GUILHERME BARROS CASTRO

Modelo de rede neural bioinspirada para o controle do trânsito urbano

Tese apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Doutor em Ciências

GUILHERME BARROS CASTRO

Modelo de rede neural bioinspirada para o controle do trânsito urbano

Tese apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Doutor em Ciências

Área de concentração: Engenharia da Computação

Orientador: Prof. Dr. André Riyuiti Hirakawa

São Paulo 2017

Este exemplar foi revisado e responsabilidade única do a	e corrigido em relação à versão original, sob autor e com a anuência de seu orientador.
São Paulo, de	de
Assinatura do autor:	
Assinatura do orientador:	

Catalogação-na-publicação

Castro, Guilherme Modelo de rede neural bioinspirada para o controle do trânsito urbano / G. Castro -- versão corr. -- São Paulo, 2017. 134 p. Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Computação e Sistemas Digitais. 1.Rede neural bioinspirada 2.Controle do trânsito urbano 3.Sistemas

dinâmicos complexos 4.Inteligência artificial I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Computação e Sistemas Digitais II.t.

Para meus pais, meu irmão e meu amor.

AGRADECIMENTOS

Gostaria de agradecer a meu orientador, professor André Hirakawa, por seu suporte e orientação durante todas as etapas da pesquisa de doutorado. Expresso minha gratidão ao professor Sidnei Martini, pelo incentivo a iniciar o doutorado e pela constante motivação e transmissão de conhecimento. Agradeço também aos professores Kechi Hirama e Bruno Albertini por sua contribuição para esta pesquisa e para este pesquisador por meio dos valiosos comentários e sugestões. Gostaria de agradecer ainda a todos os professores do departamento de Engenharia de Computação da Escola Politécnica da Universidade de São Paulo, pelo conhecimento transmitido ao longo dos anos de doutorado. Ademais, agradeço aos membros da banca, os professores Antonio Mauro Saraiva, Luciano Antonio Digiampietri, Francisco Javier Ropero Peláez e José Francisco Resende da Silva, por despenderem seu tempo com a finalidade de contribuir com o processo de doutoramento da Escola Politécnica. Expresso minha gratidão aos colegas de laboratório Akio, Celso e Danilo, pelas conversas enriquecedoras, e ao colega de Escola Politécnica Robinson Mashiba, pelas diversas discussões e reflexões sobre esta pesquisa e sobre engenharia. Por fim, agradeço imensamente a minha família, pelo constante apoio e incentivo, e a meu amor, por estar ao meu lado durante todos os anos do doutorado, sempre me motivando.

RESUMO

Congestionamentos no trânsito urbano são uma preocupação principal em grandes cidades pelo mundo, devido a seus impactos negativos multifacetados na saúde humana, no meio ambiente e na economia. A urbanização crescente, e seu consequente aumento no volume do trânsito. ainda causam mais congestionamentos por causa do ritmo lento – e, em alguns casos, inexistente – das melhoras na infraestrutura urbana. Uma solução com bom custo-benefício para reduzir o tempo médio de viagem dos veículos e prevenir os congestionamentos é o controle do trânsito urbano. No entanto, a maior parte das abordagens de controle do trânsito urbano adota um ciclo de controle fixo, o qual limita o desempenho de controle devido à consequente inabilidade de agir quando necessário. Ao contrário dessas abordagens, esse trabalho propõe uma rede neural bioinspirada que monitora o estado do sistema de forma contínua e é capaz de agir em qualquer momento. A rede neural bioinspirada proposta adota plasticidade intrínseca e inibição lateral para gerar uma competição natural entre os neurônios, a qual determina quais semáforos devem ser ativados em cada momento. Além disso, interneurônios inibitórios são adotados para coordenar intersecções vizinhas e melhorar os fluxos de veículos. Devido à grande quantidade de possíveis combinações dos parâmetros, um método para determinar o comportamento do modelo de acordo com as características intrínsecas da rede neural bioinspirada também é proposto. A convergência e a estabilidade do modelo proposto são avaliadas por seus pontos-fixos e autovalores, respectivamente. Ademais, o tempo de processamento e a complexidade computacional da rede neural bioinspirada também são avaliados. Por fim, o desempenho do modelo para diferentes demandas de veículos e situações do trânsito é avaliado com um simulador de mobilidade urbana e comparado a um método de controle adaptativo.

ABSTRACT

Traffic congestions are a major concern for big cities around the world due to its multifaceted negative impacts on human health, the environment and the economy. Growing urbanization, and the consequent increase in traffic volume, causes even more traffic congestions due to the slow-paced – and, in some cases, non-existing – improvements in the urban traffic infrastructure. A cost-effective solution to reduce vehicle travel times and prevent traffic congestions is traffic signal control. However, most approaches to traffic signal control adopt a fixed control cycle, which limits control performance due to the consequent inability to act when necessary. Contrary to these approaches, this work proposes a biologically-inspired neural network that monitors the system state continuously and can act upon it at any moment. The biologically-inspired neural network proposed adopts intrinsic plasticity and lateral inhibition to generate natural competition among neurons, determining which semaphores should be active at each moment. Furthermore, inhibitory interneurons are also adopted to coordinate neighboring intersections and to improve vehicle flows. Due to the large number of parameter combinations, a method to determine the model behavior according to the intrinsic characteristics of the biologicallyinspired neural network is also proposed. Model convergence and stability are evaluated by its fixed-points and eigenvalues, respectively. Moreover, the computation time and computational complexity of the biologically-inspired neural network are also evaluated. Finally, the model performance for different vehicle demands and traffic situations is evaluated with a simulator of urban mobility and compared to an adaptive control method.

LISTA DE FIGURAS

Figura 1 – Ciclo semafórico em uma intersecção com duas fases	24
Figura 2 – Modelo do veículo no nível de análise submicroscópico do trânsi	to urbano 30
Figura 3 – Modelo do veículo no nível de análise microscópico do trânsito u	rbano30
Figura 4 – Modelo dos veículos no nível de análise mesoscópico do trânsito	urbano
Figura 5 – Modelo dos veículos no nível de análise macroscópico do trânsit	o urbano 31
Figura 6 – Estruturas de controle centralizada, distribuída e hierárquica	32
Figura 7 – Sistema difuso de controle	37
Figura 8 – Funções de pertinência de um sistema difuso de controle	38
Figura 9 – Função de pertinência de um sistema difuso tipo-2	39
Figura 10 – Cruzamento genético	41
Figura 11 – Neurônio artificial	43
Figura 12 – Funções de ativação	44
Figura 13 – Topologia das redes neurais artificiais	45
Figura 14 – Função de ativação e plasticidade intrínseca	82
Figura 15 – Estrutura da rede neural bioinspirada para o controle de uma in	tersecção 83
Figura 16 – Comportamento dos neurônios <i>p</i> com entradas iguais e constar	ntes84
Figura 17 – Estrutura da rede neural bioinspirada para a coordenação de intersecções	86
Figura 18 – Estrutura da rede neural bioinspirada para a coordenação de intersecções	
Figura 19 – Fluxograma do algoritmo	94
Figura 20 – Cenário da análise	95
<u> </u>	

Figura 21 – Estrutura da rede neural bioinspirada para controlar uma intersecção
Figura 22 – Autovalores λ do Jacobiano do neurônio p_1 como funções da saída O_{q_1} do neurônio q_1
Figura 23 – Trajetória das variáveis de estado ($A e s$) do neurônio p_1 para O_{q1} maior que 0,9
Figura 24 – Trajetória das variáveis de estado (A e s) do neurônio p ₁ para O _{q1} igual a 0,5
Figura 25 – Avaliação do tempo de processamento e da complexidade computacional
Figura 26 – Tempo médio de viagem dos veículos para vários níveis de demanda 105
Figura 27 – Número de veículos na intersecção 1 ao longo do tempo (demanda balanceada)
Figura 28 – Tempo médio de viagem dos veículos em cenários com demanda desbalanceada
Figura 29 – Número de veículos na intersecção 1 ao longo do tempo (demanda desbalanceada)

LISTA DE TABELAS

Tabela 1 – Influência relativa dos parâmetros da rede neural bioinspirada em Ω 89
Tabela 2 – Frequência natural de oscilação Ω como uma função de w_p e v 90

LISTA DE ABREVIATURAS E SIGLAS

BDI	Beliefs Desires and Intentions
CET SP	Companhia de Engenharia de Tráfego de São Paulo
GLIDE	Green Link Determining
HMS	Hierarchical Multiagent System
MOVA	Microprocessor Optimised Vehicle Actuation
PCE	Passenger Car Equivalent
PIB	Produto Interno Bruto
SCATS	Sydney Coordinated Area Traffic System
SCOOT	Split, Cycle, Offset Optimization Technique
SUMO	Simulation of Urban MObility
TRANSYT	Traffic network study tool
XML	eXtensible Markup Language

SUMÁRIO

1.			γAU	21
1	I.1. C	Contex	tualização	21
1	I.2. C	Dbjetiv	0	25
1	I.3. J	ustific	ativa	26
1	I.4. C	Organi	zação do documento	27
2.	FUN	DAME	NTAÇÃO CONCEITUAL	29
2	2.1. F	undar	mentos do controle do trânsito urbano	29
	2.1.1	. Nív	veis de análise	29
	2.1.2	. Aro	quiteturas de controle	32
	2.1.3	. Pa	râmetros de controle e desempenho	33
	2.1.4	. Pri	meiras abordagens	34
2	2.2. F	undar	mentos das técnicas aplicadas ao controle do trânsito urbano	36
	2.2.1	. Té	cnicas baseadas em inteligência artificial	37
	2.2	2.1.1.	Lógica difusa	37
	2.2 2.2	2.1.1. 2.1.2.	Lógica difusa	37 39
	2.2 2.2 2.2	2.1.1. 2.1.2. 2.1.3.	Lógica difusa Algoritmos evolucionários Aprendizado por reforço	37 39 42
	2.2 2.2 2.2 2.2	2.1.1. 2.1.2. 2.1.3. 2.1.4.	Lógica difusa Algoritmos evolucionários Aprendizado por reforço Redes neurais artificiais	37 39 42 43
	2.2 2.2 2.2 2.2 2.2	2.1.1. 2.1.2. 2.1.3. 2.1.4. 2.1.5.	Lógica difusa Algoritmos evolucionários Aprendizado por reforço Redes neurais artificiais Sistemas multiagente	37 39 42 43 43
	2.2 2.2 2.2 2.2 2.2 2.2	2.1.1. 2.1.2. 2.1.3. 2.1.4. 2.1.5.	Lógica difusa Algoritmos evolucionários Aprendizado por reforço Redes neurais artificiais Sistemas multiagente cnicas baseadas na teoria de controle ótimo	37 39 42 43 43 46 47
	2.2 2.2 2.2 2.2 2.2 2.2 2.2.2 2.2	2.1.1. 2.1.2. 2.1.3. 2.1.4. 2.1.5. 2.1.5. . Té 2.2.1.	Lógica difusa Algoritmos evolucionários Aprendizado por reforço Redes neurais artificiais Sistemas multiagente cnicas baseadas na teoria de controle ótimo Programação dinâmica	37 39 42 43 43 46 47 47
	2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2	2.1.1. 2.1.2. 2.1.3. 2.1.4. 2.1.5. 2.1.5. Té 2.2.1. 2.2.2.	Lógica difusa Algoritmos evolucionários Aprendizado por reforço Redes neurais artificiais Sistemas multiagente cnicas baseadas na teoria de controle ótimo Programação dinâmica Controle preditivo baseado em modelo	37 39 42 43 46 47 47 48
	2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2	2.1.1. 2.1.2. 2.1.3. 2.1.4. 2.1.5. 2.1.5. 2.2.1. 2.2.1. 2.2.2. 2.2.3.	Lógica difusa Algoritmos evolucionários Aprendizado por reforço Redes neurais artificiais Sistemas multiagente cnicas baseadas na teoria de controle ótimo Programação dinâmica Controle preditivo baseado em modelo Contrapressão	37 39 42 43 46 47 47 47 48 49
3.	2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2	2.1.1. 2.1.2. 2.1.3. 2.1.4. 2.1.5. 2.2.1. 2.2.2. 2.2.2. BALH	Lógica difusa Algoritmos evolucionários Aprendizado por reforço Redes neurais artificiais Sistemas multiagente cnicas baseadas na teoria de controle ótimo Programação dinâmica Controle preditivo baseado em modelo Contrapressão OS RELACIONADOS	37 39 42 43 46 47 47 47 48 49 51
3.	2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2	2.1.1. 2.1.2. 2.1.3. 2.1.4. 2.1.5. 2.1.5. 2.2.1. 2.2.1. 2.2.2. 2.2.3. BALH ⁱ Traball	Lógica difusa Algoritmos evolucionários Aprendizado por reforço Redes neurais artificiais Sistemas multiagente cnicas baseadas na teoria de controle ótimo Programação dinâmica Controle preditivo baseado em modelo Contrapressão OS RELACIONADOS	37 39 42 43 46 47 47 47 47 47 47 47 47 47 451 51
3.	2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2 2.2	2.1.1. 2.1.2. 2.1.3. 2.1.4. 2.1.5. 2.1.5. 2.2.1. 2.2.2. 2.2.2. BALH Traball . So	Lógica difusa Algoritmos evolucionários Aprendizado por reforço Redes neurais artificiais Sistemas multiagente Cnicas baseadas na teoria de controle ótimo Programação dinâmica Controle preditivo baseado em modelo Contrapressão OS RELACIONADOS nos relacionados ao controle do trânsito urbano luções baseadas em inteligência artificial	37 39 42 43 46 47 47 47 47 47 47 51 51

