o nível de ocupação dos veículos na via comum da próxima intersecção esteja alta, é concretizada da seguinte forma. A inibição da fase 1 da intersecção A, nos casos em que a

ocupação na via comum a da interseção B ($q_{a,B}$) é alta, é realizada pelos interneurônios b_{A-B} que possuem a informação do estado de ocupação da via a da interseção B (Figura 11). Os interneurônios b_{A-B} inibem os neurônios p da fase comum 1 da interseção A ($p_{1,A}$), em dependência do nível de ocupação da via comum a da interseção B ($q_{a,B}$), nos casos em que o nível de ocupação da via comum da interseção B esteja alta, o que significa que essa via comum não está pronta para receber um fluxo de veículo pois está lotada, evitando engarrafamentos.

Aliás, o mecanismo para concretizar a primeira função do modelo de coordenação de interseções; armazenar a informação quando uma fase de um agente vizinho for ativada até que a fase comum do seguinte agente correspondente esteja pronta para se tornar ativa, provocando ondas de luzes verdes em fases comuns de interseções vizinhas; é apresentado a seguir. O momento ideal para ativar a fase semafórica comum da próxima interseção depende da sua ocupação. Se a próxima interseção tiver uma ocupação alta, sua fase comum deverá se tornar ativa assim que a fase comum da interseção anterior for ativada, para aliviar a ocupação antes que um novo fluxo de veículos chegar. Pelo contrário, se a próxima interseção estiver com uma baixa ocupação, a fase semafórica deve esperar pela aproximação do fluxo de veículos à interseção antes de ser ativada.

Para cumprir com os quesitos anteriores, o modelo age da seguinte forma. Quando a fase comum 1 da interseção A se tornar ativa, o neurônio $p_{1,A}$ produz uma saída, ativando o interneurônio excitatório c_{A-B} . O interneurônio c_{A-B} permanece ativo devido à sua auto-sinapse e não possui plasticidade intrínseca, o que reduziria gradualmente sua ativação (Figura 10). No entanto, devido ao sinal inibitório do interneurônio a_{A-B} , a saída do interneurônio c_{A-B} somente alcança o interneurônio h_{A-B} e o neurônio $p_{1,B}$, se o interneurônio inibitório a_{A-B} não estiver produzindo uma saída. O interneurônio inibitório a_{A-B} produz uma saída quando a ocupação $q_{a,B}$ é baixa ($1-q_{a,B}$ é alta), o que significa que o sinal de coordenação (saída do interneurônio c_{A-B}) deve esperar para chegar ao neurônio $p_{1,B}$ e ativá-lo. Quando a ocupação $q_{a,B}$ se tornar mais alta devido ao fluxo de veículos (oeste-leste) que estão chegando da fase 1 da interseção A (que está ativada) à interseção B , o interneurônio a_{A-B} para de

produzir uma saída e o interneurônio h_{A-B} e o neurônio $p_{1,B}$ são ativados. Portanto nesse momento, o neurônio $p_{1,A}$ está provocando um aumento na ativação do neurônio $p_{1,B}$, criando ondas de luzes verdes em interseções vizinhas com fases comuns. Por outra parte, a sinapse inibitória (similar à explicada anteriormente para controle de uma interseção) interneurônio h_{A-B} diminui gradualmente a ativação do interneurônio excitatório c_{A-B} , o qual não possui estabilidade intrínseca.

Desta forma, uma estrutura neural como a mostrada na Figura 10 é necessária para coordenar o fluxo de veículos leste-oeste com fases comuns 1 para o exemplo mostrado na Figura 11. De forma geral é utilizado para a coordenação de quaisquer duas interseções com fases comuns.

4.1.2 Determinação dos parâmetros da Rede Neural Bio-Inspirada para a coordenação entre agentes

A relação existente entre cada agente, lembrando que cada agente controla uma interseção, pode variar devido às características físicas como: distância entre as interseções (comprimento da via comum), configuração das interseções, características da via comum entre essas interseções (número de faixas da via e velocidade máxima permitida) e velocidade média atingida pelos veículos nessa via que pode influir no tempo de demora dos veículos para chegar na interseção vizinha.

Para diferenciar a relação existente na coordenação entre quaisquer duas interseções pode-se utilizar as sinapses w_{bp} e w_a , Figura 10. A sinapse w_{bp} descreve o grau de influência do estado de ocupação da via comum da próxima interseção (nível de ocupação da via a da interseção B , “Figura 11”) na interseção anterior (interseção A , Figura 11), no caso de inibição da fase comum na interseção anterior pois a próxima interseção não está pronta para receber um fluxo de veículos, evitando o engarrafamento.

Um valor alto do parâmetro w_{bp} significa que a interseção A possui uma alta influência na interseção B , provocando os veículos chegarem com maior rapidez. Portanto, a interseção B diminui rapidamente a ativação da fase comum da interseção A pois não está pronta para receber um fluxo de veículos. A alta influência da interseção B na interseção A , pode ser devido a

fatores como: pequena distância entre as interseções, alta velocidade média atingida pelos veículos ou um aumento do número de faixas com respeito à via anterior. Pelo contrário, um valor baixo do parâmetro significa que o grau de influência da interseção A na interseção B é baixo, e não afeta em grande medida na inibição da interseção A , pois os veículos vão demorar para chegarem na interseção B .

Por outro lado, a sinapse w_a descreve o grau de influência que possui a interseção A em B , no caso de formação de ondas de luzes verdes (Figuras 10 e 11). Como explicado anteriormente, um aumento na ativação de $p_{1,A}$ provoca um aumento na ativação do interneurônio h_{A-B} , e por sua vez provoca o aumento do nível de ativação do neurônio $p_{1,B}$. Este último comportamento vai depender de um limiar imposto pelo sinal inibitório do neurônio a_{A-B} . O valor desse sinal inibitório é inversamente proporcional ao nível de ocupação da via a da interseção B vezes o parâmetro w_a . Portanto, um valor baixo do parâmetro w_a diminui o limiar e o sinal do interneurônio h_{A-B} consegue aumentar a ativação do neurônio $p_{1,B}$ e portanto, da sua respectiva fase.

Portanto, neste caso, um valor baixo de w_a indica uma alta influência da interseção A na interseção B , o que significa que o fluxo de veículos que parte da interseção A chega rapidamente à interseção B . Deste modo, a ativação da fase $p_{1,A}$ aumenta rapidamente a fase comum da próxima interseção ($p_{1,B}$). Por conseguinte, um valor alto do parâmetro w_a significa uma baixa influência de A sobre B e os veículos vão demorar para chegar em B , portanto o limiar aumenta e a ativação de $p_{1,A}$ demora para aumentar a ativação de $p_{1,B}$. Logo podemos concluir que:

$$CR = w_{bp} = 1 - w_a = f(d, v_{max}, n_f) \quad (12)$$

Sendo:

CR – Coeficiente de relação entre duas interseções

d – Distância entre as interseções

v – Velocidade máxima atingida pelos veículos na via comum

n_f – Número de faixas da via comum

Todas as outras sinapses do modelo não possuem rótulos porque seus pesos sinápticos não são ajustáveis, sendo iguais a 1. Portanto, para definir e diferenciar a relação de coordenação entre duas intersecções deve-se encontrar o valor dos parâmetros w_{bp} e w_a .

4.2 Coeficiente de Relação entre duas intersecções

Como explicado anteriormente, o Coeficiente de Relação (CR) entre duas intersecções pode ser calculado inicialmente antes do algoritmo estiver online, controlando as fases e as relações das intersecções, pois CR depende apenas de parâmetros invariantes no tempo, como: distância entre as intersecções (comprimento da via comum entre as intersecções (d), velocidade máxima da via comum (v_{max}) e número de faixas da via comum (n_f).


Segundo Freedman (2009) a modelagem utilizada para estabelecer uma relação entre duas ou mais variáveis é chamada de Regressão. Este método ajuda a entender como determinadas variáveis influenciam outra variável, ou seja, verifica como o comportamento de uma(s) variável(is) pode mudar o comportamento de outra variável.

4.2.1 Regressão

A Análise de Regressão possibilita encontrar uma relação razoável entre as variáveis de entrada e a variável de saída por meio de relações empíricas. A utilização desta abordagem necessita de uma coleta de dados e do uso de métodos estatísticos. A coleta de dados permite conhecer a natureza da relação entre as variáveis de entrada e saída, e realizar estudos capazes de acomodar situações inesperadas. Se a relação for de apenas uma variável de entrada com a variável resposta temos o caso de Regressão Linear Simples. Mas se a relação for da variável resposta com mais de uma variável de entrada é utilizada a Regressão Linear Múltipla (CHIANG, 2003).

Os modelos de Regressão são construídos com vários objetivos. Neste trabalho será utilizado para prever os possíveis valores do coeficiente de relação entre duas intersecções, dependendo dos parâmetros reais das vias. Portanto, espera-se que grande parte da variação do CR seja explicada pelos parâmetros d , v_{max} e n_f . Deste modo pode-se afirmar que consegue-se

encontrar um modelo para obter os valores de CR correspondentes aos valores de d , v_{max} e n_f , embora esses novos valores não estejam dentro dos dados coletados inicialmente. O modelo é chamado de função de Regressão e é a função $f(d, v, n_f)$ em (12) (Figura 12). Este procedimento é chamado de predição e para este trabalho serão selecionados valores de entrada ao modelo de regressão dentro do intervalo de variação que posteriormente serão utilizados para não ter que lidar com o problema da extrapolação.



Fonte: Autor

4.2.2 Coleta de dados

Como explicado anteriormente, para fazer uma análise de Regressão precisa-se de um banco de dados das relações das variáveis de entrada e de saída para conhecer a natureza dessa relação. A coleta de dados apresentada neste trabalho compreende um conjunto de pontos d_i , v_{max_i} e n_{f_i} (variáveis de entrada) e seus respectivos CR (variável de saída). Com o objetivo de obter estes dados, várias series de simulações são realizadas variando os intervalos das variáveis de entrada e obtendo a simulação com a melhor resposta, sendo o coeficiente de relação da simulação com melhor resposta a saída para cada conjunto de variáveis de entrada.

Cada série de simulações consiste em um conjunto de variáveis de entrada com um valor fixo ($d = d_i$, $v_{max} = v_{max_i}$, e $n_f = n_{f_i}$) e o coeficiente de relação CR varia entre 0.01 até 1 com incremento de 0.01 e cada série de simulações contém 100 simulações. Depois de realizar as 100 simulações de cada serie são analisados os resultados e seleciona-se a simulação que apresenta a melhor resposta, e, portanto, o melhor coeficiente de relação para as variáveis de entrada. Os parâmetros de avaliação para escolher a simulação com a melhor resposta são: Tempo Médio de Viagem (TMV) e Nível Médio de Ocupação das Vias (NMOV), indicadores de desempenho vastamente utilizados na bibliografia referente ao tema, como apresentado anteriormente no capítulo 2 deste trabalho.

Os valores das variáveis de entrada para cada simulação são apresentados na Tabela 3-1. No caso da distância, utilizou-se um intervalo de 50-450 metros, com incremento de 100 metros. Os valores de velocidade máxima utilizados são 40, 50 e 60 quilômetros por hora, que são as velocidades máximas comumente permitidas pelos órgãos encarregados da Segurança do Tráfego nas regiões urbanas. Por último, as vias utilizadas tiveram entre 1 até 4 faixas, com incremento de 1. Então, por uma simples combinação pode se concluir que o banco de dados para a posterior procura das funções de regressão terá 60 amostras ($5 \cdot 4 \cdot 3 = 60$).

Tabela 4-1. Valores das variáveis de entrada

<i>Distância entre intersecções (m)</i>	<i>Velocidade Máxima (km/h)</i>	<i>Número de Faixas da Via Comum</i>
50	40	1
150	50	2
250	60	3
350		4
450		

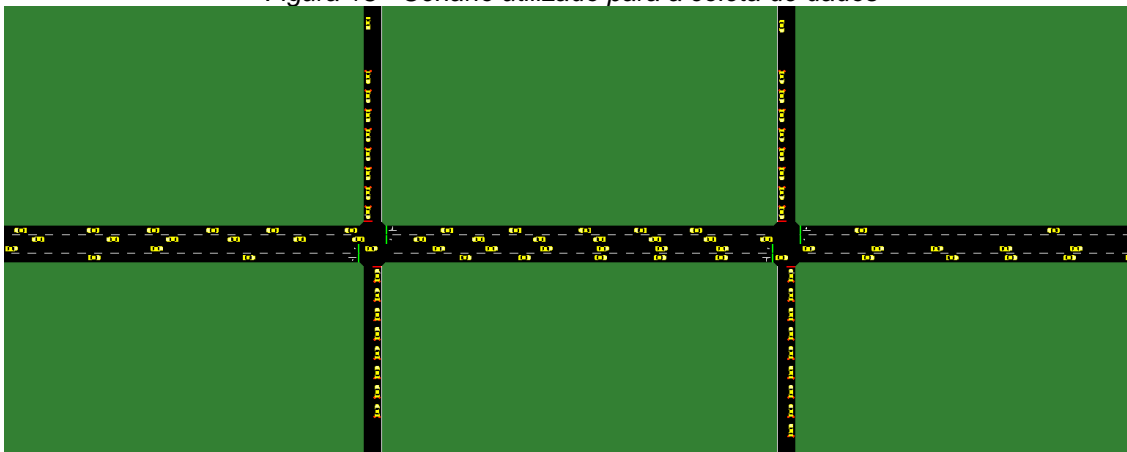
4.2.3 Cenário e Simulações

O cenário utilizado para a obtenção dos dados é bem simples, consiste de uma rua principal e duas ruas perpendiculares formando duas intersecções com semáforos (Figura 13). O algoritmo BiNN é aplicado nos agentes de controle das intersecções com as relações de coordenação entre elas. A demanda de veículos utilizada para todas as simulações foi selecionada entre média e intensa, com um valor de 2.75 veículos/segundo. Conforme explicado anteriormente, se as variáveis de entrada variam, a configuração do cenário varia da mesma forma. Um exemplo, a Figura 13 exhibe uma configuração de cenário com uma distância entre as intersecções de 150 metros, 2 faixas na rua principal e uma velocidade máxima permitida aos veículos de 50 km/h.