	:	3.1.1	.2. Algoritmos evolucionários	. 55
		3.1.1	.3. Aprendizado por reforço	. 57
		3.1.1	.4. Redes neurais artificiais	. 60
		3.1.1	.5. Sistemas multiagente	. 63
	3.1	1.2.	Soluções baseadas na teoria de controle ótimo	. 66
		3.1.2	.1. Programação dinâmica	. 66
		3.1.2	2.2. Controle preditivo baseado em modelo	. 68
		3.1.2	.3. Contrapressão	. 71
	3.2.	Tra	balhos relacionados a modelos de redes neurais bioinspiradas	. 73
	3.2 rel	2.1. acior	Similaridades e diferenças entre o modelo proposto e modelos nados	76
4.	МС	DDEI	LO DE REDE NEURAL BIOINSPIRADA PARA O CONTROLE DO	
ΤF	RÂNS	SITO	URBANO	. 79
	4.1.	Met	todologia	. 79
	4.2.	Мо	delo proposto	. 80
	4.2	2.1.	Controle de uma intersecção	. 82
	4.2	2.2.	Coordenação de intersecções	. 86
	4.2	2.3.	Determinação dos parâmetros	. 88
5.	RE	SUL	TADOS	. 93
	5.1.	Cor	nvergência e estabilidade	. 94
	5.2.	Ter	npo de computação e complexidade computacional	101
	5.3.	Sim	nulações do trânsito urbano	104
	5.3	8.1.	Demanda balanceada	105
	5.3	3.2.	Demanda desbalanceada	106
	5.4.	Dis	cussão acerca dos resultados	108
	5.5. semź	Asp áforo	pectos relacionados à implementação de um sistema de controle de	110
6)NCI	USÕES	113
υ.				110

1. INTRODUÇÃO

1.1. Contextualização

A crescente urbanização e o consequente aumento da quantidade de veículos circulando nos centros urbanos causam ainda mais congestionamentos devido à lenta, e, por vezes, inexistente, melhora na infraestrutura de mobilidade urbana. Congestionamentos resultam da uma quantidade de veículos circulando maior do que a cidade é capaz de atender, e impactam de forma negativa a economia, o meio ambiente e a sociedade. Healey e Picard (2005) analisaram métodos fisiológicos de detecção de estresse dos motoristas, como o eletrocardiograma, o eletromiograma, a condutância da pele e a respiração, por meio dos quais fica evidente o impacto negativo do trânsito na saúde humana. Mahmod et al. (2012) investigaram uma região delimitada e demonstraram a relação direta entre a quantidade de veículos circulando e a emissão de gases, como o dióxido de carbono (CO₂), óxidos de nitrogênio (NO_x), e materiais particulados (PM₁₀), os quais afetam a qualidade do ar e, por conseguinte, também a saúde humana.

Segundo Grillo e Laperrouze (2013), o trânsito urbano também tem efeito direto sobre o Produto Interno Bruto (PIB), cujos principais fatores são: o custo do combustível; o custo associado à emissão de gás carbônico; e o custo de oportunidade do tempo gasto pelos cidadãos em congestionamentos. Congestionamentos têm ainda implicações nos negócios locais, afetando seus custos e sua produtividade, como analisado por Weisbrod, Vary e Treyz (2003). Cintra (2014) estimou o desperdício de recursos por causa dos congestionamentos na cidade de São Paulo em 40 bilhões de reais para o ano de 2012, o que corresponde a 7,6% do PIB da cidade nesse ano. Por sua vez, Haddad e Vieira (2015) estimaram que uma redução de 27,63% no tempo de viagem dos motoristas da Região Metropolitana de São Paulo corresponderia a um aumento de 15,75% na produtividade dos trabalhadores da região, o que geraria um aumento de 110 bilhões de reais no PIB brasileiro no ano de 2010 (2,83% maior). Devido à dimensão do efeito da redução do tempo de viagem dos veículos no PIB, nota-se que qualquer redução adicional estatisticamente significante é importante.

Uma maneira de mitigar os impactos negativos mencionados é realizar o controle do trânsito urbano por meio da temporização dos semáforos, que visa

otimizar os fluxos de veículos, reduzindo os tempos de viagem e prevenindo congestionamentos. Dessa forma, controladores, presentes em cada intersecção entre vias, recebem informações de sensores sobre a ocupação das vias e determinam a duração do sinal verde de cada semáforo de acordo com a estratégia adotada. Abordagens baseadas tanto na teoria de controle ótimo quanto em técnicas de inteligência artificial foram propostas, como revisado no Capítulo 3 deste trabalho. No entanto, como o trânsito urbano é um sistema dinâmico complexo, não há uma solução definitiva – que só possua vantagens em relação às outras – para o seu controle.

Há diversas definições do termo 'sistema dinâmico complexo' na literatura, consequência dos diferentes conjuntos de características que esse tipo de sistema apresenta (BOSSOMAIER; GREEN, 2007; KINSNER, 2008; FUCHS, 2013; GROS, 2013). Tal diversidade pode ser ilustrada com exemplos, como é o caso de ecossistemas, da expressão genética, de cadeias de proteínas, do cérebro, da disseminação de doenças infecciosas, de reações químicas, da formação de tornados, do comportamento de torcedores em um estádio de futebol, de redes sociais, da meteorologia, da robótica, da economia, das redes de comunicação, da geração e distribuição de energia elétrica, e de todo sistema que envolva a ampla interação entre humanos (BOSSOMAIER; GREEN, 2007; FUCHS, 2013; GROS, 2013; ANTONELLI, 2013). A apresentação de algumas definições da literatura sobre sistemas dinâmicos complexos permite captar seu conceito geral, o qual elucida o comportamento do trânsito urbano e é abordado posteriormente neste trabalho para verificar a aderência do modelo proposto como um sistema dinâmico complexo.

Gros (2013) declara que a teoria de sistemas complexos aborda sistemas dinâmicos com um grande número de variáveis e que ela é uma extensão da teoria de sistemas dinâmicos com poucas variáveis. Segundo o autor, a quantidade de variáveis que torna um sistema dinâmico complexo é aquela que torna sua dinâmica caótica. Por sua vez, dinâmica caótica é o comportamento a partir do qual a predição do estado do sistema é impossível, visto que ele possui uma sensibilidade exponencial às condições iniciais do sistema e a distúrbios.

Fuchs (2013) define sistemas complexos como sistemas que exibem propriedades emergentes por causa da interação entre seus subsistemas. Essas propriedades caracterizam o sistema por gerar padrões temporais e espaciais em uma escala ordens de grandeza maior do que a escala das interações entre os

subsistemas. O autor também ressalta que sistemas complexos passam por constantes transições entre diferentes estados dinâmicos.

Bossomaier e Green (2007) definem complexidade como o balanço entre a ordem e a desordem de um sistema, apresentando fases de transição entre seus estados de equilíbrio, e originando padrões por meio da interação entre seus subsistemas. Além das definições similares – porém complementares – apresentadas pelos autores, Gros (2013), Fuchs (2013) e Bossomaier e Green (2007) ainda mencionam que sistemas dinâmicos complexos são caracterizados por possuírem não linearidades e um comportamento estocástico.

Neste trabalho, o termo 'sistema dinâmico complexo' faz referência a sistemas dinâmicos não lineares, estocásticos, com múltiplas variáveis, tanto do sistema quanto de entrada, que se modificam com o tempo, e com subsistemas que possuem relações de interdependência. O trânsito urbano é um sistema dinâmico complexo por cumprir todos os quesitos dessa definição. Por exemplo, cada intersecção entre vias, controlada por seu conjunto de semáforos, é considerada um subsistema do trânsito urbano. Ademais, cada intersecção (subsistema) interage com suas intersecções vizinhas (subsistemas vizinhos), tanto recebendo quanto enviando fluxos de veículos por meio das vias que as interconectam. A dinâmica não linear dos veículos se soma ao fechamento e à abertura de vias pelos semáforos, causando períodos de interrupção nos fluxos de veículos. Fatores como chuvas, alagamentos, buracos nas vias e frenagens inesperadas de veículos tornam o sistema de trânsito estocástico. Dentre as variáveis do sistema, os níveis de ocupação das vias são variáveis de entrada, enquanto a duração do sinal verde de cada semáforo compõe o conjunto de variáveis de estado.

Além disso, o trânsito urbano possui tanto observabilidade quanto atuação parcial, o que é um fator de complexidade adicional, dificultando ainda mais a predição de seu comportamento. Isso ocorre porque o comportamento dos motoristas não pode ser previsto 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 precisar com exatidão o número de veículos que irão atravessar a intersecção por ele controlada.

As soluções de controle revisadas neste trabalho (Capítulo 3) simplificam a dinâmica complexa do trânsito urbano ao linearizar o comportamento dos fluxos de veículos e ao discretizar o controle em ciclos semafóricos. Um ciclo semafórico



Figura 1 – Ciclo semafórico em uma intersecção com duas fases

Fonte: autoria própria

compreende o tempo total de todas as fases semafóricas de um cruzamento entre vias, como ilustrado na Figura 1. As abordagens em questão avaliam o estado do sistema de trânsito urbano ao fim de um ciclo semafórico e determinam, com essa informação, o tempo de verde de cada fase semafórica no ciclo seguinte. Essas simplificações facilitam a obtenção de uma solução para o problema de controle, mas também limitam seu desempenho, impossibilitando uma redução ainda maior do tempo de viagem dos veículos por não representarem com fidelidade a complexidade do sistema controlado.

De acordo com Bossomaier e Green (2007), a maneira com que a biologia aborda o problema de controle de sistemas gerou uma mudança de paradigma na área de robótica – a qual compreende sistemas dinâmicos complexos –, que levou pesquisadores a investigarem o controle inspirado no comportamento animal, por meio de redes neurais bioinspiradas. Yu et al. (2014) ressaltam a naturalidade com que os animais se locomovem e realizam tarefas em ambientes complexos, o que não é perceptível em robôs baseados tanto em modelos matemáticos quanto em técnicas numéricas de controle. Para os autores, atuadores presentes no controle de sistemas complexos têm a dificuldade de reproduzir as propriedades não lineares necessárias. O uso de redes neurais na área de controle é justificado, portanto, por serem sistemas não lineares que tem a capacidade de modelar comportamentos dinâmicos mais complexos. Todavia, essa abordagem foi pouco explorada, especialmente no que se refere às características biológicas dos neurônios (FOLGHERAITER et al., 2006; LEWIS; KLEIN, 2009; YU et al., 2014).

Redes neurais bioinspiradas diferem das redes neurais artificiais por focarem no comportamento dinâmico da rede neural, não necessariamente possuindo um período de treino de seus pesos sinápticos (parâmetros da rede neural), enquanto as redes neurais artificiais focam no aprendizado, o qual depende desse período de treinamento. Além disso, as redes neurais bioinspiradas adotam mais características de redes neurais biológicas, como sinapses inibitórias e mecanismos de adaptação neural. Yu et al. (2014) ressaltaram as principais vantagens de utilizar redes neurais bioinspiradas no controle de sistemas dinâmicos complexos: estabilidade e adaptabilidade.

Nesse contexto, esta pesquisa investigou o trânsito urbano e redes neurais bioinspiradas como sistemas dinâmicos complexos e propôs um modelo de controle com a finalidade de reduzir o tempo de viagem dos veículos em comparação a soluções baseadas em ciclos semafóricos. Por causa de sua estrutura e de suas propriedades, a rede neural bioinspirada proposta é capaz de monitorar o estado do sistema de trânsito urbano e tomar decisões de forma contínua, não sendo limitada por ciclos semafóricos e representando, assim, as variações não lineares do sistema.

1.2. Objetivo

O objetivo deste trabalho é propor um modelo de rede neural bioinspirada para representar o complexo sistema do trânsito urbano e possibilitar o seu controle, considerando as incertezas, as variações, o dinamismo e os relacionamentos dos diferentes componentes do sistema.

Para tanto, foi estudada a dinâmica do sistema de trânsito urbano, tanto em níveis macro quanto em níveis microscópicos, assim como as diferentes abordagens para o seu controle. Investigou-se também os aspectos dos modelos computacionais de neurônios biológicos, como sua dinâmica de ativação e inibição e seus mecanismos de adaptação, de modo a conceder ao modelo proposto as características desejadas, como reatividade momentânea e a capacidade de reagir ao estado do sistema de acordo com o conhecimento incorporado.

Por se tratar de um sistema dinâmico complexo, objetivos específicos acerca do modelo proposto incluem análises de convergência, estabilidade e complexidade computacional do modelo, assim como uma maneira de determinar seus parâmetros. Além disso, estudos de simulação avaliam o desempenho do modelo no controle do trânsito urbano.

O escopo desta pesquisa se limita à proposta e estudo de um modelo para a representação e controle do trânsito urbano, não se estendendo a sua aplicação prática e nem a questões relacionadas ao sensoriamento para a obtenção das informações de entrada do modelo, como os níveis de ocupação das vias.

1.3. Justificativa

A limitação comum dos trabalhos relacionados ao controle do trânsito urbano é a maneira como eles o simplificam, linearizando sua dinâmica e discretizando seu controle em ciclos, como apresentado na Seção 1.1 e detalhado no Capítulo 3. Segundo Fuchs (2003), sistemas linearizados são restritos quanto a seu comportamento dinâmico, não sendo modelos adequados para representar dinâmicas complexas com fidelidade. Um fenômeno similar à redução do desempenho de controle por causa da delimitação dos ciclos semafóricos ocorre na discretização de sistemas contínuos. Erros são originados caso o intervalo de amostragem não seja pequeno o suficiente, impedindo uma caracterização completa do sistema discretizado. Esse fenômeno, também chamado de *aliasing* na área de processamento de sinais, foi descrito por Nyquist (1928) e Shannon (1949) e é conhecido como o Teorema da Amostragem de Nyquist-Shannon.

Além desta limitação comum, cada tipo de solução possui ainda limitações específicas. Modelos do trânsito urbano que consideram as incertezas do sistema ou que tentam predizer seu comportamento são pouco precisos e computacionalmente intensivos (LI, 2011; GOKULAN; SRINIVASAN, 2010), como é o caso de abordagens baseadas na teoria de controle ótimo (programação dinâmica e controle

preditivo baseado em modelo). Por sua vez, métodos baseados no aprendizado, como redes neurais artificiais ou métodos de aprendizado por reforço, demandam uma quantidade infactível de dados e de tempo de treinamento para representar e controlar sistemas estocásticos com grande número de variáveis (GOKULAN; SRINIVASAN, 2010; TETTAMANTI et al., 2014).

Apesar de não se basear em modelos matemáticos e representar de forma simples o conhecimento sobre o sistema, controladores difusos ou baseados em lógica também têm dificuldade em incorporar mais informações sobre a dinâmica do sistema, pois a adição de novas regras de controle gera um aumento exponencial de complexidade computacional. Ademais, 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 dependente de variáveis externas não controladas (GOKULAN; SRINIVASAN, 2010; TETTAMANTI et al., 2014).

Com base nas propriedades de modelos de redes neurais bioinspiradas propostos para o controle de robôs (IJSPEERT, 2008; NICHOLS; MCDAID; SIDDIQUE, 2013; HELGADOTTIR et al., 2013; YU et al., 2014), como a estabilidade dinâmica frente a distúrbios e a capacidade de adaptação instantânea a mudanças no ambiente de atuação, propôs-se um modelo de rede neural bioinspirada que apresenta as características desejadas para o controle do trânsito urbano. Tais características, as quais ampliam tanto a reatividade do controle do trânsito urbano quanto suas possibilidades de atuação, são: a reordenação de fases semafóricas; a alteração imediata da duração das fases semafóricas; e a incorporação de conhecimento sobre o sistema controlado sem que haja um custo computacional adicional que impeça sua aplicação em um sistema de controle em tempo real. O desempenho do modelo proposto não depende nem da predição do comportamento do sistema de trânsito urbano e nem de técnicas de aprendizado, obtendo melhoras por causa de sua adaptabilidade instantânea, em contraposição à limitação imposta pelos ciclos semafóricos adotados em outras soluções.

1.4. Organização do documento

O primeiro capítulo desse documento contextualizou o problema investigado e expôs o objetivo do doutorado, assim como a justificativa para sua execução. O Capítulo 2 aborda uma fundamentação conceitual para a elucidação tanto dos

princípios que regem trabalhos relacionados ao controle do trânsito urbano, quanto das técnicas utilizadas no controle do trânsito urbano. Tais técnicas foram divididas em duas categorias: as relativas à inteligência artificial; e as relativas à teoria de controle ótimo. O Capítulo 3 discute os trabalhos relacionados ao controle do trânsito urbano e a modelos de rede neural bioinspirada utilizados para o controle de sistemas. Ademais, discute-se semelhanças e diferenças entre o modelo de rede neural bioinspirada proposto e outros modelos. O Capítulo 4 elucida o modelo de rede neural bioinspirada proposto para o controle do trânsito urbano, apresentando as equações que regem seu comportamento, sua estrutura e um método para a determinação de seus parâmetros. O Capítulo 5 apresenta os resultados obtidos em três aspectos: 1) análise de convergência e estabilidade do modelo proposto; 2) análise do tempo de processamento e da complexidade computacional do modelo proposto; 3) e avaliação do desempenho do modelo proposto no controle do trânsito urbano. Por fim, o Capítulo 6 abrange as conclusões desse trabalho e possíveis direções para futuras pesquisas.

2. FUNDAMENTAÇÃO CONCEITUAL

Este capítulo aborda os fundamentos conceituais necessários para a compreensão das discussões realizadas ao longo do trabalho. São apresentados aspectos relacionados ao controle do trânsito urbano, às técnicas aplicadas ao controle do trânsito urbano, baseadas tanto em inteligência artificial quanto em teoria de controle ótimo, e a redes neurais. Contudo, não é o propósito deste capítulo apresentar tais conceitos de forma exaustiva, mas sim de forma introdutória.

2.1. Fundamentos do controle do trânsito urbano

A seguir são apresentados os seguintes fundamentos do controle do trânsito urbano: os níveis de análise, as arquiteturas de controle, e os parâmetros de controle e desempenho que os trabalhos relacionados adotam. Depois, são apresentadas as primeiras abordagens de controle de sinais de trânsito, as quais são precursoras das abordagens atuais e auxiliam sua elucidação.

2.1.1. Níveis de análise

O sistema de trânsito urbano pode ser analisado em diferentes níveis: macro-, meso-, micro- e submicroscópico (KUMAR et al., 2014). A diferença entre esses níveis de análise é a maneira 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.

A Figura 2 ilustra o nível de análise submicroscópico, que considera a dinâmica interna de cada veículo – como a dinâmica do volante, dos pneus e do motor – para definir o comportamento dos veículos e, assim, do trânsito urbano. O nível microscópico, ilustrado na Figura 3, também considera a dinâmica individualizada dos veículos, mas por meio de suas variáveis globais, como as dimensões d_x , d_y , a posição nas coordenadas x_c , y_c , a velocidade v e a aceleração a.



Figura 2 – Modelo do veículo no nível de análise submicroscópico do trânsito urbano

Fonte: autoria própria



Figura 3 – Modelo do veículo no nível de análise microscópico do trânsito urbano

Fonte: autoria própria

O nível mesoscópico trata veículos próximos como uma unidade e se baseia nas variáveis globais do pelotão de veículos, como posição *x*, velocidade *v* e aceleração *a*, o que é apresentado na Figura 4. Um exemplo de modelo mesoscópico é o modelo linear por partes, proposto por Prikryl (2013), por meio do qual pode ser considerado, entre outros atributos, o período de aceleração de um pelotão de veículos após a abertura do semáforo.

A Figura 5 ilustra o nível de análise macroscópico do trânsito urbano, no qual cada intersecção entre vias é tratada como um nó da rede urbana. Nessa escala, as variáveis consideradas são a quantidade de veículos em cada nó *q* e os fluxos de veículos entre os nós *f*. Os modelos macroscópicos utilizados em controle se baseiam na lei de conservação dos veículos (HOMOLOV'A; NAGY, 2005), criada a partir do paradigma *store-and-forward* (armazenar-e-encaminhar) (GAZIS; POTTS, 1963), e que pode ser representada pela eq.(1). Na equação, a quantidade de



Figura 4 – Modelo dos veículos no nível de análise mesoscópico do trânsito urbano

Fonte: autoria própria



Figura 5 – Modelo dos veículos no nível de análise macroscópico do trânsito urbano

Fonte: autoria própria

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.

$$q^{t+1} = q^t + \sum_{i}^{N} f_i - \sum_{j}^{M} f_j$$
 (1)

2.1.2. Arquiteturas de controle

Em sistemas que possuem subsistemas, pode-se adotar uma abordagem centralizada, hierárquica, ou distribuída para defini-los e controlá-los (VRANCKEN; SOARES, 2007; ORTJOHANN et al., 2011; PUIG; OCAMPO-MARTINEZ; OCA, 2012; FREJO; CAMACHO, 2012; LIN; LING; XI, 2013). No caso do sistema de trânsito urbano, divide-se usualmente o sistema de forma que sua unidade básica seja uma intersecção entre vias, como analisado em (CASTRO; MARTINI; HIRAKAWA, 2013). Uma comparação da estrutura de controle centralizada com as estruturas de controle distribuída e hierárquica (semidistribuída) está ilustrada na Figura 6, na qual c_i são os controladores presentes em cada uma das *i* intersecções controladas.