As simulações foram realizadas utilizando o software MATLAB ("*Matrix Laboratory*") e a ferramenta SUMO ("*Simulation of Urban Mobility*") (v 32.0) (BEHRISCH et al., 2011). O modelo BiNN foi programado no MATLAB (v R2016), enquanto o modelo do sistema de trânsito urbano foi programado em XML ("*eXtensible Markup Language*") utilizado no ambiente SUMO. Para realizar as simulações e análises dos resultados, foi utilizado o protocolo

TraCI4Matlab desenvolvido por Acosta Gil (2014), que adota o paradigma cliente-servidor e permite a interação entre SUMO (servidor) e o MATLAB (cliente). Todas as simulações têm um tempo de duração de 3600 segundos (uma hora).

Figura 13 - Cenário utilizado para a coleta de dados



Fonte: Autor

Os valores iniciais dos parâmetros do algoritmo BiNN selecionados como: as sinapses w_i , o coeficiente de adaptação dos neurônios v (constante) e a inclinação da função de ativação m (constante), foram os mesmos utilizados por Castro, Martini e Hirakawa (2014); Castro et al. (2015) e Castro, Hirakawa e Martini (2017) nas suas pesquisas. Enquanto o resto dos parâmetros começam com valor igual a 0 e variam ao longo do controle de acordo com a Tabela 4-2.

Tabela 4-2. Valores iniciais dos parâmetros do algoritmo BiNN

Parâmetro	Valor	Parâmetro	Valor
w_q	1	w_h	-0.3
w_{qh}	0.4	w_p	0.4
w_{qp}	0.4	v	0.125
w_{ph}	0.3	m	25

4.2.4 Dados coletados

Depois de configurar o algoritmo BiNN e o cenário, foram realizadas as simulações, 6000 no total, 60 séries de variáveis de entrada (d, v, n_f), e 100 simulações para cada série. Para cada série de simulação foi selecionada a melhor resposta em termos de TMV e NMOV e o coeficiente de relação dessa simulação foi selecionado como a variável de saída para essa série de


variáveis de entrada. Na tabela 4-3 apresentam-se algumas das respostas obtidas em uma série de simulação com variáveis de entrada ($d = 50, v_{max} = 40, n_f = 3$). Nesta série foi selecionada a simulação com coeficiente de relação $R = 0.96$ por ter os menores valores de TMV e de NMOV. O resultado obtido é razoável de acordo com o explicado anteriormente, no qual foi concluído que intersecções próximas devem ter relações fortes, portanto coeficientes de relação próximos a 1.

Tabela 4-3. Resultados da série de simulação com $d = 50, v_{max} = 40, n_f = 3$

Coefficiente de Relação R	Tempo Médio de Viagem TMV	Nível Médio de Ocupação das Vias NMOV
0.52	115.30	82.71
0.54	109.29	82.71
0.56	109.29	82.71
0.58	109.10	82.71
0.60	109.10	82.71
0.62	109.10	82.71
0.64	101.71	77.33
0.66	106.29	77.33
0.68	103.97	82.79
0.70	108.32	81.82
0.72	107.84	81.82
0.74	104.85	82.56
0.76	103.63	87.06
0.78	103.06	87.06
0.80	103.06	87.06
0.82	104.05	84.94
0.84	104.05	84.94
0.86	104.09	84.94
0.88	103.36	84.94
0.90	104.58	87.60
0.92	103.51	88.40
0.94	102.30	84.07
0.96	101.65	71.18
0.98	106.68	82.76
1.00	102.40	82.94

Depois de realizar as simulações e analisar as respostas de cada série de simulação obteve-se os dados com as amostras das variáveis de entrada e saída. Na Figura 14 e na Tabela 4-4 apresenta-se o resultado da análise, um total de 60 mostras (60 pontos) com variáveis de entrada e saída.

Figura 14. Melhores Coeficientes de Relação obtido em cada série



Fonte: Autor

Tabela 4-4. Dados obtidos na coleta

Número de Série de Simulação	Variáveis de Entradas			Variável de Saída
	Distância d	Velocidade Máxima v_{max}	Número de Faixas n_f	Coefficiente de Relação R
1	450	16,67	3	0,12
2	450	16,67	4	0,15
3	450	11,11	2	0,16
4	450	11,11	3	0,21
5	450	13,89	4	0,21
6	450	16,67	2	0,26
7	450	13,89	2	0,28
8	450	11,11	1	0,29
9	450	11,11	4	0,32
10	350	13,89	4	0,38
11	450	13,89	1	0,42
12	450	16,67	1	0,42
13	350	13,89	2	0,45
14	350	16,67	2	0,48
15	350	11,11	1	0,5
16	350	11,11	4	0,5
17	350	11,11	2	0,52
18	350	11,11	3	0,52
19	350	16,67	4	0,58
20	450	13,89	3	0,6
21	250	11,11	2	0,61
22	350	13,89	3	0,61
23	250	13,89	4	0,62
24	250	16,67	4	0,62
25	250	13,89	2	0,63
26	350	16,67	3	0,63
27	250	11,11	1	0,66
28	250	16,67	2	0,68
29	350	13,89	1	0,7
30	350	16,67	1	0,71
31	150	11,11	1	0,72
32	150	11,11	2	0,72
33	250	13,89	1	0,72
34	150	16,67	2	0,74
35	250	11,11	3	0,74
36	250	13,89	3	0,75
37	250	16,67	3	0,75
38	250	16,67	1	0,77
39	50	11,11	1	0,78
40	150	13,89	1	0,78
41	150	11,11	3	0,79
42	150	16,67	1	0,79
43	250	11,11	4	0,8
44	50	11,11	2	0,83
45	150	16,67	3	0,86
46	50	13,89	1	0,88
47	50	16,67	1	0,88
48	150	13,89	3	0,9
49	150	13,89	4	0,92
50	150	16,67	4	0,92
51	50	16,67	3	0,94
52	50	11,11	3	0,96
53	50	13,89	2	0,96
54	50	13,89	3	0,96
55	60	17	4	0,96
56	150	11,11	4	0,96
57	150	13,89	2	0,96
58	50	16,67	2	0,98
59	50	11,11	4	1
60	50	13,89	4	1

4.3 Modelos de Regressão

Depois de obter os dados conforme explicado anteriormente devemos encontrar o Modelo de Regressão. Neste caso serão avaliados vários modelos para depois, em cenários com características reais, validar esses modelos e concluir qual modelo fornece o melhor resultado.

Os seguintes métodos matemáticos foram avaliados para encontrar os modelos:

1. Função polinomial com uma variável.
2. Função polinomial com duas variáveis.
3. Redes Neurais Artificiais.

4.3.1 Função Polinomial com uma variável

Em estatística, o coeficiente de correlação de Pearson ρ mede o grau da correlação entre duas variáveis X e Y. Se o coeficiente ρ tiver um valor entre -1 e 1 então pode se concluir que as variáveis têm uma correlação linear, positiva no caso $0 < \rho < 1$ e negativa no caso $-1 < \rho < 0$. A correlação de Pearson (Eq. 13) é igual à covariância de ambas variáveis dividida pela raiz quadrada do produto das suas variâncias (RODGERS; NICEWANDER, 1988).

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (13)$$

Segundo os autores, infere-se o seguinte:

- $|\rho| > 0.9$ - correlação muito forte
- $0.7 > |\rho| > 0.9$ - correlação forte
- $0.5 > |\rho| > 0.7$ - correlação moderada
- $0.3 > |\rho| > 0.5$ - correlação fraca
- $0 > |\rho| > 0.3$ - correlação desprezível

Aliás, qualquer função polinomial de uma variável (P1V) pode ser representada pela expressão:

$$P(x) = a_0x^n + a_1x^{n-1} + a_2x^{n-2} + \dots + a_{n-1}x + a_n \quad (14)$$

$a_0, a_1, a_2, \dots, a_{n-1}$ e a_n são os coeficientes da função polinomial e o grau da função $n \in N$.

Para obter um modelo de regressão utilizando a P1V temos que usar apenas uma variável de entrada e achar os coeficientes e o grau da função que corresponde com o menor erro médio de predição. Para este caso obteve-se a variável: tempo mínimo de chegada do fluxo de veículo até a próxima intersecção t_{min} (Eq. 15) que é igual à distância entre as intersecções dividida pela velocidade máxima permitida na via comum entre as intersecções. Após a análise de correlação, concluiu-se que a correlação entre t_{min} e R é forte ($\rho = -0.877$), portanto pode-se utilizar t_{min} como variável de entrada para o Modelo de Regressão Linear Simples.


$$t_{min_i} = \frac{d_i}{v_{max_i}} \quad (15)$$

O melhor resultado, em termos de erro médio de predição ($\bar{E} = 0,0642$) foi obtido com uma função polinomial de grau 8, apresentada a seguir:

$$f(t) = 0.0001t^8 - 0.0017t^7 + 0.0254t^6 - 0.2638t^5 + 1.8903t^4 - 9.0060t^3 + 26.7895t^2 - 44.4269t + 32.0152 \quad (16)$$

Na Figura 15 pode-se observar o resultado da regressão utilizando o método de Função Polinomial com grau 8.

Figura 15 - Resposta do Modelo de Regressão com o método de Função Polinomial com uma variável de entrada (t_{min})



Nesse gráfico podemos observar que, para cada valor de tempo, existem 4 resultados de coeficientes de relação diferentes (4 pontos), isso acontece pois para cada valor de d_i e v_{max_i} (no final t_{min_i}) existem 4 respostas diferentes na vertical, sendo as respostas das simulações para os 4 valores do

parâmetro número de faixas. Existem valores de tempo para os quais não se percebe no gráfico 4 respostas, isso acontece porque o CR tem uma resposta semelhante para valores de número de faixas diferentes.

4.3.2 Função Polinomial com duas variáveis

O segundo método utilizado para encontrar o Modelo de Regressão foi uma Função Polinomial com duas variáveis de entrada (P2V), essas variáveis são: o tempo mínimo dos veículos para chegar até a próxima intersecção (t_{min_i}) e o número de faixas presentes na via comum entre as duas intersecções (n_f). O melhor resultado foi obtido com uma função polinomial de grau 6 com coeficientes b mostrados na Tabela 4-5 com um erro médio de predição de 0.0601 com relação aos valores dos coeficientes de relação obtidos na coleta de dados para esses mesmos cenários.


Tabela 4-5. Coeficientes obtidos da Função Polinomial de duas variáveis

$g(t, n_f) =$					
b_1	$b_1 =$	1.0822	$b_{12}n_f^3t$	$b_{12} =$	-0.0072
b_2t	$b_2 =$	-0.1594	$b_{13}t^3n_f$	$b_{13} =$	0.0008
b_3n_f	$b_3 =$	-0.0933	$b_{14}n_f^3t^2$	$b_{14} =$	0.0012
b_4n_ft	$b_4 =$	0.1150	$b_{15}t^3n_f^2$	$b_{15} =$	-0.0002
b_5t^2	$b_5 =$	0.0184	$b_{16}t^3n_f^3$	$b_{16} =$	0
$b_6n_f^2$	$b_6 =$	0	$b_{17}t^4$	$b_{17} =$	0
$b_7t^2n_f$	$b_7 =$	-0.0150	$b_{18}n_f^4$	$b_{18} =$	0.0020
$b_8n_f^2t$	$b_8 =$	0	$b_{19}t^4n_f$	$b_{19} =$	0
$b_9n_f^2t^2$	$b_9 =$	0	$b_{20}n_f^4t$	$b_{20} =$	0.0008
$b_{10}n_f^3$	$b_{10} =$	-0.0049	$b_{21}t^4n_f^2$	$b_{21} =$	0
$b_{11}t^3$	$b_{11} =$	-0.0008	$b_{22}n_f^4t^2$	$b_{22} =$	-0.0002

A representação gráfica da resposta do método P2V é dificultada por causa da existência de duas variáveis de entrada e uma de saída. Portanto, a resposta foi separada em dois gráficos. A Figura 16 mostra a resposta obtida com o modelo de regressão em função do tempo mínimo, observa-se que para cada valor de t_{min_i} existem 4 pontos na vertical, que são as 4 simulações com os 4 valores diferentes no parâmetro número de faixa. A principal diferença entre o modelo P1V e o modelo P2V é que o segundo modelo consegue diferenciar a resposta quando existe uma variação no parâmetro número de faixas. Este comportamento é perfeitamente visível na Figura 17, na qual mostra-se a resposta do modelo tendo em conta a variação no número de faixas. Observe-se que o coeficiente de relação obtido varia em dependência


do número de faixas da via. Normalmente o maior CR é atingido para configurações com o maior número de faixas na via comum. Essa é uma resposta lógica, pois nesse tipo de cenário (vias com maior quantidade de faixas) os veículos possuem mais liberdade em relação ao movimento e conseguem chegar mais rápido à próxima intersecção.