Enquanto na estrutura de controle centralizada todos os controladores se comunicam com um controlador central, o qual é responsável pela tomada de decisões, na estrutura de controle distribuído cada controlador se comunica com os





Controle distribuído

Fonte: autoria própria

controladores de intersecções vizinhas e é responsável pelas decisões acerca da intersecção que ele controla. Por sua vez, na estrutura hierárquica os controladores podem se comunicar com seus vizinhos e com controladores de níveis intermediários, que podem agregar informações locais, regionais ou globais e desempenhar diferentes funções. Nesse caso, a tomada de decisão é distribuída para cada tipo de controlador conforme seu papel na arquitetura de controle proposta.

2.1.3. Parâmetros de controle e desempenho

Para controlar os semáforos de uma intersecção entre vias, determina-se a duração do ciclo semafórico e do tempo de verde de cada fase semafórica, os quais são, segundo Diakaki (1999) e Papageorgiou (2004), os fatores com maior influência no controle de uma intersecção. Cada método de controle se baseia em um conjunto de variáveis do trânsito urbano, como as quantidades e os fluxos de veículos em cada faixa, ou em suas predições a respeito dessas variáveis, para tomar suas decisões. Além disso, alguns métodos que controlam intersecções consecutivas, ou redes urbanas, determinam também atrasos (*offsets*) entre intersecções para sincronizar suas fases e formar ondas verdes (BATISTA JUNIOR; COUTINHO, 2013). A Figura 1, do Capítulo 1, ilustra o ciclo de funcionamento de um conjunto de semáforos em uma intersecção com duas fases.

Para avaliar o desempenho das soluções de controle são comparados alguns de seus índices, como atraso médio dos veículos, tempo médio de viagem, velocidade média, tamanho máximo de fila e quantidade máxima de veículos, de acordo com os objetivos dos autores. Dessa maneira, define-se eficiência de controle do trânsito urbano como uma medida do desempenho do método de controle empregado segundo o índice adotado (DIAKAKI, 1999). Tais índices são definidos como

- atraso médio: média do tempo adicional que os veículos necessitam para percorrer seus trajetos em comparação ao tempo que eles necessitariam caso não houvesse semáforos no trajeto;
- tempo médio de viagem: média do tempo que os veículos necessitam para percorrer seus trajetos;
- velocidade média: média das velocidades médias dos veículos após completarem seus trajetos;

- tamanho máximo de fila: maior fila de veículos presente em qualquer uma das faixas durante toda a simulação;
- quantidade máxima de veículos é a maior quantidade total de veículos presente nas faixas que compõe a intersecção durante toda a simulação.

Na próxima seção, são apresentadas as primeiras abordagens de controle do trânsito urbano e suas contribuições, as quais formam a base de abordagens mais sofisticadas do controle desse sistema, revisadas no Capítulo 3.

2.1.4. Primeiras abordagens

Zhao, Dai e Zhang (2012) dividem a história do controle de sinais de trânsito em três fases: controle com tempos prefixados; controle adaptativo; e controle inteligente. Nesta subseção, são apresentados métodos relativos às duas primeiras fases, enquanto no Capítulo 3 são apresentados os trabalhos referentes à última fase e ao estado da arte na área de controle de sinais de trânsito. A fase nomeada por Zhao, Dai e Zhang (2012) de 'controle inteligente' é estendida neste trabalho para abranger o estado da arte de forma mais completa, compreendendo duas etapas: soluções de controle baseados em inteligência artificial, as quais fazem parte da classificação de Zhao, Dai e Zhang (2012); e soluções de controle baseados na teoria de controle ótimo, não presentes no trabalho dos autores, mas que possuem contribuições significativas para o controle do trânsito urbano.

As primeiras abordagens de controle de sinais de trânsito se basearam na elaboração de métodos para calcular tempos fixos para os ciclos dos semáforos de maneira a reduzir o tempo de viagem dos veículos (WEBSTER, 1958; MILLER, 1963). Apesar de não fazerem mais parte do estado da arte em controle do trânsito urbano, tais métodos são aplicados em intersecções nas quais não há a infraestrutura necessária de sensoriamento e controle para a aplicação de um método de controle adaptativo ou inteligente. Como a maior parte das intersecções de cidades não está apta a adotar métodos de controle adaptativos ou inteligentes, as abordagens apresentadas nesta seção são, ainda hoje, as mais utilizadas. Além disso, os princípios utilizados por essas abordagens, como o de minimizar a quantidade de paradas dos veículos para reduzir seus tempos de viagem, formam a base das propostas de controle adaptativo e inteligente.
O método *Traffic network study tool* (TRANSYT) (ROBERTSON, 1969) utiliza um algoritmo de otimização do tipo *hill-climbing* (baseado no gradiente da função objetivo) para determinar o melhor plano de tempos fixos a partir de variáveis de entrada, como: topologia da rede urbana, fluxos de saturação das vias, duração mínima do tempo de verde de cada semáforo, e um plano inicial de tempos fixos dos semáforos da rede urbana. Outra abordagem, proposta por Little (1966) e estendida por Gartner et al. (1991), se baseia na determinação de tempos fixos com o objetivo de sintonizar a abertura dos semáforos vizinhos com pequenos atrasos (*offsets*) em ruas principais, formando, assim, ondas verdes e reduzindo a quantidade de paradas dos veículos. Entretanto, nenhum desses métodos considera o estado atual do sistema de 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.

Métodos adaptativos de controle dos sinais de trânsito adequam seu funcionamento de acordo com variações no volume de trânsito e em sua distribuição. Os primeiros métodos adaptativos, também chamados de 'acionados por veículos', consistem em tomar a decisão de estender, ou não, o tempo de verde dos semáforos a partir da quantidade de veículos medidos por sensores presentes nas ruas de uma única intersecção, sem informações de intersecções vizinhas, como é o caso do LHOVRA (PETERSON; BERGH; STEEN, 1986) e do *Microprocessor Optimised Vehicle Actuation* (MOVA) (PEIRCE; WEBB, 1990). A capacidade adaptativa desses métodos de controle provê soluções adequadas em relação ao dinamismo do trânsito urbano, e é o princípio comum de todos os métodos de controle inteligente.

O método *Split, Cycle, Offset Optimization Technique* (SCOOT), proposto por Hunt, Robertson e Bretherton (1982), avalia a quantidade de veículos a uma distância da intersecção entre vias e, com essa informação, prediz o perfil do fluxo de veículos que chegará aos semáforos. A predição de todas as vias da intersecção é comparada às estimativas dos fluxos de partida dos veículos quando o semáforo está aberto para determinar quais fases dos semáforos terão seu tempo de verde aumentado e quais terão seu tempo de verde reduzido. A alteração dos tempos de verde e vermelho dos semáforos é pequena e gradual para garantir a adaptabilidade do sistema, mas sem provocar alterações bruscas nos fluxos de veículos e interferir, assim, nas predições de intersecções vizinhas. Outro método adaptativo é o *Sydney Coordinated Area Traffic System* (SCATS) (LOWRIE, 1982), que determina os tempos de verde e vermelho dos semáforos com base no nível de saturação das intersecções. A arquitetura do SCATS é hierárquica, com dois níveis de controle: tático e estratégico. No nível tático, controladores locais agem em cada intersecção com o objetivo de aumentar a reatividade do sistema. Uma de suas funções é a de pular fases dos semáforos caso não haja demanda de veículos no momento em que elas deveriam estar ativas. O nível estratégico é responsável pela determinação da duração dos ciclos e da distribuição das fases dos semáforos, assim como pela coordenação entre semáforos de diferentes intersecções. Ao contrário do SCOOT, que busca uma solução ótima para a minimização do tempo de viagem dos veículos a cada ciclo de controle, o SCATS procura ser mais consistente, uniformizando o nível de saturação nas ruas e, assim, reduzindo a propagação do trânsito (WOLSHON; TAYLOR, 1999).

Por serem métodos de controle que possuem um controlador centralizado, o SCOOT e o SCATS recebem informações sobre todas as intersecções durante o processo de tomada de decisão acerca da temporização dos semáforos, sendo chamados de 'responsivos ao trânsito'. Ambos os métodos de controle são comercializados por empresas, o que os tornou os métodos de controle adaptativo mais utilizados no mundo, com o SCOOT presente em mais de 200 localidades e o SCATS em mais de 50 (ZHAO; TIAN, 2012). Entretanto, apesar de serem adaptativos, eles têm uma limitação em sua capacidade de reação às variações no estado do trânsito, e, assim, em sua eficiência de controle. A causa dessa limitação é o tempo necessário para agregar e processar os dados provenientes de todas as intersecções da rede urbana em suas estruturas centralizadoras.

2.2. Fundamentos das técnicas aplicadas ao controle do trânsito urbano

Esta seção apresenta, de forma introdutória, as técnicas utilizadas pelas propostas classificadas como controle inteligente, as quais fazem parte do estado da arte do controle do trânsito urbano. Os métodos de controle inteligente adotam uma arquitetura de controle distribuída com o objetivo de aumentar a velocidade da tomada de decisão e, por conseguinte, melhorar a eficiência de controle.

2.2.1. Técnicas baseadas em inteligência artificial

2.2.1.1. Lógica difusa

A lógica difusa (ou nebulosa), proposta por Zadeh (1965), aborda o aspecto vago, impreciso, da informação ao mapear valores numéricos de variáveis em termos linguísticos, assim como feito pelos seres humanos (BEDE, 2013). Por exemplo, uma temperatura ambiente (variável) de 40 graus Celsius (valor numérico) é considerada quente (termo linguístico), enquanto que, caso a temperatura ambiente fosse de 10 graus Celsius, ela seria considerada fria. Outra possibilidade é considerar uma temperatura de 15 graus Celsius como 70% pertinente ao termo linguístico 'frio' e 30% pertinente ao termo linguístico 'amena'.

De acordo com o modelo de Mamdani (1974), um sistema difuso de controle pode ser dividido em três etapas, como ilustrado pela Figura 7. A etapa de fuzzificação determina o grau de pertinência de cada entrada numérica do sistema em relação a cada termo linguístico. Com essa finalidade, são utilizadas funções de pertinência, as quais podem ser triangulares, trapezoidais ou Gaussianas, dentre outras, como ilustrado na Figura 8. A escolha de qual tipo de função de pertinência utilizar depende de quantos termos linguísticos são desejados e de qual é a relação entre a variável de entrada e os termos linguísticos adotados.

A partir dos graus de pertinência de cada variável de entrada do sistema, a máquina de inferências aplica o raciocínio desejado, cujo resultado é composto por termos linguísticos decorrentes do conjunto de regras lógicas (do tipo *if-then*) préformuladas. Exemplos de regras são: 'se (*if*) a temperatura ambiente (variável de entrada) é baixa (termo linguístico), então (*then*) o calor gerado pelo condicionador







Figura 8 – Funções de pertinência de um sistema difuso de controle

Fonte: autoria própria

de ar (variável de saída) deve ser alto (termo linguístico)'; e 'se a temperatura ambiente é baixa e o ambiente possui muitas pessoas (segunda variável de entrada), então o calor gerado pelo condicionador de ar deve ser médio'.

Os graus de pertinência dos termos linguísticos de saída são atribuídos de acordo com as regras utilizadas nas inferências, como discutido por Bede (2013). No caso de um sistema com uma variável de entrada e uma variável de saída, o grau de pertinência do termo linguístico de saída corresponde àquele do de entrada. No entanto, em sistemas com mais de uma variável de entrada, o grau de pertinência do termo linguístico de saída pode ser: o valor máximo dentre os graus de pertinência das entradas; o valor mínimo dentre os graus de pertinência das entradas; o valor mínimo dentre os graus de pertinência das entradas.

A etapa de defuzzificação da lógica difusa converte os graus de pertinência dos termos linguísticos de saída em valores numéricos, tratáveis pelo sistema de controle. Assim como no caso das variáveis de entrada, também utiliza-se funções de pertinência para determinar o valor numérico das variáveis de saída. Dentre os métodos de defuzzificação estão o do centro de gravidade (mais utilizado), o de centro da área, o de valor esperado, e o de média dos máximos, os quais ponderam – cada qual com sua fórmula – os graus de pertinência e as funções de pertinência

para determinar a saída numérica do sistema (BEDE, 2013). Dessa maneira, o valor numérico obtido na etapa de defuzzificação é utilizado pelo atuador do sistema e o ciclo de controle se repete.

Um dos trabalhos revisados no Capítulo 3, o de Gokulan e Srinivasan (2010), adota uma extensão da lógica difusa, denominada lógica difusa tipo-2, em sua abordagem para o controle do trânsito urbano. Em vez de atribuir valores absolutos às entradas do sistema, a lógica difusa tipo-2, proposta por Zadeh (1975) e desenvolvida por Karnik, Mendel e Liang (1999), atribui verdades parciais às entradas como forma de lidar com as incertezas relacionadas a seus valores. Dessa maneira, tanto a fuzzificação quanto o processo de inferências da lógica difusa tipo-2 possuem uma dimensão adicional, que trata da amplitude de valores de cada entrada e cujo efeito nas funções de pertinência é ilustrado pela Figura 9. A lógica difusa tipo-2 possui, então, uma maior complexidade computacional e uma etapa adicional em seu ciclo de funcionamento (GOKULAN; SRINVASAN, 2010). Tal etapa consiste em reduzir os graus de pertinência do tipo-2 dos termos linguísticos de saída da máquina de inferências em graus de pertinência do tipo-1, que consideram verdades parciais apenas para as variáveis de estado do sistema e que compõe a entrada da etapa de defuzzificação.

2.2.1.2. Algoritmos evolucionários

Algoritmos evolucionários se baseiam em mecanismos heurísticos de busca para





Fonte: Gokulan e Srinivasan (2010)

achar os pontos ótimos de um sistema, simplificando o problema de otimização de sistemas não lineares (ZHAO; DAI; ZHANG, 2012). Os algoritmos genéticos, base comum dos algoritmos evolucionários abordados neste trabalho, representam as soluções possíveis do sistema a ser otimizado por meio de cromossomos, cujos alelos representam características ou variáveis desse sistema. Tais alelos são alvo de mutações e cruzamentos genéticos a cada iteração do algoritmo, com a finalidade de modificar as variáveis do sistema em busca de soluções ótimas. Neste processo, semelhante à seleção natural biológica, as soluções possíveis são avaliadas por um parâmetro de desempenho chamado *fitness* ou aptidão, a qual é computada a cada iteração desde a população inicial, e evolui até que as melhores soluções sejam obtidas.

A etapa inicial do algoritmo genético consiste na geração aleatória de uma população de cromossomos (soluções possíveis). Os alelos desses cromossomos são, então, objeto de cruzamentos genéticos e de mutações a cada nova iteração do algoritmo para gerar uma nova população de cromossomos. Uma vantagem dessa abordagem é a busca de soluções em paralelo, visto que cada nova população de cromossomos gera e avalia diversas soluções possíveis simultaneamente. Pares de cromossomos (pais) são selecionados de forma aleatória para terem parte de seus alelos intercambiados entre si (cruzamento genético), originando novos cromossomos (filhos) com características diferentes, conforme ilustrado na Figura 10. Após os cruzamentos genéticos, alguns cromossomos filhos são selecionados aleatoriamente, com uma probabilidade pré-definida, e têm alelos modificados, também de forma aleatória. Essas duas etapas de modificações dos alelos permitem que soluções ótimas locais ruins sejam evitadas e novas e melhores soluções sejam obtidas.

A aptidão de cada novo cromossomo gerado é determinada por uma função objetivo, a qual é definida de acordo com cada aplicação. Uma opção comumente utilizada é a função dos quadrados mínimos (RUSSELL; NORVIG, 2009), cujas variáveis são os parâmetros de desempenho do sistema a ser otimizado. A última etapa de cada iteração do algoritmo genético consiste em selecionar quais cromossomos farão parte da próxima geração, tornando-se os novos cromossomos pais. O parâmetro principal dessa seleção é a aptidão dos cromossomos, mas a composição da nova população também depende de um fator probabilístico e da fração escolhida de cromossomos pais e filhos. As frações de cromossomos pais e





cromossomos pais

cromossomos filhos

Fonte: autoria própria

filhos determinam quantos cromossomos de cada tipo farão parte da próxima geração. Por sua vez, o fator probabilístico de cada cromossomo, o qual é proporcional à sua aptidão, permite que cromossomos com baixa aptidão tenham uma chance de ser selecionados para a próxima geração, garantindo que soluções ótimas que estejam próximas a esse cromossomo possam ser encontradas.

Gokulan e Srinivasan (2014), cuja proposta é apresentada com mais detalhes no Capítulo 3, adotaram uma variação do algoritmo genético, o aprendizado evolucionário simbiótico, para otimizar os parâmetros de seu método de controle do trânsito urbano. Moriarty e Miikkulainen (1996) definem o aprendizado evolucionário simbiótico como um processo de coevolução, no qual indivíduos cooperam entre si para evoluir. Nessa abordagem, os cromossomos representam soluções parciais, em vez de soluções finais, para o problema de otimização; e as combinações de soluções parciais formam as soluções finais, que são então avaliadas. Dessa maneira, o aprendizado evolucionário simbiótico possui uma etapa adicional, a de combinação de soluções parciais de tipos diferentes, com o objetivo de explorar o espaço de soluções de uma maneira mais ampla.

2.2.1.3. Aprendizado por reforço

Um controlador (ou agente) baseado no método de aprendizado por reforço – mais especificamente, no *Q-learning* – age de acordo com o estado atual do sistema de forma a maximizar o reforço recebido em seu período de atividade. Para determinar cada ação, o controlador utiliza a função ação-utilidade, ou função-Q, representada em forma de tabela. Cada par ação/estado do sistema possui um valor Q (reforço) na tabela, o qual é correspondente à utilidade esperada de realizar uma determinada ação em um determinado estado do sistema. De acordo com cada estado do sistema, o controlador seleciona a ação que possui o maior valor Q, de forma a maximizar o reforço recebido. Após a realização da ação, o controlador atualiza sua função-Q conforme o impacto que aquela ação causou ao sistema. Dessa maneira, o controlador aprende continuamente a realizar ações cada vez melhores, mapeando seu comportamento sem a necessidade de um modelo matemático do sistema controlado.

A equação que determina a atualização do valor Q de um par [ação *a*, estado do sistema *s*] está representada pela eq.(2) (MITCHELL, 1997). Na equação, *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*'. Portanto, o segundo termo da equação incrementa o valor Q de acordo com a ação *a*' que possui o maior reforço no estado *s*', o qual é ponderado por γ , que determina o grau de imediatismo do aprendizado. Valores mais altos de γ têm como consequência um aprendizado com foco maior no reforço futuro, enquanto abordagens que adotam valores mais baixos de γ focam mais no reforço imediato de cada ação.

$$Q(s,a) = r(s,a) + \gamma \max_{a'} Q(s',a')$$
⁽²⁾

Como forma de reduzir a complexidade computacional do Q-learning – visto que a alta complexidade computacional é uma desvantagem do método – autores adotam funções de aproximação para representar a tabela que mapeia os valores Q (PRASHANTH; BHATNAGAR, 2011). Outra abordagem para aumentar o desempenho do método é considerar um fator aleatório no início da ação do controlador, o que diminui a importância dos reforços na seleção de ações e aumenta o nível de exploração do espaço de soluções (RUSSELL; NORVIG, 2009).

2.2.1.4. Redes neurais artificiais

Redes neurais artificiais imitam a função dos neurônios biológicos do cérebro e de suas conexões, simulando a maneira com que o cérebro processa dados; sua principal característica é identificar e memorizar padrões por meio da atualização dos pesos das conexões entre os neurônios (sinapses) (ZHAO; DAI; ZHANG, 2012). Em redes neurais artificiais a atividade eletroquímica dos neurônios é representada por equações matemáticas (RUSSELL; NORVIG, 2009). Os neurônios artificiais, unidades de processamento das redes neurais artificiais, produzem um sinal de saída caso a combinação linear de suas entradas ultrapassem um limiar (suave ou rígido). A Figura 11 ilustra um neurônio artificial, exemplificando suas entradas I_1 , I_2 e I_3 , seus pesos sinápticos w_1 , w_2 e w_3 , sua ativação A, e sua saída O.

A soma ponderada das entradas de um neurônio constitui sua ativação *A*, conforme representado pela eq.(3). Na equação, w_i é o peso de cada sinapse *i*, que representa a força relativa da sinapse, enquanto I_i é o valor do sinal de entrada, que pode variar de 0 a 1.

$$A = \sum_{i=1}^{n} w_i I_i \tag{3}$$

Quando a ativação de um neurônio excede um valor limite, o neurônio fica ativo por um período e produz um sinal de saída de acordo com a função de ativação adotada. A função de ativação pode ser, dentre outras opções menos utilizadas, tanto uma função degrau quanto uma função linear por partes ou uma função







Figura 12 - Funções de ativação



Fonte: autoria própria

sigmoide, as quais concedem para as redes neurais artificiais a propriedade de representar funções não lineares. A Figura 12 ilustra tais funções de ativação e mostra suas respectivas equações.

A topologia de uma rede neural artificial é definida com base no problema em questão. Quanto maior a complexidade do problema, maior a quantidade necessária de neurônios para representá-lo. Problemas mais simples podem ser representados por redes neurais artificiais que possuem apenas neurônios de entrada e neurônios de saída. Tal topologia é capaz de representar funções lineares e está ilustrada na Figura 13. Com o objetivo de representar funções não lineares, devem ser adicionadas camadas intermediárias de neurônios, ou camadas escondidas, como ilustrado também na Figura 13. Segundo 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.

A quantidade de neurônios de entrada de uma rede neural artificial é equivalente à quantidade de variáveis de entrada do problema por ela representado. Do mesmo modo, a quantidade de neurônios de saída equivale à quantidade de variáveis de saída do problema. O número de neurônios das camadas intermediárias é comumente determinado de forma empírica (RUSSELL; NORVIG, 2009). Nessa determinação, há um compromisso entre convergência e generalização e procura-se evitar tanto o *overfitting* (sobre ajuste) quanto o *underfitting* (sub ajuste).



Figura 13 – Topologia das redes neurais artificiais

Fonte: autoria própria

O *overfitting* ocorre quando a rede neural artificial possui mais neurônios em camadas intermediárias do que o necessário, fazendo com que a complexidade da rede neural artificial utilizada exceda a complexidade do problema a ser representado pela rede. Nesse caso, perde-se a capacidade de generalização, pois a rede neural artificial converge ao comportamento específico dos dados de treinamento e não é mais capaz de representar o comportamento geral do problema. Por sua vez, o *underfitting* ocorre quando a quantidade de neurônios da camada intermediária não é suficiente para representar de forma geral o comportamento do problema, o representando apenas de forma simplificada.

Com o objetivo de realizar o treinamento da rede neural artificial, é utilizado um conjunto de dados composto por entradas e saídas do problema em questão. Não há uma regra para definir o tamanho do conjunto de dados. Entretanto, este deve ser grande o suficiente para representar o comportamento geral do problema (RUSSELL; NORVIG, 2009). O conjunto de dados deve ser dividido em duas partes: conjunto de treinamento e conjunto de validação. O conjunto de treinamento é

utilizado para modificar os pesos sinápticos da rede neural artificial e ensiná-la o comportamento do problema. Dessa maneira, os dados de entrada são apresentados à rede neural artificial e suas saídas são comparadas às saídas reais do problema, originando um erro, que é utilizado para recalcular os pesos sinápticos da rede.