Figura 16 - Resposta do Modelo de Regressão com o método de Função Polinomial com duas variáveis de entrada (t_{min} e n_f).



Fonte: Autor

Figura 17 - Variação do coeficiente de relação tendo em conta a variação do número de faixas



Fonte: Autor

4.3.3 Rede Neural Artificial

O último método utilizado para achar um Modelo de Regressão são as Redes Neurais Artificiais Supervisionadas (RNA). Neste caso utiliza-se uma rede neural convencional com 3 variáveis de entrada (d, v, n_f) e uma variável de saída (R), e obteve-se a função apresentada na Eq. 17. Para o processo de

treinamento e validação da rede neural utilizaram-se as 60 mostras obtidas na fase de coleta de dados. Depois de criar, configurar e treinar várias redes com diferentes parâmetros e tipos de configurações com a ajuda do toolbox de Redes Neuras do Matlab, obteve-se a melhor resposta em termos de erro médio com uma Rede Neural Artificial com as seguintes características:


- Rede composta por 3 camadas (uma camada de entrada, uma camada intermediária e uma camada de saída). A camada de entrada possui 9 neurônios, a camada intermediária possui 4 neurônios e a camada de saída possui 1 neurônio.
- A função de transferência dos neurônios das duas primeiras camadas é a tangente hiperbólica e a ativação do neurônio da última camada é calculada mediante uma função linear.
- Os valores dos pesos sinápticos são atualizados de acordo com o algoritmo de treinamento de backpropagation Levenberg-Marquardt. O método procura um mínimo local em uma função e converge mais rapidamente do que um algoritmo genético (SAPNA; TAMILARASI; KUMAR, 2012).
- A função de desempenho utilizada foi o Erro Quadrático Médio.

$$R = z(d, v, n_f) \quad (17)$$

A seguir é apresentada a resposta do Modelo de Regressão utilizando o método RNA. Esta resposta apresentou um erro médio de 0.0195, uma diminuição notável com respeito aos métodos utilizados anteriormente. Na Figura 18 pode-se observar que os resultados obtidos com este método cobrem quase todas as amostras obtidas na fase de coleta de dados, portanto apresenta uma resposta mais exata do que os métodos polinomiais apresentados anteriormente. A Figura 19 mostra a resposta do método em dependência de cada série de simulação da coleta de dados. Por exemplo, a simulação 1 (da Tabela 4-4) corresponde aos valores $d = 450, v_{max} = 60, n_f = 3$, a simulação 2 corresponde aos valores $d = 450, v_{max} = 60, n_f = 4$ e assim por diante. Os valores dos parâmetros de entrada para cada número de série de simulação podem ser observados na Tabela 4-4. A resposta da aproximação por regressão apresenta alguns comportamentos instáveis


quando comparado com a resposta da simulação. Isso acontece devido aos CR não apresentarem uma resposta uniforme em relação à variação dos parâmetros de entrada na fase da coleta de dados. Assim, o erro de aproximação da RNA pode aumentar. Na série de simulação 20 ($d = 450, v_{max} = 50, n_f = 3$), $CR = 0.60$ e com valores muito semelhantes nas séries de simulação 5 ($d = 450, v_{max} = 50, n_f = 2$) e simulação 6 ($d = 450, v_{max} = 50, n_f = 4$), os melhores CR obtidos na fase de coleta de dados foram 0.21 e 0.26 e que são bem distantes do 0.60 obtido com valores semelhantes nos parâmetros de entrada. Esse comportamento dificulta o processo de obtenção da função de regressão.

Figura 18 - Resposta do Modelo de Regressão com o método de Redes Neurais Artificiais com 3 variáveis de entrada (d, v, n_f)



Fonte: Autor

Figura 19 - Comparação da resposta obtida no modelo de regressão (Redes Neurais Artificiais) com a resposta obtida na coleta de dados



Fonte: Autor

4.4 Algumas considerações sobre as funções de regressão

Com base na simplificação de parâmetros (utilizou-se $t_{min} = d/v_{max}$ como variável de entrada e não teve-se em conta variável parâmetro n_f), uma das funções de Regressão propostas foi a função polinomial de regressão com uma variável de entrada, obtendo-se um erro médio de aproximação de 6.42%, quando comparado com os valores obtidos na coleta de dados. Essa função inclui dois dos parâmetros apresentados inicialmente (d, v_{max}), simplificada por meio da Eq. 15. Por outro lado, na função polinomial de regressão com duas variáveis de entrada (t_{min}, n_f), que compreende os três parâmetros a serem adicionados ao modelo (d, v_{max}, n_f), o erro obtido foi de 6.01%. Por último, com a função de regressão obtido por meio de Redes Neurais Artificiais, o erro diminuiu consideravelmente até 1.95%. Portanto, quando comparado o erro médio de aproximação das três funções de regressão utilizadas, podemos concluir que o método de RNA apresenta o melhor resultado com a melhor aproximação aos valores de entrada e saída obtidos na fase de coleta de dados. No próximo capítulo é apresentada a forma de validação dos métodos de cálculo do coeficiente de relação apresentados neste capítulo e escolhe-se o método que apresenta o melhor resultado.

Capítulo 5

5 Prova de conceito

O capítulo apresenta a prova do conceito visando validar as contribuições da pesquisa, e para isso, são analisados os diferentes métodos de cálculo do Coeficiente de Relação entre intersecções vizinhas para descobrir qual deles fornece a melhor resposta mediante a aplicação do modelo de Redes Neurais Bio-inspiradas no controle de intersecções com uma abordagem distribuída e coordenação entre os agentes que as controlam. Os métodos avaliados serão aplicados no controle dos agentes das intersecções em um cenário réplica de um cenário real e a resposta é analisada em termos de TMV e NMOV. Com esse objetivo são calculados os valores mais adequados tanto para cada um dos métodos do cálculo do Coeficiente de Relação quanto para o algoritmo BiNN. O cenário escolhido localiza-se na cidade de São Paulo. Os resultados obtidos com os diferentes modelos do cálculo do *CR* também serão comparados com um algoritmo BiNN que não diferencia a relação entre as intersecções (apresentado em Castro et al. (2015)) e com o método de controle atual utilizado na maioria das intersecções da cidade: Controle com Tempos Prefixados.

5.1 Cenário

O cenário real escolhido visa transpor as limitações dos cenários ideais selecionados para analisar o modelo BiNN em trabalhos anteriores (CASTRO; MARTINI; HIRAKAWA, 2014; CASTRO et al., 2015, 2017). O propósito é conseguir fornecer uma ideia real dos resultados que poderiam se obter levando a proposta à prática. Nas pesquisas anteriores utilizam-se cenários idealizados, pois exibem uniformidade nas suas estruturas (as distâncias entre as intersecções são todas iguais), além de contar com um número pequeno de intersecções com semáforos, bem distantes dos cenários reais encontrados nos grandes centros urbanos.

A cidade de São Paulo batalha diariamente contra o congestionamento do trânsito. É um dos maiores centros urbanos do mundo, de acordo com Instituto

Brasileiro de Geografia e Estatística, (2018) tinha em 2018, uma população aproximada de 12.176.866 habitantes apenas no município do mesmo nome, que possui uma extensão de 1.521,11 km², com uma densidade populacional de 8.005,25 habitantes por quilômetro quadrado. A cidade tem uma frota veicular de aproximadamente 7 milhões de veículos e uma extensão de vias de aproximadamente 17.000 km incluindo ruas e avenidas e 6.387 semáforos em 2017 (PREFEITURA DE SÃO PAULO, 2017). Como resultado, São Paulo possui um dos mais altos níveis de fluxo de veículos, com frequentes engarrafamentos de mais de 150 km de lentidão na região do centro expandido no horário de pico (PREFEITURA DE SÃO PAULO, 2017).

Na zona oeste da cidade, especificamente na região do bairro do Butantã, encontra-se uma das principais rodovias da cidade, a Raposo Tavares que conecta todas as cidades da região Sudoeste da Grande São Paulo com a Capital, o que provoca, sobretudo em horário de picos, engarrafamentos de trânsito. Devido ao alto número de veículos que são utilizados nesta via para chegar e sair dos trabalhos, escolas e faculdades, foi escolhido um trecho dessa região como cenário para a prova de conceito.

O cenário escolhido encontra-se perto da estação Butantã do metrô, e compreende um total de 7,4 km de vias (Figuras 7 e 8), com 9 intersecções com semáforos. Como apresentado anteriormente, a Rodovia Raposo Tavares tem um fluxo bem alto de veículos procedente da região Sudoeste da Grande São Paulo, mesma característica apresentada pela Av. Professor Francisco Morato. Além disso, esta região tem uma característica muito importante para avaliar a proposta: as distâncias das vias comuns entre as intersecções vizinhas variam entre 70 e 400 metros, as velocidades máximas permitidas nessas vias também variam entre 40 e 60 *km/h* e o número de faixas varia entre 1 e 4, dependendo da via.

As rotas dos veículos foram programadas com as mesmas características das rotas de trânsito descritas e observadas nos Radars da prefeitura e no site da Globo (GLOBO COMUNICAÇÃO E PARTICIPAÇÕES S.A, 2017; PREFEITURA DE SÃO PAULO, 2017), além das observadas pelo autor nas pesquisas de campo realizadas.

de cada neurônio mediante a eq. 9 que define a priorização das fases com maior fluxo de veículos. Os valores dos coeficientes (Tabela 5-1) sinápticos utilizados foram os mesmos calculados por Castro et al. (2015) baseado em um método proposto para a determinação dos parâmetros da rede.

Tabela 5-1. Valores iniciais dos coeficientes sinápticos

w_q	1	w_p	0.4
w_{qh}	0.4	w_{ph}	0.3
w_{qp}	0.4	w_h	-0.3

Em relação à estrutura matemática da rede responsável pelo controle de uma intersecção existem outros dois parâmetros a serem determinados: a inclinação da função sigmoide m (Eq. 6) e a taxa de deslocamento dos neurônios v (Eq. 7). O valor de m é igual a 25, sendo apresentado por Castro, Martini e Hirakawa (2014). O valor de v foi calculado mediante as Eqs. 8 e 9. O tempo de espera máximo de uma fase inativa (T_{max}) selecionado foi 90 segundos e o tempo de atualização (T_{step}) do algoritmo, 10 s, portanto, o valor de v calculado foi 0.195 para todas as intersecções do cenário.

Na rede responsável pela coordenação entre intersecções existem dois coeficientes sinápticos a serem calculados: w_{bp} e w_a , pois os outros coeficientes sinápticos não influenciam no controle da coordenação e, portanto, são todos iguais a 1 (Figura 10, não têm marcadores). Os valores dos parâmetros w_{bp} e w_a variam em dependência das características físicas do cenário e serão calculados na próxima secção.

Em relação à estrutura matemática da rede de coordenação, os neurônios p e h têm plasticidade sináptica, portanto o valor da taxa de deslocamento s é atualizada a cada tempo de atualização do algoritmo (Eq. 7). Os valores das taxas de deslocamento dos neurônios a , b , c e d são explicados a seguir. Os valores das taxas de deslocamento s_c e s_d são iguais a 0.1 para que qualquer saída os ative e aumente a ativação da intersecção seguinte no caso da criação de ondas de luzes verdes em intersecções vizinhas. O neurônio b possui o valor do seu limite inferior alterado, igual a 0.8, com o objetivo de que uma ocupação superior a 0.8 seja capaz de produzir uma saída significativa e, portanto, inibir a intersecção vizinha anterior (esse é o caso em que a via não consegue receber um novo fluxo de veículos porque está lotada). O neurônio a ,

que é o responsável pela inibição do sinal que cria as ondas de luzes verdes, aguarda uma ocupação de 50% da sua capacidade total na via comum para começar a liberar esses veículos e receber um novo fluxo de veículo da intersecção vizinha anterior, sendo a taxa de deslocamento desse neurônio fixada em 0.5.