O conjunto de validação é utilizado para quantificar o erro da rede neural artificial ao tentar predizer o comportamento do problema a partir de dados que não foram previamente apresentados à rede. Interrompe-se o treinamento quando o erro do conjunto de validação possuir o menor valor, o que indica que o compromisso ideal entre convergência e generalização foi alcançado. O algoritmo mais comum de treinamento de redes neurais artificiais é o *backpropagation*, por sua capacidade de determinar os pesos sinápticos das camadas intermediárias da rede neural artificial, atribuindo a cada sinapse a parcela do erro total pela qual ela é responsável (RUSSELL; NORVIG, 2009).

2.2.1.5. Sistemas multiagente

Um agente é um sistema computacional que está situado em um ambiente e que é capaz de agir de forma autônoma nesse ambiente para cumprir os objetivos designados a ele (WOOLDRIDGE, 2009). Sistemas multiagente são utilizados nos casos em que é possível dividir um problema complexo em subproblemas, os quais são resolvidos por múltiplos agentes. Os subproblemas podem ser modulares e utilizar agentes semelhantes para reduzir a escala do problema original e resolvê-lo de forma paralela e distribuída, ou ser diferentes e utilizar agentes específicos para solucionar cada subproblema. Os agentes atuam em um mesmo ambiente e podem agir de forma competitiva ou cooperativa em relação a outros agentes para solucionar seus respectivos subproblemas. Em ambos os casos o objetivo é resolver o problema original da melhor forma possível por meio do resultado final da ação conjunta de todos os agentes.

As abordagens de controle do trânsito urbano baseadas em sistemas multiagente solucionam problemas de grande escala de controle e coordenação, os quais métodos tradicionais de controle, com arquitetura centralizada, têm dificuldade em resolver (ZHAO; DAI; ZHANG, 2012). Por esse motivo, a arquitetura de controle da teoria de sistemas multiagente é utilizada em associação a outros métodos

computacionais para realizar o controle distribuído do trânsito urbano, como feito por Gokulan e Srinivasan (2010) com o controlador difuso, por Abdoos, Mozayani e Bazzan (2011) com o aprendizado por reforço, por Srinivasan, Choy e Cheu (2006) com a rede neural artificial, e por Oliveira e Camponogara (2010) com o controle preditivo baseado em modelo. Na arquitetura de sistemas multiagente do trânsito urbano que esses trabalhos adotam, cada intersecção é representada por um agente, que controla seus semáforos. O agente de uma intersecção se comunica com agentes vizinhos (controladores de intersecções 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.

2.2.2. Técnicas baseadas na teoria de controle ótimo

A teoria de controle ótimo se propõe a descrever sistemas dinâmicos com equações diferenciais e, então, minimizar funções de custo como forma de atingir a eficiência ótima de controle de cada sistema de acordo com seus objetivos. Os métodos mais comumente aplicados ao controle do trânsito urbano são a programação dinâmica, o controle preditivo baseado em modelo e a contrapressão.

2.2.2.1. Programação dinâmica

Ao contrário das técnicas de programação linear e não-linear, que resolvem problemas de otimização em apenas um estágio (ou fase), a programação dinâmica resolve problemas de decisão multiestágio, possuem variáveis que interdependentes, por meio de sua conversão em uma série de problemas de estágio único (HEUNG; HO; FUNG, 2005). Problemas de um estágio possuem uma única função de custo (ou função objetivo), a ser minimizada ou maximizada, e uma série de restrições. Por sua vez, na programação dinâmica são utilizadas mais de uma função de custo. Além disso, na programação linear, as equações referentes à função de custo e às restrições são lineares, enquanto na programação não-linear e na programação dinâmica tais equações podem possuir não-linearidades.

O principal aspecto da programação dinâmica é a equação de Hamilton–Jacobi– Bellman (BELLMAN, 1957), uma equação diferencial parcial que fornece o valor ótimo da função de custo na otimização de um sistema dinâmico (MURRAY et al., 2002). A programação dinâmica calcula a equação de Hamilton–Jacobi–Bellman de forma sequencial considerando todos os estágios do problema de otimização para obter as ações que levam o sistema de um estado atual a um estado desejado (CAI; WONG; HEYDECKER, 2009). No controle de sinais de trânsito, a função de custo é formada por um parâmetro de desempenho, como o tempo de viagem dos veículos, que é determinado por um modelo macroscópico do trânsito urbano. Como a solução da equação de Hamilton–Jacobi–Bellman de forma direta é infactível, por causa de sua complexidade computacional, métodos de controle baseados em programação dinâmica utilizam técnicas de aproximação para realizar o controle em tempo real.

2.2.2.2. Controle preditivo baseado em modelo

O conceito básico do controle preditivo baseado em modelo – ou model predictive control – é utilizar um modelo dinâmico do sistema para predizer seu comportamento, otimizando as predições obtidas a partir do estado atual do sistema para tomar a melhor decisão. Apesar de obter uma sequência ótima de ações de controle, apenas a primeira ação é realizada, e o processo de predição se repete com o novo estado do sistema. Camacho e Bordons (2004) definem os principais aspectos do controle preditivo baseado em modelo como: o modelo que descreve a dinâmica do sistema; a função de custo, utilizada para avaliar as predições obtidas com o modelo; e o horizonte de predição, que determina o intervalo de tempo futuro a ser considerado na otimização. 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.

Tipicamente, o controle preditivo baseado em modelo é utilizado com uma arquitetura centralizada, mas ele também pode ser aplicado com uma arquitetura de controle distribuída (CAMPONOGARA et al., 2002). Com essa arquitetura, o problema original de otimização é dividido em um conjunto de subproblemas, assim como em sistemas multiagente. Cada subproblema é resolvido de forma local, mas com troca de informações entre subproblemas que possuam relações de interdependência. Nesses casos, quando um subproblema é resolvido, a decisão tomada é comunicada aos subproblemas de interesse, pois essa decisão afeta a resolução de tais subproblemas. Dessa maneira, cada subproblema atualiza sua

decisão com base nas informações recebidas dos subproblemas interdependentes, gerando um processo de convergência para a solução ótima global.

2.2.2.3. Contrapressão

Abordagens baseadas em contrapressão – ou *backpressure* – têm como objetivo maximizar o fluxo de uma rede ao considerar o nível de congestionamento de seus nós para tomar as decisões de controle. A contrapressão surgiu na área de redes de comunicação para otimizar os fluxos de dados (TASSIULAS; EPHREMIDES, 1992) e sua aplicação na área de trânsito urbano utiliza os mesmos princípios para melhorar o fluxo de veículos (WONGPIROMSARN et al., 2012). O conceito central da proposta é priorizar fluxos com alta pressão em sua origem e baixa pressão em seu destino, evitando a formação de gargalos e garantindo um fluxo global melhor. Além disso, duas características da contrapressão favorecem sua aplicação (GREGOIRE et al., 2015): a arquitetura de controle distribuído; e a baixa complexidade computacional (*O*(1) para cada intersecção).

O algoritmo de contrapressão computa, inicialmente, a pressão de todos os conectores entre os nós da rede. No caso do trânsito urbano, essa pressão é equivalente às filas de veículos presentes nas vias que passam pelas intersecções controladas. Depois, a pressão associada a cada fluxo de veículos que atravessa a intersecção controlada W_{ab} é calculada pela diferença entre a pressão da via da qual o fluxo parte Q_a e a pressão da via para a qual o fluxo segue Q_b , conforme representado na eq.(4) (WONGPIROMSARN et al., 2012). Esse valor é utilizado para definir quais fluxos possuem maior pressão e são prioritários e, por conseguinte, que fase semafórica deve ser ativada. Dessa maneira, a fase semafórica ativada é a que permite o maior alívio de pressão na intersecção em questão.

$$W_{ab}(t) = Q_a(t) - Q_b(t) \tag{4}$$

3. TRABALHOS RELACIONADOS

Este capítulo aborda os trabalhos relacionados tanto ao controle do trânsito urbano quanto a redes neurais bioinspiradas. Os trabalhos relacionados ao controle do trânsito urbano estão divididos em duas categorias: soluções baseadas em inteligência artificial e soluções baseadas na teoria de controle ótimo.

3.1. Trabalhos relacionados ao controle do trânsito urbano

3.1.1. Soluções baseadas em inteligência artificial

As soluções baseadas em inteligência artificial englobam o uso de sistemas difusos (*fuzzy*), algoritmos evolucionários, aprendizado por reforço, redes neurais artificiais e sistemas multiagente, cuja principal característica comum é a de serem orientados por dados. A dificuldade em obter uma solução ótima em tempo real para sistemas dinâmicos complexos por meio de modelos matemáticos justifica o uso desse tipo de abordagem, que procura melhorar a eficiência do sistema por meio da modelagem e controle baseados nos dados adquiridos; além disso, como cada alternativa computacional possui vantagens e desvantagens, é comum a combinação de conceitos para o controle de sistemas complexos como o trânsito urbano (ZHAO; DAI; ZHANG, 2012). Nas subseções a seguir, os trabalhos revisados estão organizados de acordo com o principal conceito no qual eles são baseados.

3.1.1.1. Lógica difusa

O controle dos sinais de trânsito na lógica difusa, proposta por Zadeh (1965), classifica os valores das variáveis envolvidas em conjuntos, de acordo com funções de pertinência. As vantagens da lógica difusa são: eliminar a incerteza associada à utilização de valores absolutos em sistemas estocásticos; e simplificar a resolução de um problema complexo, ao reduzir sua dimensão e facilitar sua modelagem por usar termos linguísticos. Pappis e Mamdani (1977) elaboraram um controlador baseado em lógica difusa para uma única intersecção de mão simples e duas fases (leste-oeste e norte-sul), que consiste em estender ou não uma fase ativa de acordo com as estimativas de fluxo de veículos em cada rua. Os autores obtiveram

resultados de 10% a 21% melhores em termos de tempo médio de viagem do que um controlador com tempos fixos pré-determinados devido à adaptabilidade do método proposto.

Trabia, Kaseko e Ande (1999) propuseram um controlador baseado em lógica difusa de dois estágios para uma intersecção mais complexa, com quatro fases, o que envolve mais variáveis. No primeiro estágio, o controlador estima a intensidade do trânsito em cada faixa, que é utilizada, no segundo estágio, para decidir se a fase atual deve ser finalizada ou se seu tempo de verde deve ser estendido. Os resultados obtidos em simulações comparativas foram 9,54% melhores do que um método de controle acionado por veículos em termos de tempo médio de viagem. Isso ocorreu, pois o método difuso é mais adaptativo, visto que a única adaptação possível do método comparado é de terminar uma fase caso veículos não fossem detectados.

Lee e Lee-Kwang (1999) adotaram controladores difusos para controlar conjuntos de intersecções de forma distribuída e cooperativa. O método determina a ordem das fases e sua duração para minimizar o tempo médio de viagem dos veículos. Uma limitação importante dos métodos de controle adaptativos até então era a de utilizar sequências fixas de fases, não possibilitando sua ordenação ótima para cada situação, assunto que foi o foco do trabalho de Murat e Gedizlioglu (2005). Além da situação do trânsito em sua intersecção, o controlador difuso pondera dois fatores relacionados às intersecções vizinhas: a sincronização entre fases, para permitir fluxos mais contínuos de veículos ao longo da via; e o nível de saturação das intersecções, para não liberar mais veículos para intersecções que já estejam saturadas. Tal abordagem comprovou as vantagens da cooperação entre controladores por meio de simulações, nas quais obteve resultados de 3,5% a 13,5% melhores em comparação a um método de controle acionado por veículos em termos de tempo médio de viagem para diferentes cenários.

Chou e Teng (2002) também consideraram a influência de intersecções vizinhas no controlador difuso de uma intersecção, mas apenas por meio da sincronização de fases. Os autores propuseram um controlador difuso com o objetivo de melhorar a eficiência de controle, ao considerar mais variáveis do sistema de trânsito, como o número de intersecções consecutivas, o número de faixas de uma via, o comprimento das vias e o comprimento dos veículos, e ao reduzir sua complexidade, por adotar menos regras de controle, apenas nove, contra 25 de Pappis e Madami

(1977). Os autores demonstraram com simulações comparativas que tanto um controlador com tempos-fixos, quanto um controlador difuso sem sincronização entre fases de intersecções vizinhas apresentam congestionamentos em diversos cenários, nos quais a abordagem de Chou e Teng (2002) mantém a fluência dos fluxos de veículos.

Qiao, Yang e Gao (2011) propuseram um modelo de controle difuso em dois estágios, um que seleciona a fase semafórica ativa, e outro que determina o tempo de verde da fase selecionada, que considera, além da eficiência de controle, a justiça entre os motoristas. O parâmetro justiça foi incluído no modelo para evitar que a otimização do tempo médio de viagem ocorresse em detrimento de alguns veículos, que seriam prejudicados em favor do ótimo global, e é determinado a partir da variação do tempo de viagem entre os veículos. A abordagem obteve melhores resultados do que um método de controle acionado por veículos e do que o modelo difuso proposto por Pappis e Madami (1977) em simulações comparativas tanto em termos de variação do tempo de viagem (justiça) quanto em termos de tempo médio de viagem dos veículos (eficiência). A contribuição principal do trabalho é a análise da justiça entre os motoristas no processo de tomada de decisão, mas tal atributo também pode ser incorporado em modelos de controle de forma mais direta, porém menos efetiva, com a estipulação de tempos máximos de duração das fases, como feito em trabalhos prévios (PAPPIS; MANDAMI, 1977; TRABIA; KASEKO; ANDE, 1999).

Gokulan e Srinivasan (2010) elaboraram um controlador geométrico difuso tipo-2, capaz de tratar os vários níveis de incerteza das entradas e da base de regras do sistema de controle de sinais de trânsito. O controlador difuso tipo-2, proposto por Zadeh (1975) e desenvolvido por Karnik, Mendel e Liang (1999), incorpora as incertezas associadas às entradas do sistema ao estipular para elas uma gama de verdades parciais, ao invés de valores absolutos, como ocorre no caso do controlador difuso tipo-1. Controladores difusos tipo-2 apresentaram melhores resultados do que controladores difusos tipo-1 em sistemas com entradas ruidosas não estacionárias (WU; MENDEL, 2002), e sua principal limitação é a complexidade computacional associada à obtenção de uma saída com valor absoluto (KARNIK; MENDEL; LIANG, 1999). No entanto, essa limitação foi superada por meio de um sistema difuso geométrico, que combina o redutor de tipo (de tipo-2 para tipo-1) e o

defuzzificador em um único bloco, reduzindo os requisitos computacionais (COUPLAND; JOHN, 2007).

O controlador geométrico difuso tipo-2 proposto por Gokulan e Srinivasan (2010) é baseado em 27 regras de controle e em três tipos de variáveis de entrada: fila de veículos; fluxo de veículos; e situação das intersecções vizinhas. A abordagem foi comparada ao método Green Link Determining (GLIDE) (KEONG, 1993), que é uma versão modificada do SCATS para aplicação em Cingapura, e ao Hierarchical Multiagent System (HMS) (CHOY; SRINIVASAN; CHEU, 2003; CHOY: SRINIVASAN; CHEU, 2006), que é um sistema de controle semidistribuído baseado em uma rede neural híbrida. Os resultados obtidos nas simulações comparativas demonstraram a superioridade do método proposto por Gokulan e Srinivasan (2010) em termos de tempo médio de viagem e de velocidade média em todos os casos investigados, incluindo cenários com incidentes planejados e não planejados. Segundo os autores, a arquitetura distribuída de controle é um dos motivos que justificam sua superioridade, pois reduz o custo de comunicação presente em arquiteturas centralizadas ou hierárquicas (com diferentes níveis de centralização) e aumenta o nível de cooperação no controle das intersecções.

Odeh et al. (2015) propuseram um controlador difuso de dois estágios para estimar os tempos de verde de cada semáforo em uma cenário com quatro intersecções. O primeiro estágio do controlador possui duas entradas: a quantidade de veículos da via bloqueada pelo semáforo cujo tempo de verde está sendo determinado; e a quantidade de veículos na via que receberá os veículos, caso o semáforo esteja aberto. A segunda entrada impede que veículos sejam liberados para vias que já estejam congestionadas. A saída deste primeiro estágio é a estimativa de tempo de verde do semáforo. O segundo estágio do controlador difuso também possui duas entradas: a saída do primeiro estágio; e a quantidade de veículos na segunda via que receberá veículos com o semáforo aberto, caso ela exista. A saída do segundo estágio do controlador é a estimativa do tempo de verde do semáforo nos casos em que duas vias recebem veículos quando o semáforo está verde.

Em complemento ao controlador difuso, os autores (ODEH et al., 2015) propuseram um algoritmo genético para determinar quais fases estariam ativas em cada intersecção em cada momento, de forma a originar uma coordenação entre as intersecções. Simulações mostraram que o controlador difuso, sem o uso do

algoritmo genético, obteve uma melhora de 5% na quantidade de veículos presentes no cenário investigado em comparação a um controlador com tempos de verde prédeterminados. Ademais, o controlador difuso auxiliado pelo algoritmo genético obteve uma melhora de 34% considerando o mesmo cenário de comparação. Apesar do uso do algoritmo genético aumentar o tempo de computação do controlador em 20 segundos, tal valor é baixo o suficiente para que o algoritmo seja processado dentro do ciclo semafórico e executado a cada novo ciclo.

O controlador difuso é um sistema de raciocínio vago, que não necessita de modelos matemáticos do sistema a ser controlado e que traduz o conhecimento prévio de especialistas sobre o sistema em regras de controle; por esse motivo ele é comumente utilizado em combinação com outros métodos de inteligência computacional, como sistemas multiagente, algoritmos evolucionários e redes neurais (ZHAO; DAI; ZHANG, 2012). Entretanto, o uso de regras lógicas para o controle limita a incorporação de conhecimento sobre a dinâmica das variáveis envolvidas, por causa da complexidade em incluí-las no modelo de controle e do custo computacional adicional. Além disso, a determinação da base de regras e das funções de pertinência dos controladores difusos é empírico, tornando esse processo escopo de trabalhos de otimização (GOKULAN; SRINIVASAN, 2014), e restringindo a eficiência dos controladores de sistemas dinâmicos complexos, cujo ponto ótimo de operação é variável e dependente de variáveis externas não controladas.

3.1.1.2. Algoritmos evolucionários

Gokulan e Srinivasan (2010) concluíram que o uso de algoritmos evolucionários poderia melhorar o desempenho do controlador difuso proposto por meio da otimização das regras de controle e das funções de pertinência elaboradas, como realizado por Schmöcker, Ahuja e Bell (2008), Qiao, Yang e Gao (2011) e Gokulan e Srinivasan (2014). Qiao, Yang e Gao (2011) compararam o desempenho do controlador difuso sem a otimização da base de regras com o controlador difuso com a otimização, demonstrando uma melhora de 8,56% em relação ao tempo médio de viagem dos veículos após o uso do algoritmo genético. Odeh et al. (2015) também utilizaram um algoritmo genético para aumentar o desempenho de um controlador

difuso, mas, em sua proposta, o algoritmo genético atua na seleção das fases semafóricas ativas para aumentar o nível de coordenação entre as intersecções.

Foy, Benekohal e Goldberg (1992) e Ceylan e Bell (2004) propuseram algoritmos genéticos para otimizar os seguintes parâmetros de controle dos semáforos: duração dos ciclos; tempos de verde; e diferença do início do tempo de verde entre semáforos de intersecções vizinhas, para sincronizá-los. Enquanto Foy, Benekohal e Goldberg (1992) apenas verificaram a funcionalidade da aplicação do algoritmo genético para o controle do sistema de trânsito, Ceylan e Bell (2004) compararam seu algoritmo a outro algoritmo de otimização. Os resultados das simulações demonstraram que o método proposto foi 34% superior ao outro algoritmo de otimização. Segundo os autores, o algoritmo genético converge, na maioria dos casos, para ótimos locais, ao invés de convergir para o ótimo global do problema de otimização. Apesar disso, as mutações e os cruzamentos genéticos permitem que ótimos locais ruins sejam evitados e novos e melhores ótimos locais sejam obtidos, o que justifica a superioridade do método proposto.

Gokulan e Srinivasan (2014) propuseram um método de aprendizado evolucionário simbiótico para otimizar os parâmetros do controlador difuso tipo-2 elaborado previamente (GOKULAN; SRINIVASAN, 2010). O aprendizado evolucionário simbiótico é um tipo de algoritmo genético, no qual cromossomos representam soluções parciais, ao invés de soluções finais, e as combinações de soluções parciais formam as soluções finais. Para reduzir a quantidade de combinações de soluções parciais possíveis, os autores adotaram a abordagem de agrupamento proposta por Juang, Lin e Lin (2000), na qual soluções parciais só podem ser combinadas quando pertencentes a grupos distintos. Foram criados dois grupos de soluções parciais: o de funções de pertinência das entradas; e o da base de regras do sistema difuso. O processo evolutivo ocorre da mesma maneira que em algoritmos genéticos convencionais, com mutações e cruzamentos genéticos, mas, no método proposto, a exploração do espaço de soluções é melhor, como demonstram os resultados do trabalho.

Os autores comparam seu método de controle com o controlador geométrico difuso tipo-2 que foi a base para sua proposta (GOKULAN; SRINIVASAN, 2010) e com o mesmo controlador após uma otimização de seus parâmetros por meio de um algoritmo genético convencional. Nas simulações comparativas, o controlador difuso tipo-2 com os parâmetros otimizados por meio de um algoritmo genético

convencional obteve resultados cerca de 10% melhores em termos de tempo médio de viagem e 15% melhores considerando a velocidade média do que o controlador difuso tipo-2 sem otimização em um cenário de simulação de 24 horas. Por sua vez, o controlador proposto pelos autores, com otimização por meio de um algoritmo evolucionário simbiótico, obteve resultados cerca de 3% melhores do que o controlador otimizado pelo algoritmo genético convencional, sendo, além disso, mais consistente ao longo da simulação e necessitando de menos iterações até sua convergência.

Ceylan e Bell (2004), Zhao, Dai e Zhang (2012) e Gokulan e Srinivasan (2014) ressaltam que o tempo de computação da maior parte dos algoritmos evolutivos limita sua utilização a fins de otimização *offline*. A única exceção dentre as abordagens aqui revisadas é a de Odeh et al. (2015), que utiliza um algoritmo genético apenas para determinar a ordem das fases semafóricas. Além disso, métodos de otimização buscam a solução ótima para um problema com base em modelos, o que, no caso de sistemas complexos como o trânsito urbano, não reflete a gama de comportamentos apresentados na realidade, limitando seu desempenho.

3.1.1.3. Aprendizado por reforço

Ao contrário dos algoritmos evolucionários, os métodos de aprendizado em tempo real – como o aprendizado por reforço – possibilitam a otimização do sistema dinâmico durante sua operação. Um controlador baseado no método de aprendizado por reforço age de acordo com o estado atual do sistema, avalia o impacto de suas ações, e recebe reforços positivos ou negativos por cada ação de acordo com o impacto causado ao sistema.