Por último, a entrada $q_{a,B}$ da rede responsável pela coordenação entre intersecções foi tomada como uma porcentagem de ocupação dessa via (Eq. 18) diferente da rede responsável pelo controle de uma intersecção que foi tomada como uma porcentagem do total de veículos das vias que conformam essa intersecção (Eq. 19).

$$q_{a,B} = \frac{\text{ocupação atual da via}}{\text{ocupação total da via}} \quad (18)$$

$$q_a = \frac{\text{numeros de veículos na via } a}{\text{numero de veículos de todas as vias}} \quad (19)$$

5.3 Cálculo dos parâmetros da extensão proposta ao modelo BiNN

Este trabalho visou estender o modelo BiNN adicionando informações, tais como: distância entre as intersecções, velocidade dos veículos e número de faixas da via comum entre essas intersecções, para torná-lo aderente às diferenças existentes entre as intersecções do cenário real de trânsito, como explicado anteriormente. As informações são adicionadas ao modelo por meio do Coeficiente de Relação (CR) entre duas intersecções. Mas para calcular o CR precisa-se das informações físicas do cenário (cumprimentos das vias comuns, velocidades máximas permitidas e número de faixas dessas vias).

Como apresentado anteriormente, o cenário escolhido inclui 9 intersecções com semáforos e os valores dos parâmetros que precisam-se calcular são de vias comuns entre intersecções vizinhas. Na Tabela 5-2 podemos observar quais são as relações entre as intersecções no cenário escolhido. O sentido da relação sempre é da vertical para a horizontal. Um exemplo, a intersecção 5 tem relação com a intersecção 1 mediante os veículos que viajam de norte para o sul (4) pela rua Alvarenga (fase 2 - vertical), então neste caso, o trecho entre as ruas Reação e Sapetuba é a via comum entre as duas intersecções vizinhas (5 e 1) (Figura 22). Outro exemplo de relação, um pouco mais complexo, pode ser encontrado entre as

intersecções 1 e 2. Neste caso, as duas fases (1 e 2) da intersecção 1 apresentam relação com a intersecção 2. A fase 1, que são os veículos que viajam pela Rodovia Raposo Tavares e continuam pela rua Sapetuba (via 1 da intersecção 1, com deslocamento oeste-leste) e por outro lado, os veículos que viajam pela rua Alvarenga (via 4 da intersecção 1, com movimento de veículo norte-sul) e tomam a rua Sapetuba (Figura 22). Portanto, neste caso, a célula que representa esta relação possui dois números 1 e 4, que são as fases da intersecção 1 que estão relacionadas com a intersecção 2.

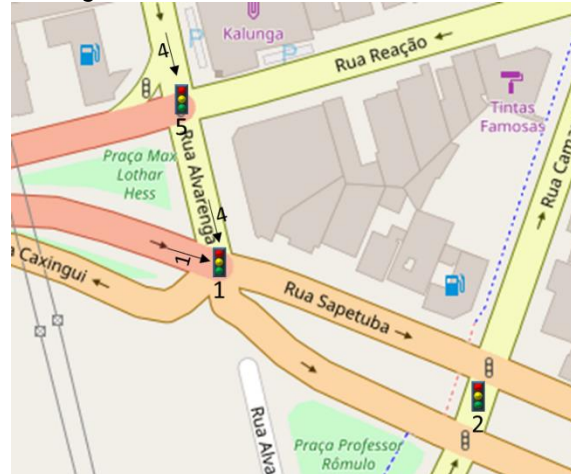
Tabela 5-2 Relações entre as intersecções.

	1	2	3	4	5	6	7	8	9
1		1,4							
2			1			1,3			
3				1					
4									
5	4								
6					2			3	
7						2,4		2	
8									2
9					4,2				

Relação:	
1	oeste para leste
2	leste para oeste
3	sul para norte
4	norte para sul

FASE 1
FASE 2

Figura 22 – Trecho do cenário escolhido



Fonte: Autor

A seguir são apresentadas 3 tabelas com os valores de cada parâmetro para o cálculo do CR segundo a Eq. 12: comprimento da via (Tabela 5-3), velocidade máxima permitida na via (Tabela 5-4) e número de faixas da via (Tabela 5-5), sempre se referindo às vias comuns entre intersecções vizinhas.

Tabela 5-3 Distância entre intersecções vizinhas (metros)

	1	2	3	4	5	6	7	8	9
1		100	-	-	-	-	-	-	-
2	-		320	-	-	145	-	-	-
3	-	-		50	-	-	-	-	-
4	-	-	-		-	-	-	-	-
5	56	-	-	-		-	-	-	-
6	-	-	-	-	158		-	65	-
7	-	-	-	-	-	170		150	-
8	-	-	-	-	-	-	-		217
9	-	-	-	-	175	-	-	-	

Tabela 5-4 Velocidade máxima permitida na via (km/h)

	1	2	3	4	5	6	7	8	9
1		60	-	-	-	-	-	-	-
2	-		60	-	-	50	-	-	-
3	-	-		50	-	-	-	-	-
4	-	-	-		-	-	-	-	-
5	60	-	-	-		-	-	-	-
6	-	-	-	-	50		-	50	-
7	-	-	-	-	-	50		40	-
8	-	-	-	-	-	-	-		40
9	-	-	-	-	50	-	-	-	

Tabela 5-5. Número de faixas da via comum

	1	2	3	4	5	6	7	8	9
1		4	-	-	-	-	-	-	-
2	-		4	-	-	2	-	-	-
3	-	-		4	-	-	-	-	-
4	-	-	-		-	-	-	-	-
5	4	-	-	-		-	-	-	-
6	-	-	-	-	3		-	2	-
7	-	-	-	-	-	3		2	-
8	-	-	-	-	-	-	-		2
9	-	-	-	-	4	-	-	-	

Depois de obter os valores dos parâmetros d e v_{max} é possível calcular o t_{min} mediante a eq. 15, obtendo-se uma nova tabela de tempos mínimos de demora para o fluxo de veículo chegar na próxima intersecção (Tabela 5-6).

Tabela 5-6. Tempos mínimos para o novo fluxo de veículos chegar na intersecção seguinte.

	1	2	3	4	5	6	7	8	9
1		4	-	-	-	-	-	-	-
2	-		4	-	-	2	-	-	-
3	-	-		4	-	-	-	-	-
4	-	-	-		-	-	-	-	-
5	4	-	-	-		-	-	-	-
6	-	-	-	-	3		-	2	-
7	-	-	-	-	-	3		2	-
8	-	-	-	-	-	-	-		2
9	-	-	-	-	4	-	-	-	

O próximo passo foi obter os *CRs* para cada método apresentado no capítulo anterior: P1V, P2V e RNA. O método P1V só depende do t_{min} e os valores foram calculados a partir da Eq. 16 e apresentados na tabela 5.7. O método P2V depende dos parâmetros t_{min} e n_f e os valores dos *CRs* foram calculados a partir dos coeficientes apresentados na Tabela 4-5 e os valores calculados são apresentados na Tabela 5-8. Por último, na Tabela 5-9 são mostrados os valores dos *CRs* calculados a partir do método RNA.

Tabela 5-7. Valores do CR calculados pelo método P1V

	1	2	3	4	5	6	7	8	9
1		0.81	-	-	-	-	-	-	-
2	-		0.64	-	-	0.86	-	-	-
3	-	-		0.96	-	-	-	-	-
4	-	-	-		-	-	-	-	-
5	0.96	-	-	-		-	-	-	-
6	-	-	-	-	0.87		-	0.87	-
7	-	-	-	-	-	0.85		0.81	-
8	-	-	-	-	-	-	-		0.65
9	-	-	-	-	0.86	-	-	-	

Tabela 5-8. Valores do CR calculados pelo método P2V

	1	2	3	4	5	6	7	8	9
1		0.99	-	-	-	-	-	-	-
2	-		0.63	-	-	0.82	-	-	-
3	-	-		0.98	-	-	-	-	-
4	-	-	-		-	-	-	-	-
5	0.98	-	-	-		-	-	-	-
6	-	-	-	-	0.87		-	0.92	-
7	-	-	-	-	-	0.84		0.73	-
8	-	-	-	-	-	-	-		0.57
9	-	-	-	-	0.92	-	-	-	

Tabela 5-9. Valores do CR calculados pelo método RNA

	1	2	3	4	5	6	7	8	9
1		0.99	-	-	-	-	-	-	-
2	-		0.59	-	-	0.97	-	-	-
3	-	-		1	-	-	-	-	-
4	-	-	-		-	-	-	-	-
5	1	-	-	-		-	-	-	-
6	-	-	-	-	0.89		-	1	-
7	-	-	-	-	-	0.88		0.72	-
8	-	-	-	-	-	-	-		0.65
9	-	-	-	-	0.85	-	-	-	

Após calcular os valores dos CRs para os três métodos apresentados anteriormente e do restante dos parâmetros do algoritmo BiNN, simulações foram realizadas para analisar as respostas com cada método.

5.4 Simulações

Da mesma forma que na simulação dos modelos de regressão, as simulações do cenário adotado como prova de conceito foram realizadas utilizando o software MATLAB e a ferramenta SUMO ("*Simulation of Urban Mobility*") (v 32.0) (BEHRISCH et al., 2011). O modelo BiNN foi programado no MATLAB (v R2016), enquanto o modelo do sistema de trânsito urbano foi programado em XML ("*eXtensible Markup Language*") utilizado no ambiente SUMO. Para realizar as simulações e a análise dos resultados foi utilizado o protocolo TraCI4Matlab desenvolvido por Acosta Gil (2014), que adota o paradigma cliente-servidor e permite a interação entre SUMO (servidor) e MATLAB (cliente). Todas as simulações têm um tempo de duração de 3600 segundos (uma hora).

O objetivo das simulações é analisar os resultados obtidos com cada método de cálculo do Coeficiente de Relação apresentado neste trabalho e selecionar qual desses métodos apresenta uma melhor resposta em termos de TMV e NOV (Nível de Ocupação das Vias). Outro objetivo é o de comparar o desempenho do algoritmo BiNN inicialmente apresentado por Castro et al. (2015) que não diferencia as relações entre as intersecções. Por último, é realizada a comparação com o Controle com Fases Prefixadas (CFP) atualmente utilizado para regular o tempo do semáforo no município de São Paulo.

No caso do algoritmo BiNN que não diferencia os *CRs*, os valores dos parâmetros w_{bp} e w_a foram adotados como 0.5, conforme apresentado na seção anterior. O intervalo de tempo dos semáforos vermelhos e verdes utilizados pelo CFP foi calculado com base nas informações obtidas em um estudo de campo¹ realizado para registrar as fases das interseções e medir o tempo de fase. Entretanto, essas medidas não podem ser conclusivas, pois segundo a Companhia de Engenharia de Tráfego de São Paulo (PREFEITURA DE SÃO PAULO, 2017), os tempos de ativação das fases podem variar em intervalos de 40 segundos. Portanto, os tempos dessas medidas foram complementados pelas informações obtidas em (GLOBO COMUNICAÇÃO E PARTICIPAÇÕES S.A, 2017).

A soma dos tempos de ativação das fases dos agentes de controle de trânsito é igual a 120 segundos. A fase principal destes agentes tem tempo de ativação entre 70 e 90 segundos dependendo da importância da via secundária. O tempo de ativação das fases secundárias também pode variar de 30 a 50 segundos. Na Tabela 5-10 são apresentadas as fases principais em cada interseção (marcadas em cinza) e os tempos de ativação de cada fase. Nas simulações não foram utilizadas as fases das luzes amarelas dos semáforos e nem as fases para pedestres a fim de simplificar a análise. Esse procedimento é adotado em todos os trabalhos relacionados com o controle de semáforos.

Tabela 5-10. Configuração das fases das interseções para o CFP

<i>Interseções</i>	<i>Fases das Interseções</i>	
	<i>Fase 1</i> <i>Fluxo de veículos</i> <i>Horizontal</i>	<i>Fase 2</i> <i>Fluxo de veículos</i> <i>Vertical</i>
1	80	40
2	80	40
3	90	30
4	50	70
5	80	40
6	70	50
7	70	50
8	70	50
9	35	85

¹ O estudo de campo foi realizado nos dias 04, 05 e 06/02/2019 (segunda-feira, terça-feira e quarta-feira respectivamente) nos horários compreendidos entre 7:30 e 9:30 horas para obter parâmetros em horários de pico (demanda intensa). Nesses dias também foram medidos os parâmetros sob demanda média de veículos em horários entre 10:00 e 12:00 horas. Por último, no domingo 10/02/2019 entre 07:00 e 12:00 horas foram realizadas as medições para obter os valores sob baixa demanda de veículos.

Para analisar o desempenho dos modelos foram realizados 15 tipos de simulações: 5 simulações com os diferentes algoritmos de controle (BiNN-P1V, BiNN-P2V, BiNN-RNA, BiNN, CFP) para os três tipos de demanda escolhidos (baixa, média e intensa). A Tabela 5-11 apresenta a descrição de cada tipo de simulação. A demanda de veículos é calculada como a quantidade de veículos que entram no cenário a cada segundo que é o mesmo procedimento usado por Lin, Xi e Yang (2008); Murcia, Hirakawa e Castro (2017) e Zhou et al. (2017). Os valores de demanda baixa, média e intensa escolhidos são os mesmos usados por Murcia, Hirakawa e Castro (2017).

Tabela 5-11 Descrição das simulações.

<i>Simulações</i>	<i>Algoritmo de Controle aplicado</i>	<i>Demanda veículos/segundo</i>	<i>Descrição</i>
1	BiNN-P1V	2.00	Demanda baixa
2	BiNN-P2V		
3	BiNN-RNA		
4	BiNN		
5	CFP		
6	BiNN-P1V	2.50	Demanda média
7	BiNN-P2V		
8	BiNN-RNA		
9	BiNN		
10	CFP	3.00	Demanda intensa
11	BiNN-P1V		
12	BiNN-P2V		
13	BiNN-RNA		
14	BiNN		
15	CFP		

A demanda de 2.00 veículos por segundo representa um fluxo baixo, enquanto a demanda de 3.00 veículos por segundo representa um trânsito intenso, selecionado a fim de analisar os resultados com as vias saturadas, e a demanda de 2.50 representa um cenário com trânsito médio. Todos os veículos utilizados têm as mesmas características, 5 metros de comprimento, com aceleração de 0.8 m/s^2 (metros por segundo ao quadrado). Além disso, o comportamento estocástico de direção (parâmetro do simulador SUMO) é igual a 0.5 em todos os testes e esse valor significa um valor médio (entre determinístico e estocástico) na conduta dos motoristas na condução. As rotas dos veículos foram programadas com as mesmas características das rotas de trânsito descritas e observadas em (GLOBO COMUNICAÇÃO E PARTICIPAÇÕES S.A, 2017), além das observadas e conferidas pelo autor na pesquisa de campo.

5.5 Avaliação dos indicadores de desempenho


Como apresentado anteriormente, os indicadores de desempenho utilizados para analisar as respostas obtidas nas simulações foram o TMV, utilizado nas análises feitas por Balaji e Srinivasan (2010); Gokulan e Srinivasan (2010); Krzysztof (2016) e Jin, Ma e Kosonen (2017), e o NOV no cenário, usado por Castro et al. (2015) e Diveev, Sofronova e Mikhalev (2016).

5.5.1 Tempo Médio de Viagem (TMV) dos veículos

Para o cálculo do TMV foi tomado, em cada tipo de simulação, a média de todos os veículos que entraram no cenário, desde que tivessem terminado de percorrer completamente

Na Figura 23 observa-se a resposta de cada método de controle sob uma demanda baixa de veículos. Pode-se observar que, como esperado, a pior resposta foi do algoritmo CFP, enquanto os outros quatro algoritmos têm respostas semelhantes. Embora as melhores respostas sejam as obtidas por BiNN-F2V e BiNN-ARN, com um valor quase igual. A melhor resposta, aquela que foi obtida pelo BiNN-ARN, representa uma melhoria de 16.8% com respeito ao CFP. Em relação ao BiNN, o BiNN-ARN apresentou uma melhora de 3.3%, embora o BiNN tenha apresentado uma resposta ligeiramente superior em relação ao BiNN-F2V (2.9%) que também é parte da proposta.


Figura 23 - Tempo Médio de Viagem sob demanda baixa de veículos.



Fonte: Autor

A Figura 24 apresenta a resposta do parâmetro de avaliação TMV sob uma demanda média de veículos. A ideia da escolha dessa demanda é aumentar o fluxo de veículos, mas sem saturar totalmente a via. Sob estas condições, como esperado, a pior resposta continua sendo o método CFP, pois ele não age em dependência da quantidade de veículos em cada via das intersecções. Neste caso a melhor resposta foi obtida pelo BiNN-RNA, com uma melhoria de 30.77 segundos com relação à pior resposta (CFP), que representa o 18.6%. Em relação ao algoritmo que não diferencia as relações entre intersecções (BiNN), o BiNN-RNA apresenta uma melhora de um 5.3% que significa um ligeiro aumento em relação à demanda baixa. Com respeito às outras respostas, o BiNN-P2V tem uma resposta bem semelhante ao BiNN-RNA, da mesma forma que na demanda baixa. O BiNN-P1V apresentou uma resposta semelhante ao BiNN, embora fosse ligeiramente superior. Em geral, o aumento da porcentagem de melhoria dos algoritmos que diferenciam as relações entre as intersecções vizinhas explica-se com o aumento da demanda de veículos, nessas condições esses algoritmos otimizam os tempos de ativação da fase dos semáforos, em dependência não apenas da quantidade de veículos que esperam nas vias adjacentes, senão também dependem do tempo que demora o fluxo de veículos para chegar em intersecções vizinhas. Portanto, aumenta muito a chance de uma melhoria no TMV.

Figura 24 - Tempo Médio de Viagem sob demanda média de veículos




Fonte: Autor

O objetivo de analisar as respostas dos algoritmos sob demandas intensas é o de observar como é a resposta em condições de saturação das vias nas condições encontradas nos horários de pico nessa região de São Paulo. A Figura 25 apresenta a resposta de cada método sob uma demanda intensa de veículos. Como aconteceu com as outras duas demandas, o CFP apresentou também a pior resposta com uma diferença de 32.95 segundos com relação ao BiNN-RNA, mas neste caso representando uma melhora de 13.2%. Essa diminuição da porcentagem de melhoria com relação à demanda média pode ser justificada com a saturação das vias e esse fato provoca que, para qualquer fase ativa, sempre existe circulação de veículos nessa via no tempo total da ativação. Portanto, os algoritmos BiNNs apenas dão prioridade às fases principais na intersecção, mediante a propriedade de plasticidade sináptica, e eles não conseguem otimizar o tempo de ativação da fase em dependência da inibição ou a criação de ondas de luzes verdes, pois todas as vias encontram-se totalmente lotadas. Mediante a plasticidade sináptica, o algoritmo BiNN consegue diminuir o tempo médio de viagem total, mas nas condições de saturação das vias é impossível melhorar os parâmetros de desempenho de forma significativa.

Em relação ao BiNN, o BiNN-RNA apresentou uma melhora de 10.6%. Este comportamento pode ser explicado com a característica da diferenciação de relações entre intersecções vizinhas que o BiNN-RNA possui e que consegue criar ondas de luzes verdes e inibição de fases em dependência das características físicas do cenário e, portanto, otimiza o tempo ativação de cada fase. As respostas do BiNN-P2V e o BiNN-P1V são bem semelhantes e próximas ao BiNN-RNA.

Figura 25 - Tempo Médio de Viagem sob demanda intensa de veículos




Fonte: Autor

5.5.2 Nível de Ocupação das Vias (NOV)

Um segundo parâmetro escolhido para a análise dos resultados foi o NOV. Nas Figuras 26, 28 e 30, observam-se o desempenho do método de controle para este parâmetro. Além disso, nas Figuras 27, 29 e 31 exibem-se os valores médios deste parâmetro (NMOV) para cada demanda de trânsito.


No caso da demanda baixa de trânsito (Figura 26), o NOV tende a estabilizar para todos os métodos de controle num valor próximo à 500 veículos. O CFP apresenta uma maior resposta até o segundo 2500 da simulação, prejudicando o valor médio do parâmetro, sendo a maior ocupação média obtida para a demanda baixa como pode se observar na Figura 27. Os restantes métodos apresentam uma resposta semelhante, mas o BiNN-RNA e o BiNN-P2V obtiveram os melhores resultados quando analisados pelo valor médio do parâmetro (NMOV), enquanto o BiNN e o BiNN-P1V obtiveram resultados ligeiramente inferiores quando comparados com o BiNN-RNA e o BiNN-P2V. Em relação ao NMOV, a diferença entre a melhor (BiNN-RNA) e a pior resposta (CFP) é de 69.1 veículos, o que representa 17.4%, por outra parte quando comparado com o BiNN, o BiNN-RNA apresenta uma melhora de 2.8%. Em geral, o comportamento dos 5 métodos foi bem parecido quando comparados os parâmetros TMV e NMOV para a demanda baixa de veículos.

Figura 26 - Nível de Ocupação das Vias sob demanda baixa de veículos



Fonte: Autor

Figura 27 - Nível de Médio de Ocupação das Vias sob demanda baixa de veículos




Fonte: Autor

Nas Figuras 28 e 29 podem ser observadas as respostas dos métodos em relação ao NOV e ao NMOV sob demanda média de veículos. As respostas para os 5 métodos também apresentam um comportamento semelhante quando comparado com a demanda baixa de veículos, porém os valores médios de ocupação da via aumentaram. A pior resposta continuou sendo o CFP, enquanto a melhor foi o BiNN-RNA (mesmo acontecido com o TMV sob demanda média) e a diferença entre estes dois métodos é de 21.5%, apresentando um aumento com relação à demanda baixa. O BiNN-RNA

apresentou uma resposta ligeiramente melhor quando comparado com o BiNN-P2V, comportamento semelhante com o TMV na demanda média. Em relação ao BiNN, o BiNN-RNA (melhor resposta) obteve uma melhora de 7.2% e a diferença dos valores médios entre o BiNN e o BiNN-P1V também mostrou um ligeiro aumento.

O aumento percentual de melhora entre os métodos que diferenciam as relações entre as intersecções (BiNN-P2V, BiNN-P1V e BiNN-RNA) e o método sem diferenciar essas relações (BiNN), pode ser justificado no comportamento seguinte: quando o nível de ocupação das vias aumenta, a otimização dos tempos de ativação de cada fase possui uma maior influência na resposta do controle, portanto, os métodos que diferenciam as características físicas do cenário para a criação de ondas verdes e a inibição de fases, melhoram a resposta em relação aos métodos que tem relações iguais entre as intersecções.

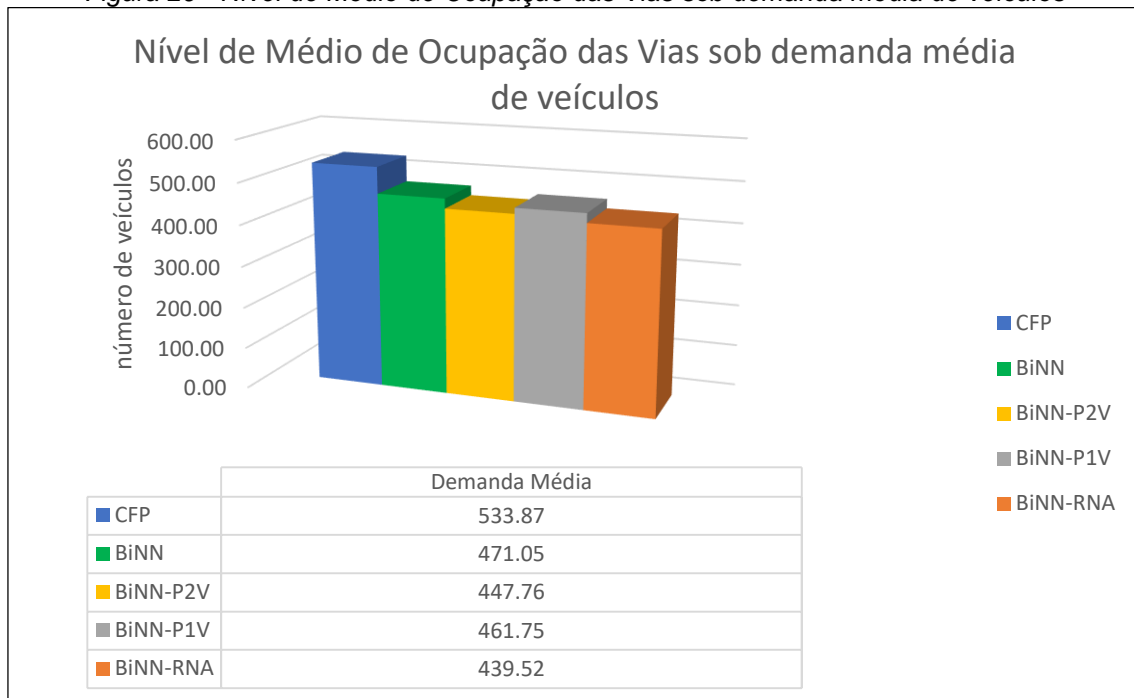
Figura 28 - Nível de Ocupação das Vias sob demanda média de veículos



Fonte: Autor

Analisando as respostas do parâmetro NOV sob demanda intensa trânsito (Figura 30), pode se concluir que o objetivo de saturar as vias para analisar o comportamento do controle proposto foi atingido. Observa-se que a resposta dos 5 métodos propostos não apresenta nenhum valor de estabilização, portanto, os valores médios do NOV também exibiram um aumento significativo, como é possível observar na Figura 31.

Figura 29 - Nível de Médio de Ocupação das Vias sob demanda média de veículos

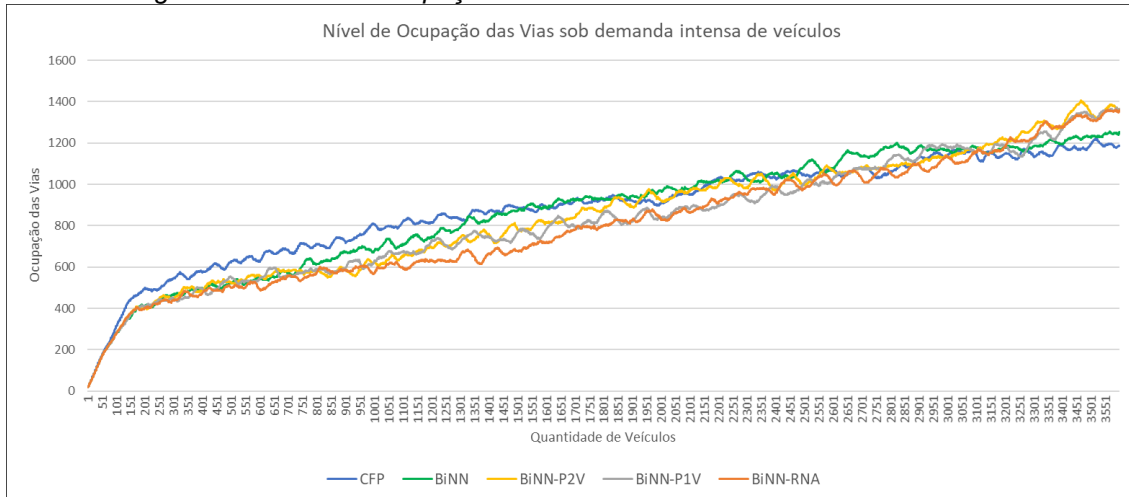


Fonte: Autor

Como observado em todas as análises anteriores, a pior resposta foi obtida pelo CFP com diferença com relação à melhor resposta (BiNN-RNA) reduzida até 9.6% por causa das condições de saturação explicadas anteriormente. O método BiNN apresentou uma resposta semelhante ao CFP e a diferença com o BiNN-RNA aumentou ligeiramente com relação à demanda média (8.2%). Os métodos BiNN-P1V e BiNN-P2V mostraram comportamentos semelhantes, o primeiro com 2.5% de melhoria, e em comparação com a melhor resposta (BiNN-RNA), uma diferença apenas de 2.6%.


Em geral as diferenças entre as respostas dos 5 métodos diminuem quando se analisa o comportamento do parâmetro de avaliação NOV sob demanda intensa de veículos, comportamento este bem semelhante ao do parâmetro TMV sob a mesma demanda, devido à saturação das vias.

Figura 30 - Nível de Ocupação das Vias sob demanda intensa de veículos



Fonte: Autor

Figura 31 - Nível de Médio de Ocupação das Vias sob demanda intensa de veículos



Fonte: Autor

5.6 Considerações sobre os resultados

O objetivo das simulações foi estimar o impacto real no trânsito provocado pelo controle BiNN que inclui as características físicas do cenário para visar diferenciar as relações entre intersecções vizinhas, possibilitando simulações em cenários com características semelhantes às encontradas no cenário real, além de determinar a seleção do melhor método para o cálculo do valor de CR. Também foram comparados três métodos propostos neste trabalho para o cálculo do CR (BiNN-P1V, BiNN-P2V e BiNN-ARN) com o modelo BiNN sem

diferenciar relações (método proposto em Castro et al. (2015)) e o método usado atualmente na maioria dos agentes que controlam as intersecções da cidade (CFP).

Para uma demanda baixa, os parâmetros de avaliação (TMV e NOV) escolhidos para os métodos: BiNN-RNA e BiNN-P2V apresentaram os melhores resultados, enquanto o pior resultado foi obtido para o método CFP. Sob demanda média de trânsito, o BiNN-RNA apresentou os melhores resultados e às duas piores respostas foram CFP e BiNN. Por último, na demanda intensa, o BiNN-RNA exibiu novamente a melhor resposta, enquanto os piores resultados continuaram sendo o CFP e o BiNN. Em geral, pode-se concluir que os métodos que diferenciam as relações entre intersecções (BiNN-RNA, BiNN-P2V e BiNN-P1V) apresentaram quando comparados com o modelo BiNN sem diferenciar relações entre intersecções

Com essa análise é possível concluir que o melhor método para calcular o coeficiente de relação entre duas intersecções é o método RNA, pois nas demandas: baixa exibiu resultados muito similares com a melhor resposta (BiNN-P2V), e nas demandas média e intensa apresentou o melhor resultado. Este resultado corrobora o resultado obtido anteriormente, no cálculo do erro médio das funções de regressão, no qual o método baseado em Redes Neurais Artificiais exibiu o melhor resultado.

Com relação às porcentagens de melhoria, no caso da demanda baixa e atendendo aos dois parâmetros de avaliação utilizados, o BiNN-RNA apresentou uma melhoria de 16.5% quando comparado com o CFP, e quando comparado com BiNN o valor foi de apenas 1.9%. Com relação à demanda média, a melhoria entre o BiNN-RNA e o CFP representa 20%, e com relação ao BiNN, representa 6.3%. Por último, na demanda intensa de veículos, com relação ao CFP a melhoria foi de 14.1% e quando comparado com o BiNN o valor representou 9.4%.

Portanto, depois de analisar os resultados obtidos nestas simulações pode-se concluir que o método BiNN-RNA apresentou os melhores resultados quando se analisam as três demandas e os dois indicadores de desempenho. De forma geral também pode-se concluir que os métodos com diferenciação de

relações entre intersecções apresentaram melhores resultados quando comparado com o modelo inicial BiNN apresentado por Castro et al. (2015).

6 Conclusões

Este trabalho propôs uma melhoria do modelo de controle de intersecções anteriormente apresentado no grupo de pesquisa. A finalidade foi aperfeiçoar o modelo, adicionando características físicas reais dos cenários, para diferenciar as relações existentes entre intersecções vizinhas. O modelo baseia-se em Redes Neurais Bio-Inspiradas e apresenta um controle distribuído, no qual cada intersecção é controlada por um agente de controle que interage com os outros agentes de controle de intersecções vizinhas, enviando e recebendo informações para produzir tanto ondas de luzes verdes quanto inibições de fases.

Para adicionar as características do cenário na configuração do modelo foi selecionado um coeficiente de relação (CR), o qual possui um valor entre 0 e 1 e descreve o nível de influência de uma intersecção em uma outra intersecção. Quanto maior for o valor do coeficiente significa que o nível de influência de uma intersecção na outra é alto e, portanto, o fluxo de veículo demora pouco tempo para chegar. O CR foi utilizado para calcular os valores das sinapses w_a e w_b no modelo de Coordenação de Intersecções, que são utilizadas tanto na criação de ondas de luzes verdes quanto na inibição de fases de intersecções.

Com base na metodologia, propôs-se realizar um cálculo inicial off-line para configurar os CR s e posteriormente calcular as sinapses para configurar o Modelo de Coordenação para cada relação entre intersecções. Com o objetivo de encontrar a função que melhor descrevesse a relação entre os três parâmetros selecionados (comprimento da via comum entre as intersecções (d), velocidade máxima da via comum (v_{max}) e número de faixas da via comum (n_f)) e o CR , realizou-se uma análise de regressão com três métodos diferentes: Função Polinomial com uma Variável, Função Polinomial com duas Variáveis e Redes Neurais Artificiais. Os resultados preliminares mostraram que a regressão com RNA apresentou o menor erro médio quando comparado com os resultados obtidos na fase de coleta de dados em 60 cenários com configurações diferentes.

Posteriormente, com o objetivo de selecionar qual dos três métodos utilizados para o cálculo do CR apresenta os melhores resultados, além de comparar com o modelo BiNN anterior e com o método CFP (método de controle atual utilizado na maioria das intersecções da cidade) e estimar o impacto real que pode ter a aplicação do modelo proposto em um cenário real, os métodos foram validados em um cenário simulado baseado em um cenário real da cidade de São Paulo.

Dois parâmetros foram utilizados para avaliar os resultados obtidos na simulação: TMV e NOV. Com relação ao primeiro parâmetro, em média, o método BiNN-RNA obteve uma melhoria em média de 15.99% quando comparado com o CFP e 5.85% quando comparado com o método anterior proposto no grupo de pesquisa, o qual é a base da proposta (BiNN). Com relação ao segundo parâmetro, o NOV, os resultados foram quase idênticos e, em média, a melhoria com relação ao CFP foi de 15.97% e com relação ao BiNN foi exatamente igual (5.85%). Estes valores corroboram os resultados anteriores obtidos na proposta dos três métodos de regressão, no qual o método baseado em Redes Neurais Artificiais obteve o melhor erro médio de regressão.

Portanto pode-se concluir que o método proposto, para diferenciar as relações entre as intersecções, melhora ainda mais os resultados quando comparado com o modelo BiNN anteriormente proposto. Por conseguinte, também é superior ao controle atual usado na maioria das intersecções da cidade.

Com os resultados obtidos podemos concluir que o modelo de controle BiNN-RNA, proposta baseada em controle distribuído de intersecções diferenciando as relações entre elas, permite uma redução do NOV, provocando uma melhor circulação de veículos e um aumento no número de veículos que podem utilizar as vias.

Um possível trabalho futuro de pesquisa relacionado às relações entre as intersecções pode ser a utilização do método de aprendizado por reforço para o cálculo dos coeficientes de relação para otimizar o cálculo do parâmetro CR, sendo possível o cálculo do CR ser atualizado de forma on-line. Outra direção

de pesquisa futura poderia ser a aplicação do método proposto em hardware para o controle do sistema de trânsito urbano para avaliar o controle do sistema real.

Referências

- ALVES JR, D. R. **Congestionamento e lentidão no trânsito: repercussão na saúde e no comportamento**. Disponível em: <<http://www.transportabrasil.com.br/2012/11/congestionamento-e-lentidao-no-transito-repercussao-na-saude-e-no-comportamento/>>. Acesso em: 18 abr. 2018.
- ARAGHI, S. et al. Intelligent Traffic Light Control of Isolated Intersections Using Machine Learning Methods. In: 2013 IEEE International Conference on Systems, Man, and Cybernetics, **Anais...IEEE**, out. 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6722370/>>. Acesso em: 7 dez. 2017.
- ARAGHI, S.; KHOSRAVI, A.; CREIGHTON, D. A review on computational intelligence methods for controlling traffic signal timing. **Expert Systems with Applications**, v. 42, n. 3, p. 1538–1550, 15 fev. 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417414005429>>. Acesso em: 7 dez. 2017.
- ARROUB, A. et al. A literature review on Smart Cities: Paradigms, opportunities and open problems. **2016 International Conference on Wireless Networks and Mobile Communications (WINCOM)**, p. 180–186, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7777211/>>.
- BALAJI, P. G.; SRINIVASAN, D. Multi-Agent System in Urban Traffic Signal Control. **IEEE Computational Intelligence Magazine**, nov. 2010. Disponível em: <<http://ieeexplore.ieee.org/document/5605615/>>. Acesso em: 6 dez. 2017.
- BATTISTA, G.; VOLLARO, R. de L. Correlation between air pollution and weather data in urban areas: Assessment of the city of Rome (Italy) as spatially and temporally independent regarding pollutants. **Atmospheric Environment**, v. 165, p. 240–247, set. 2017. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1352231017304399>>. Acesso em: 26 abr. 2018.
- BEDE, B. Mathematics of Fuzzy Sets and Fuzzy Logic. In: [s.l.: s.n.]
- BELLMAN, R. **Dynamic Programming**. New Jersey: Princeton University Press, 1957.
- BRESCIANI FILHO, E. Considerações sobre Sistemas Dinâmicos Complexos. In: Seminários sobre Auto-Organização, do CLE - Centro de Lógica, Epistemologia e História da Ciência, da UNICAMP, Campinas, São Paulo. **Anais...** Campinas, São Paulo: 2013. Disponível em: <<http://www.cle.unicamp.br/index.php/sites/default/files/19042013-BrescianiEttore.pdf>>. Acesso em: 3 maio. 2018.
- CAI, C.; WONG, C. K.; HEYDECKER, B. G. Adaptive traffic signal control using approximate dynamic programming. **Transportation Research Part C: Emerging Technologies**, v. 17, n. 5, p. 456–474, 1 out. 2009. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0968090X09000321>>. Acesso em: 5 jun. 2018.
- CAMACHO, E. F.; BORDONS, C. **Model predictive control**. [s.l.] Springer, 1999.
- CAO, W. et al. A review on neural networks with random weights. **Neurocomputing**, v. 275, p. 278–287, 31 jan. 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0925231217314613>>. Acesso em: 3 jun. 2018.
- CARREIRO, R. **FISCOBRAS 2013. OBRAS DE IMPLANTAÇÃO DO TRECHO NORTE DO RODOANEL MÁRIO COVAS - LOTE 4**. [s.l.: s.n.].
- CASTRO, G. B. et al. Biologically-Inspired Neural Network for Coordinated Urban Traffic

Control: Parameter Determination and Stability Analysis. In: 2015 International Conference on Computational Science and Computational Intelligence (CSCI), **Anais...IEEE**, dez. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7424092/>>. Acesso em: 6 dez. 2017.

CASTRO, G. B.; HIRAKAWA, A. R.; MARTINI, J. S. C. Adaptive traffic signal control based on bio-neural network. **Procedia Computer Science**, v. 109, p. 1182–1187, 2017. Disponível em: <www.elsevier.com/locate/procedia>. Acesso em: 9 out. 2017.

CASTRO, G. B.; MARTINI, J. S. C.; HIRAKAWA, A. R. Biologically-Inspired Neural Network for Traffic Signal Control. In: IEEE 17th International Conference on Intelligent Transportation Systems (ITSC), **Anais...2014**.

CHIANG, C. L. **Statistical Methods of Analysis**. [s.l.] WORLD SCIENTIFIC, 2003.

CHOY, M. C.; SRINIVASAN, D.; CHEU, R. L. Neural Networks for Continuous Online Learning and Control. **IEEE Transactions on Neural Networks**, v. 17, n. 6, p. 1511–1531, nov. 2006. Disponível em: <<http://ieeexplore.ieee.org/document/4012019/>>. Acesso em: 7 jun. 2018.

CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics of Control, Signals, and Systems**, v. 2, n. 4, p. 303–314, dez. 1989. Disponível em: <<http://link.springer.com/10.1007/BF02551274>>. Acesso em: 3 jun. 2018.

DAI, Y.; ZHAO, D.; YI, J. A comparative study of urban traffic signal control with reinforcement learning and Adaptive Dynamic Programming. In: The 2010 International Joint Conference on Neural Networks (IJCNN), **Anais...IEEE**, jul. 2010. Disponível em: <<http://ieeexplore.ieee.org/document/5596480/>>. Acesso em: 31 maio. 2018.

DAKIC, I.; STEVANOVIC, J.; STEVANOVIC, A. Backpressure Traffic Control Algorithms in Field-like Signal Operations. In: 2015 IEEE 18th International Conference on Intelligent Transportation Systems, **Anais...IEEE**, set. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7313123/>>. Acesso em: 31 maio. 2018.

DE ABREU BATISTA, A.; COUTINHO, L. R. A multiagent system for combining green wave and adaptive control in a dynamic way. In: 16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013), **Anais...IEEE**, out. 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6728592/>>. Acesso em: 30 maio. 2018.

DE OLIVEIRA, M. B. W.; NETO, A. de A. Optimization of Traffic Lights Timing based on Artificial Neural. **IEEE 17th International Conference on Intelligent Transportation Systems (ITSC)**, p. 1921–1922, 2014.

DEB, K. et al. A fast and elitist multiobjective genetic algorithm: NSGA-II. **IEEE Transactions on Evolutionary Computation**, v. 6, n. 2, p. 182–197, abr. 2002. Disponível em: <<http://ieeexplore.ieee.org/document/996017/>>. Acesso em: 2 jun. 2018.

DESAI, N. S. Homeostatic plasticity in the CNS: synaptic and intrinsic forms. **Journal of Physiology-Paris**, v. 97, n. 4–6, p. 391–402, 1 jul. 2003. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0928425704000166>>. Acesso em: 8 jun. 2018.

DIVEEV, A.; SOFRONOVA, E.; MIKHALEV, V. Model Predictive Control for Urban Traffic Flows. **IEEE International Conference on Systems, Man, and Cybernetics**, p. 3051–3056, 2016.

DUSPARIC, I.; MONTEIL, J.; CAHILL, V. Towards autonomic urban traffic control with collaborative multi-policy reinforcement learning. **IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC**, p. 2065–2070, nov. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7795890/>>. Acesso em: 7 dez. 2017.

EL-TANTAWY, S.; ABDULHAI, B.; ABDELGAWAD, H. Multiagent Reinforcement Learning for

Integrated Network of Adaptive Traffic Signal Controllers (MARLIN-ATSC): Methodology and Large-Scale Application on Downtown Toronto. **IEEE Transactions on Intelligent Transportation Systems**, v. 14, n. 3, p. 1140–1150, set. 2013. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6502719>>. Acesso em: 6 dez. 2017.

EL MOUDNI, A.; YIN, B.; DRIDI, M. Forward search algorithm based on dynamic programming for real-time adaptive traffic signal control. **IET Intelligent Transport Systems**, v. 9, n. 7, p. 754–764, 1 set. 2015. Disponível em: <<http://digital-library.theiet.org/content/journals/10.1049/iet-its.2014.0156>>. Acesso em: 5 jun. 2018.

ELGAREJ, M.; KHALIFA, M.; YOUSSEFI, M. Traffic Lights Optimization with Distributed Ant Colony Optimization Based on Multi-agent System. **Springer International Publishing AG**, p. 266–279, 2016.

FANG, Y. L.; SHI, Z. K.; CAO, J. L. Congestion phenomenon analysis and delayed-feedback control in a modified coupled map traffic flow model containing the velocity difference. **Communications in Nonlinear Science and Numerical Simulation**, v. 23, n. 1–3, p. 175–184, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.cnsns.2014.11.007>>.

FEOFILOFF, P. **Programação dinâmica**. Disponível em: <https://www.ime.usp.br/~pf/analise_de_algoritmos/aulas/dynamic-programming.html>. Acesso em: 31 maio. 2018.

FREEDMAN, D. **Statistical models : theory and practice**. [s.l.] Cambridge University Press, 2009.

GARTNER, N. H. et al. A multi-band approach to arterial traffic signal optimization. **Transportation Research Part B: Methodological**, v. 25, n. 1, p. 55–74, 1 fev. 1991. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0191261591900139>>. Acesso em: 5 jun. 2018.

GLOBO COMUNICAÇÃO E PARTICIPAÇÕES S.A. **Radar do trânsito em tempo real de São Paulo**. Disponível em: <<http://g1.globo.com/sao-paulo/transito/radar-tempo-transito-agora.html>>.

GOKULAN, B. P.; SRINIVASAN, D. Distributed Geometric Fuzzy Multiagent Urban Traffic Signal Control. **IEEE Transactions on Intelligent Transportation Systems**, v. 11, n. 3, p. 714–727, set. 2010. Disponível em: <<http://ieeexplore.ieee.org/document/5483228/>>. Acesso em: 6 dez. 2017.

GOKULAN, B. P.; SRINIVASAN, D. Modified Symbiotic Evolutionary Learning for Type-2 Fuzzy System. **IEEE Systems Journal**, v. 8, n. 2, p. 353–362, jun. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6471733/>>. Acesso em: 19 fev. 2018.

GREGOIRE, J. et al. Capacity-Aware Backpressure Traffic Signal Control. **IEEE Transactions on Control of Network Systems**, v. 2, n. 2, p. 164–173, jun. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/6979216/>>. Acesso em: 6 jun. 2018.

HAJIAHMADI, M. et al. Integrated Predictive Control of Freeway Networks Using the Extended Link Transmission Model. **IEEE Transactions on Intelligent Transportation Systems**, v. 17, n. 1, p. 65–78, jan. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7217816/>>. Acesso em: 6 jun. 2018.

HAMILTON, A. et al. Performance Evaluation of Stage Skipping and New Data Sources Compared Against MOVA Control. **17th International Conference on Intelligent Transportation Systems (ITSC), Qingdao, China**, p. 2535–2540, 2014. Disponível em: <<http://ieeexplore.ieee.org.ez67.periodicos.capes.gov.br/stamp/stamp.jsp?arnumber=6958096>>. Acesso em: 10 out. 2017.

HERNAFI, Y.; AHMED, M. Ben; BOUHORMA, M. An Approaches ' based on Intelligent Transportation Systems to Dissect Driver Behavior and Smart Mobility in Smart City. p. 886–895, 2016.

HEYDECKER, B.; CAI, C.; WONG, C. Adaptive Dynamic Control for Road Traffic Signals. In: 2007 IEEE International Conference on Networking, Sensing and Control, **Anais...IEEE**, 2007. Disponível em: <<http://ieeexplore.ieee.org/document/4238988/>>. Acesso em: 31 maio. 2018.

HOWARD, R. A. **Dynamic programming and Markov processes**. [s.l.] M.I.T. Press, 1960.

HUANG, M.-L. Intersection traffic flow forecasting based on v-GSVR with a new hybrid evolutionary algorithm. **Neurocomputing**, v. 147, p. 343–349, 5 jan. 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0925231214008261>>. Acesso em: 7 jun. 2018.

HUNT, P. B.; ROBERTSON, D. I.; BRETHERTON, R. D. The SCOOT on-line traffic signal optimisation technique. **Traffic Engineering & Control**, v. 23, n. 4, p. 190–192, 1982. Disponível em: <<https://www.scopus.com/record/display.uri?eid=2-s2.0-0019899060&origin=resultslist&sort=plf-f&src=s&st1=The+SCOOT+on-line+traffic+signal+optimisation+technique&st2=&sid=5187bfc49d4bb74e2d19285c939308b6&sot=b&sdt=b&sl=70&s=TITLE-ABS-KEY%28The+SCOOT+on-line>>. Acesso em: 5 jun. 2018.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Estimativa da População Residente no Brasil e unidades da Federação**. [s.l.: s.n.].

JAMSHIDNEJAD, A. et al. Gradient-based model-predictive control for green urban mobility in traffic networks. In: 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC), **Anais...IEEE**, nov. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7795690/>>. Acesso em: 31 maio. 2018.

JAMSHIDNEJAD, A.; DE SCHUTTER, B.; MAHJOOB, M. J. Urban traffic control using a fuzzy multi-agent system. In: 2015 European Control Conference (ECC), **Anais...IEEE**, jul. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7331000/>>. Acesso em: 7 jun. 2018.

JAYASOORIYA, S. A. C. S.; BANDARA, Y. M. M. S. Measuring the Economic costs of traffic congestion. In: 2017 Moratuwa Engineering Research Conference (MERCon), **Anais...IEEE**, maio 2017. Disponível em: <<http://ieeexplore.ieee.org/document/7980471/>>. Acesso em: 19 abr. 2018.

JIANG, L. et al. Traffic signal light control model based on evolutionary programming algorithm optimization BP neural network. In: 2017 7th IEEE International Conference on Electronics Information and Emergency Communication (ICEIEC), **Anais...IEEE**, jul. 2017. Disponível em: <<http://ieeexplore.ieee.org/document/8076629/>>. Acesso em: 8 jun. 2018.

JIN, J.; MA, X. Adaptive Group-Based Signal Control Using Reinforcement Learning with Eligibility Traces. In: 2015 IEEE 18th International Conference on Intelligent Transportation Systems, **Anais...IEEE**, set. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7313481/>>. Acesso em: 7 dez. 2017.

JIN, J.; MA, X. Hierarchical multi-agent control of traffic lights based on collective learning. **Engineering Applications of Artificial Intelligence**, nov. 2017. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0952197617302658>>. Acesso em: 11 dez. 2017.

JING, P.; HUANG, H.; CHEN, L. An Adaptive Traffic Signal Control in a Connected Vehicle Environment: A Systematic Review. **Information**, v. 8, n. 3, p. 101, 24 ago. 2017. Disponível em: <<http://www.mdpi.com/2078-2489/8/3/101>>. Acesso em: 16 maio. 2018.

KAUR, T.; AGRAWAL, S. Adaptive Traffic Lights Based On Hybrid of Neural Network and Genetic Algorithm for Reduced Traffic Congestion. **Engineering and Computational Sciences (RAECS), 2014 Recent Advances in**, p. 266–279, 2014.

- KEONG, C. K. The GLIDE system—Singapore's urban traffic control system. **Transport Reviews**, v. 13, n. 4, p. 295–305, out. 1993. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/01441649308716854>>. Acesso em: 7 jun. 2018.
- KHAMIS, M. A.; GOMAA, W.; EL-SHISHINY, H. Multi-objective traffic light control system based on Bayesian probability interpretation. In: 2012 15th International IEEE Conference on Intelligent Transportation Systems, **Anais...IEEE**, set. 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6338853/>>. Acesso em: 7 dez. 2017.
- KUMAR, P. et al. Multilevel Modeling of the Traffic Dynamic. **IEEE Transactions on Intelligent Transportation Systems**, v. 15, n. 3, p. 1066–1082, jun. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6701151/>>. Acesso em: 28 maio. 2018.
- LAMOTTE, O. et al. Submicroscopic and Physics Simulation of Autonomous and Intelligent Vehicles in Virtual Reality. In: 2010 Second International Conference on Advances in System Simulation, **Anais...IEEE**, ago. 2010. Disponível em: <<http://ieeexplore.ieee.org/document/5601901/>>. Acesso em: 28 maio. 2018.
- LI, J.-Q. Discretization modeling, integer programming formulations and dynamic programming algorithms for robust traffic signal timing. **Transportation Research Part C: Emerging Technologies**, v. 19, n. 4, p. 708–719, 1 ago. 2011. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0968090X10001725>>. Acesso em: 5 jun. 2018.
- LIN, S.; XI, Y.; YANG, Y. Short-Term Traffic Flow Forecasting Using Macroscopic Urban Traffic Network Model. In: 2008 11th International IEEE Conference on Intelligent Transportation Systems, **Anais...IEEE**, out. 2008. Disponível em: <<http://ieeexplore.ieee.org/document/4732567/>>. Acesso em: 30 maio. 2018.
- LITTLE, J. D. C. The Synchronization of Traffic Signals by Mixed-Integer Linear Programming. **Operations Research**, v. 14, p. 568–594, 1966. Disponível em: <<https://www.jstor.org/stable/168720>>. Acesso em: 5 jun. 2018.
- LIU, Y. et al. Direct emission of nitrous acid (HONO) from gasoline cars in China determined by vehicle chassis dynamometer experiments. **Atmospheric Environment**, v. 169, p. 89–96, nov. 2017. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1352231017304600>>. Acesso em: 26 abr. 2018.
- MAMDANI, E. H. Application of fuzzy algorithms for control of simple dynamic plant. **Proceedings of the Institution of Electrical Engineers**, v. 121, n. 12, p. 1585, 1974. Disponível em: <<http://digital-library.theiet.org/content/journals/10.1049/piee.1974.0328>>. Acesso em: 2 jun. 2018.
- MAO, Z.-H.; MASSAQUOI, S. G. Dynamics of Winner-Take-All Competition in Recurrent Neural Networks With Lateral Inhibition. **IEEE Transactions on Neural Networks**, v. 18, n. 1, p. 55–69, jan. 2007. Disponível em: <<http://ieeexplore.ieee.org/document/4049830/>>. Acesso em: 8 maio. 2018.
- MCKENNEY, D.; WHITE, T. Distributed and adaptive traffic signal control within a realistic traffic simulation. **Engineering Applications of Artificial Intelligence**, v. 26, n. 1, p. 574–583, 1 jan. 2013. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0952197612000966>>. Acesso em: 7 dez. 2017.
- MEYER-BASE, A.; THUMMLER, V. Local and Global Stability Analysis of an Unsupervised Competitive Neural Network. **IEEE Transactions on Neural Networks**, v. 19, n. 2, p. 346–351, fev. 2008. Disponível em: <<http://ieeexplore.ieee.org/document/4435134/>>. Acesso em: 5 fev. 2018.
- MITCHELL, T. M. **Machine Learning**. [s.l.] McGraw-Hill Science/Engineering/Math, 1997.

MURCIA, N. et al. Bio-Inspired Neural Network Model Applied to Urban Traffic Control in a Real Scenario. (H. R. Arabnia et al., Eds.) In: 4th Annual Conf. on Computational Science & Computational Intelligence, **Anais...IEEE Computer Society**, dez. 2017. Disponível em: <<https://ieeexplore.ieee.org/document/8560806/>>. Acesso em: 30 jan. 2019.

MURCIA, N.; HIRAKAWA, A. R.; CASTRO, G. B. Bio-inspired Neural Network Model Applied to Urban Traffic. In: 2017 International Conference on Computational Science and Computational Intelligence (CSCI), **Anais...IEEE**, dez. 2017. Disponível em: <<https://ieeexplore.ieee.org/document/8560806/>>. Acesso em: 30 jan. 2019.

NI, D. **Traffic flow theory : characteristics, experimental methods, and numerical techniques**. Massachusetts : Elsevier Inc., 2016.

NICHOLS, E.; MCDAID, L. J.; SIDDIQUE, N. Biologically Inspired SNN for Robot Control. **IEEE Transactions on Cybernetics**, v. 43, n. 1, p. 115–128, fev. 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6220278/>>. Acesso em: 18 maio. 2018.

PACHECO, J. C.; ROSSETTI, R. J. F. Agent-Based Traffic Control: a Fuzzy Q-Learning Approach. In: 13th International IEEE Conference on Intelligent Transportation Systems, **Anais...IEEE**, set. 2010. Disponível em: <<http://ieeexplore.ieee.org/document/5624984/>>. Acesso em: 7 dez. 2017.

PEIRCE, J. R.; WEBB, P. J. MOVA control of isolated traffic signals-recent experience. **Road Traffic Control, 1990., Third International Conference on**, p. 110–113, 1990.

PELÁEZ, J. R.; ANDINA, D. Do biological synapses perform probabilistic computations? **Neurocomputing**, v. 114, p. 24–31, 2013.

PENG, G.; LIU, C.; TUO, M. Influence of the traffic interruption probability on traffic stability in lattice model for two-lane freeway. **Physica A: Statistical Mechanics and its Applications**, v. 436, p. 952–959, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.physa.2015.05.055>>.

PETERSON, A.; BERGH, T.; STEEN, K. LHOVRA, a new traffic signal control strategy for isolated junctions. 1986.

POOLE, D.; MACKWORTH, A. Q-learning. In: **Artificial Intelligence: foundations of computational agents**. Vancouver, Canada: Cambridge University Press, 2010.

PREFEITURA DE SÃO PAULO. **Companhia de Engenharia de Tráfego de São Paulo**. Disponível em: <<http://www.cetsp.com.br/>>. Acesso em: 2 mar. 2018.

PRIKRYL, J. Simple model for urban traffic between two signalized intersections. In: 16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013), **Itsc, Anais...IEEE**, out. 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6728208/>>. Acesso em: 2 fev. 2018.

ROBERTSON, D. I. TRANSYT Method for area traffic control. **Traffic engineering & control.**, v. 11, n. 6, p. 276–281, 1978. Disponível em: <<http://www.worldcat.org/title/traffic-engineering-control/oclc/1645844>>. Acesso em: 5 jun. 2018.

RODGERS, J. L.; NICEWANDER, W. A. Thirteen Ways to Look at the Correlation Coefficient. **The American Statistician**, v. 42, n. 1, p. 59, fev. 1988. Disponível em: <<https://www.jstor.org/stable/2685263?origin=crossref>>. Acesso em: 21 fev. 2019.

ROLLS, E.; TREVES, A. **Neural Networks and Brain Function**. [s.l.] Oxford University Pres, 1998.

SABETGHADAM, B. et al. Type-2 fuzzy multiagent traffic signal control. In: 2012 IEEE 13th International Conference on Information Reuse & Integration (IRI), **Anais...IEEE**, ago. 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6303051/>>. Acesso em: 7 dez. 2017.

SALKHAM, A. et al. A Collaborative Reinforcement Learning Approach to Urban Traffic Control Optimization. In: 2008 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology, **Anais...IEEE**, dez. 2008. Disponível em: <<http://ieeexplore.ieee.org/document/4740684/>>. Acesso em: 7 dez. 2017.

SAPNA, S.; TAMILARASI, A.; KUMAR, M. P. Backpropagation Learning Algorithm Based on Levenberg Marquardt Algorithm. In: Computer Science & Information Technology (CS & IT), **Anais...Academy & Industry Research Collaboration Center (AIRCC)**, 31 out. 2012. Disponível em: <<http://www.airccj.org/CSCP/vol2/csit2438.pdf>>. Acesso em: 26 fev. 2019.

SILVA, I. N. Da et al. Artificial Neural Network Architectures and Training Processes. In: **Artificial neural networks : a practical course**. [s.l.] Springer, 2017. p. 307.

SONI, D. **Introduction to Evolutionary Algorithms. Optimization by natural selection**. Disponível em: <<https://towardsdatascience.com/introduction-to-evolutionary-algorithms-a8594b484ac>>. Acesso em: 2 jun. 2018.

SRINIVASAN, D.; CHOY, M. C.; CHEU, R. L. Cooperative, hybrid agent architecture for real-time traffic signal control. **IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans**, v. 33, n. 5, p. 597–607, 2003. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1245532>>.

SRINIVASAN, D.; CHOY, M. C. M. C. M. C.; CHEU, R. L. R. L. R. L. Neural networks for real-time traffic signal control. **IEEE Transactions on Intelligent Transportation Systems**, v. 7, n. 3, p. 261–272, set. 2006. Disponível em: <<http://ieeexplore.ieee.org/document/1688100/>>. Acesso em: 7 dez. 2017.

TETTAMANTI, T. et al. Robust Control for Urban Road Traffic Networks. **IEEE Transactions on Intelligent Transportation Systems**, v. 15, n. 1, p. 385–398, fev. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6615947/>>. Acesso em: 17 maio. 2018.

THUNIG, T.; NAGEL, K. Towards a robust and wide-area traffic signal control for inner-city areas. In: 2017 5th IEEE International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS), **Anais...IEEE**, jun. 2017. Disponível em: <<http://ieeexplore.ieee.org/document/8005622/>>. Acesso em: 7 dez. 2017.

UNITED NATIONS. **World population prospects. Key finding and advance tablesSante Publique**. [s.l: s.n.]. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/21798940>>.

VIT, F. et al. System alliances as a tool for solving Smart Cities problems. **2015 Smart Cities Symposium Prague, SCSP 2015**, 2015.

VON STRITZKY, J.; CABRERIZO, C. Ideas para las ciudades inteligentes del futuro. p. 64, 2011.

VRANCKEN, J.; DOS SANTOS SOARES, M. Multi-level control of networks: the case of road traffic control. In: 2007 IEEE International Conference on Systems, Man and Cybernetics, **Anais...IEEE**, out. 2007. Disponível em: <<http://ieeexplore.ieee.org/document/4414190/>>. Acesso em: 30 maio. 2018.

WEBSTER, F. **Traffic signal settings**. London: H.M.S.O., 1958.

WEN, K.; QU, S.; ZHANG, Y. A Control-oriented Macroscopic Traffic Flow Model for Urban Diverse Intersections. In: 2009 International Asia Conference on Informatics in Control, Automation and Robotics, **Anais...IEEE**, fev. 2009. Disponível em: <<http://ieeexplore.ieee.org/document/4777195/>>. Acesso em: 30 maio. 2018.

WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, Madaline, and backpropagation. **Proceedings of the IEEE**, v. 78, n. 9, p. 1415–1442, 1990. Disponível em: <<http://ieeexplore.ieee.org/document/58323/>>. Acesso em: 8 jun. 2018.

WONGPIROMSARN, T. et al. Distributed traffic signal control for maximum network throughput. In: 2012 15th International IEEE Conference on Intelligent Transportation Systems, **Anais...IEEE**, set. 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6338817/>>. Acesso em: 2 jun. 2018.

WU, B.; WANG, D. Traffic Signal Networks Control Optimize with PSO Algorithm. p. 230–234, 2016.

XU, Y. et al. Multiagent Based Decentralized Traffic Light Control for Large Urban Transportation System. **Mathematical Problems in Engineering**, v. 2014, n. 3, p. 1–13, dez. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7424092/>>. Acesso em: 6 dez. 2017.

YE, B.-L. et al. A green wave band based method for urban arterial signal control. In: Proceedings of the 11th IEEE International Conference on Networking, Sensing and Control, **Anais...IEEE**, abr. 2014. Disponível em: <<http://ieeexplore.ieee.org/document/6819612/>>. Acesso em: 7 dez. 2017.

YIN, B.; DRIDI, M.; EL MOUDNI, A. Approximate dynamic programming with recursive least-squares temporal difference learning for adaptive traffic signal control. In: 2015 54th IEEE Conference on Decision and Control (CDC), **Anais...IEEE**, dez. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7402755/>>. Acesso em: 5 jun. 2018.

YU, D.; WU, Y.; YANG, N. Research on Area Control Method in Urban Signal Intersection under the Multi - agent System. In: 2016 Eighth International Conference on Measuring Technology and Mechatronics Automation (ICMTMA), **Anais...IEEE**, mar. 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7488602/>>. Acesso em: 18 maio. 2018.

YU, J. et al. A survey on CPG-inspired control models and system implementation. **IEEE Transactions on Neural Networks and Learning Systems**, v. 25, p. 441–456, 2014.

ZADEH, L. A. Fuzzy sets. **Information and Control**, v. 8, n. 3, p. 338–353, 1 jun. 1965. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S001999586590241X?via%3Dihub>>. Acesso em: 2 jun. 2018.

ZADEH, L. A.; KLIR, G. J.; YUAN, B. **Fuzzy Sets, Fuzzy Logic, and Fuzzy Systems**. [s.l.] WORLD SCIENTIFIC, 1996. v. 6

ZEGEYE, S. K. et al. A Predictive Traffic Controller for Sustainable Mobility Using Parameterized Control Policies. **IEEE Transactions on Intelligent Transportation Systems**, v. 13, n. 3, p. 1420–1429, set. 2012. Disponível em: <<http://ieeexplore.ieee.org/document/6226876/>>. Acesso em: 6 jun. 2018.

ZHANG, G. P. Neural networks for classification: a survey. **IEEE Transactions on Systems, Man and Cybernetics, Part C (Applications and Reviews)**, v. 30, n. 4, p. 451–462, 2000. Disponível em: <<http://ieeexplore.ieee.org/document/897072/>>. Acesso em: 3 jun. 2018.

ZHAO-SHENG YANG et al. Intelligent cooperation control of urban traffic networks. In: 2005 International Conference on Machine Learning and Cybernetics, **Anais...IEEE**, 2005. Disponível em: <<http://ieeexplore.ieee.org/document/1527178/>>. Acesso em: 7 dez. 2017.

ZHAO, D.; DAI, Y.; ZHANG, Z. Computational Intelligence in Urban Traffic Signal Control: A Survey. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, v. 42, n. 4, p. 485–494, jul. 2012. Disponível em: <<http://ieeexplore.ieee.org/document/5978226/>>. Acesso em: 7 dez. 2017.

ZHOU, Z. et al. Two-Level Hierarchical Model-Based Predictive Control for Large-Scale Urban Traffic Networks. **IEEE Transactions on Control Systems Technology**, v. 25, n. 2, p. 496–508, mar. 2017. Disponível em: <<http://ieeexplore.ieee.org/document/7488982/>>. Acesso em: 6

jun. 2018.

ZITZLER, E.; THIELE, L. Multiobjective evolutionary algorithms: a comparative case study and the strength Pareto approach. **IEEE Transactions on Evolutionary Computation**, v. 3, n. 4, p. 257–271, 1999. Disponível em: <<http://ieeexplore.ieee.org/document/797969/>>. Acesso em: 2 jun. 2018.