Abdulhai, Pringle e Grigoris (2003) propuseram um algoritmo baseado em Qlearning com o objetivo de reduzir o tempo médio de viagem dos veículos, aprendendo a relação entre as ações do controlador e seus efeitos no sistema de trânsito. Uma vantagem da abordagem é não depender de um modelo matemático do sistema de trânsito – como é o caso de métodos baseados em teoria do controle –, o qual limita o desempenho do controle à precisão do modelo. Outra vantagem é a não necessidade de um treinamento supervisionado prévio, como é o caso de alguns tipos de rede neural artificial. Entretanto, o algoritmo proposto por Abdulhai, Pringle e Grigoris (2003) requer a representação completa (um valor Q para cada combinação possível entre todas as ações e estados) do sistema para seu funcionamento, o que o impede de ser utilizado em redes urbanas. Os autores validaram o algoritmo para o controle de uma única intersecção, pois, como ressaltado por Prashanth e Bhatnagar (2011) e Zhao, Dai e Zhang (2012), sua complexidade computacional cresce exponencialmente com o número de intersecções controladas.

Prashanth e Bhatnagar (2011) propuseram um algoritmo de controle baseado em Q-learning que incorpora a aproximação de funções, o que o permite controlar em tempo real sistemas de trânsito maiores, como em corredores de oito interseccões ou grades de ordem três (com nove intersecções). A aproximação de funções parametriza o cálculo de todos os possíveis valores de Q por meio de um vetor de atributos, que são combinações de ações e estados do sistema. O vetor de atributos possui uma dimensão menor do que o vetor Q original, pois, ao invés de utilizar os valores absolutos dos tempos de verde (ações) e das filas de veículos (estados), os classifica como baixo, médio ou alto, reduzindo as combinações resultantes entre ações e estados. Como Qiao, Yang e Gao (2011), Prashanth e Bhatnagar (2011) também consideram a justica (não prejudicar em demasia alguns motoristas para obter um tempo médio de viagem global menor) como parâmetro de desempenho. Simulações comparativas foram realizadas para validar o algoritmo proposto, que obteve resultados melhores em todos os cenários considerados. O algoritmo de Prashanth e Bhatnagar (2011) foi comparado ao de Abdulhai, Pringle e Grigoris (2003), a controladores com tempos-fixos, a um controlador que seleciona a fase ativa de acordo com a maior fila de veículos, e a um controlador que seleciona a fase ativa de acordo com o tempo de inatividade das fases.

Uma limitação dos algoritmos de aprendizado por reforço propostos por Abdulhai, Pringle e Grigoris (2003) e Prashanth e Bhatnagar (2011) é sua arquitetura centralizada, que limita o tempo de reação do controle, e, assim, seu desempenho. Abdoos, Mozayani e Bazzan (2011) propuseram um método de controle baseado em Q-learning multiagente, no qual cada intersecção possui um controlador. A arquitetura distribuída de controle em um ambiente de aprendizado em tempo real gera um comportamento não estacionário, pois a mudança do comportamento de um controlador afeta o padrão de entrada dos controladores vizinhos e, assim, sua aprendizagem. Portanto, o algoritmo de Q-learning multiagente não garante a convergência do sistema para uma solução ótima, o que é considerado uma vantagem pelos autores, visto que o controlador estaria sempre se adaptando a novas situações do trânsito. Em uma simulação comparativa, o método proposto por Abdoos, Mozayani e Bazzan (2011) obteve um tempo médio de viagem 11,7% menor do que um controlador com tempos fixos.

Araghi et al. (2013) propuseram um método de controle para uma única intersecção baseado no método de Abdoos, Mozayani e Bazzan (2011). Os autores estenderam os parâmetros do algoritmo de Q-learning de Abdoos, Mozayani e Bazzan (2011), aumentando a precisão de descrição do sistema e a gama de ações do controlador. Ao invés dos 24 estados de cada intersecção propostos por Abdoos, Mozayani e Bazzan (2011), Araghi et al. (2013) consideraram 81, como forma de caracterizar com mais precisão o comprimento das filas de veículos de cada uma das 4 vias que formam a intersecção. No lugar dos ciclos semafóricos fixos de Abdoos, Mozayani e Bazzan (2011), Araghi et al. (2013) propuseram ciclos com tempos variáveis, estendendo as 19 possíveis combinações de tempos de verde a 81 combinações. Além disso, ao invés de considerar apenas reforços positivos, determinados a partir do comprimento das filas de veículos, Araghi et al. (2013) utilizam reforços positivos e negativos, o que acelera o aprendizado e a convergência do algoritmo. Os efeitos das alterações propostas foram avaliados em simulações comparativas, que revelaram um desempenho 27,2% melhor em termos de tempo médio de viagem no cenário estudado. A representação mais simples dos estados e das ações proposta por Abdoos, Mozayani e Bazzan (2011) não permitiu a diferenciação nem de fluxos de veículos parecidos, o que limitou seu tempo de resposta, nem de ações mais díspares, necessárias nos casos em que as diferenças nas filas de veículos são grandes, o que restringe sua capacidade de recuperação.

Zhu et al. (2015) propuseram um algoritmo de aprendizado por reforço que considera as ações conjuntas das intersecções para controlar os sinais de trânsito de forma coordenada. O algoritmo foi comparado a um algoritmo de controle adaptativo dos sinais de trânsito baseado na proposta de Wunderlich et al. (2008) e a um algoritmo de Q-learning que considera o aprendizado independente de cada intersecção. Ambos os algoritmos baseados em aprendizado por reforço foram superiores ao método de controle adaptativo em todas as simulações. O algoritmo proposto por Zhu et al. (2015) foi, em média, 24,6% melhor que o método de controle adaptativo dos veículos para atravessar as intersecções. Ademais, o algoritmo proposto por Zhu et al. (2015) foi, em média, 24,0% melhor que o método de controle adaptativo en todas veículos para atravessar as intersecções. Ademais, o algoritmo proposto por Zhu et al. (2015) foi, em média, 24,0% melhor que o método de controle adaptativo en todas veículos para atravessar as intersecções. Ademais, o algoritmo proposto por Zhu et al. (2015) foi, em média, 24,0% melhor que o método de controle adaptativo en todas para atravessar as intersecções. Ademais, o algoritmo proposto por Zhu et al. (2015) foi, em média, 24,0% melhor que o método de controle adaptativo en relação ao atraso médio dos veículos para atravessar as intersecções.

22,5% superior ao algoritmo com aprendizado independente de cada intersecção segundo o mesmo critério, o que ressalta a importância da coordenação no controle dos sinais de trânsito.

Métodos de controle baseados em Q-learning requerem o armazenamento de uma tabela com os valores de Q, cujo crescimento exponencial de combinações de novos estados e ações restringe o desempenho de controle (ZHAO; DAI; ZHANG, 2012; ARAGHI et al., 2013). Segundo Gokulan e Srinivasan (2014), na aprendizagem em tempo real é necessário compreender a consequência de cada ação tomada pelo controlador, o que é complicado em sistemas com comportamento estocástico e com uma grande quantidade de variáveis fortemente acopladas. Além disso, apesar de se adaptarem a condições constantes de trânsito em diferentes cenários, os algoritmos de aprendizado por reforço possuem um tempo de convergência antes de se adaptarem a mudanças abruptas na dinâmica do sistema.

3.1.1.4. Redes neurais artificiais

Assim como no controle por meio da lógica difusa, dos algoritmos evolucionários e do aprendizado por reforço, Spall e Chin (1994) propuseram uma rede neural artificial que não necessita de um modelo do sistema de trânsito para controlá-lo. Segundo eles, a dificuldade em descrever matematicamente os elementos do sistema de trânsito limita qualquer estratégia de controle que requeira um modelo de sua dinâmica. A rede neural artificial proposta pelos autores representa uma função de controle, que tem como entrada o estado do trânsito e como saída os tempos de verde ótimos dos semáforos. Os parâmetros críticos de desempenho da rede são os pesos das conexões entre os neurônios, determinados pelo método de aproximação estocástica com perturbação simultânea. Spall e Chin (1994) utilizaram uma rede neural para cada um de cinco períodos do dia, nos quais os fluxos de veículos possuem padrões similares. Cada rede neural é treinada separadamente até sua convergência, e, durante sua operação, também passa por um processo de aprendizado para se adaptar a flutuações diárias de fluxos de veículos e a mudanças de padrões em longo prazo.

O algoritmo de aproximação estocástica com perturbação simultânea, proposto previamente por Spall (1992), consiste em achar o mínimo de uma função na presença de ruído, e dispensa o uso de um modelo do trânsito urbano ao estimar o

gradiente necessário no processo de aprendizado. Outras redes neurais artificiais, como a proposta por Nataksuji e Kaku (1991), utilizam modelos macroscópicos do trânsito e um algoritmo clássico de *backpropagation* (CHOY; SRINIVASAN; CHEU, 2003) para calcular os gradientes do processo de aprendizado. Dessa maneira, esses trabalhos possuem limitações no desempenho de controle por causa da ocorrência de padrões não previstos durante o treinamento da rede; por sua incapacidade de se adaptar em tempo real; e por causa das poucas variáveis consideradas no modelo simplificado do trânsito urbano, que não representa com fidelidade o comportamento real do sistema. Apesar do método de controle elaborado por Spall e Chin (1994) ser adaptativo – por permitir o aprendizado em tempo real –, as simulações demonstraram que a rede neural artificial necessita de 50 dias de simulação para convergir após uma mudança moderada no estado do sistema.

Choy, Srinivasan e Cheu (2003) propuseram um método de controle hierárquico híbrido baseado em uma rede neural artificial para controlar o trânsito urbano. Sua hierarquia consiste em controladores individuais para cada interseccão. controladores de zonas, que determinam a cooperação dos controladores das intersecções, e um controlador regional, que determina a política ótima a ser seguida pelos controladores das zonas. O método de controle compreende, além da rede neural artificial, o uso de lógica difusa, de um algoritmo evolucionário e de aprendizado por reforço. A rede neural artificial é responsável pela determinação das saídas do sistema a partir de suas entradas. A lógica difusa elimina incertezas associadas às variáveis e simplifica o sistema de controle ao reduzir os valores possíveis de cada variável a três: baixo, médio, e alto. O aprendizado por reforço, o algoritmo evolucionário e a plasticidade sináptica (alteração dos pesos das conexões entre os neurônios) são utilizados para garantir a adaptabilidade do sistema no ambiente dinâmico em que ele está inserido.

Tanto o aprendizado por reforço quanto a plasticidade sináptica fazem parte do processo de otimização dos pesos sinápticos em tempo real, recompensando as ações tomadas pelo controlador quando a situação do trânsito melhora. Por sua vez, o objetivo do algoritmo evolucionário é a otimização das funções de pertinência da lógica difusa. Em simulações comparativas, o método de controle proposto por Choy, Srinivasan e Cheu (2003) obteve até 40% de melhora em termos de tempo médio de viagem em relação ao método GLIDE (KEONG, 1993). Apesar de agregar

as vantagens de cada método de inteligência computacional utilizado, uma hibridização também agrega as desvantagens, como evidenciado por Gokulan e Srinivasan (2010) em simulações que compararam o método de controle de Choy, Srinivasan e Cheu (2003) com sua proposta de controlador difuso tipo-2.

Srinivasan, Choy e Cheu (2006) propuseram uma rede neural artificial para o controle distribuído do trânsito urbano que, assim como Spall e Chin (1994), utiliza o algoritmo de aproximação estocástica com perturbação simultânea para atualizar os pesos sinápticos e garantir a adaptabilidade do sistema por meio do aprendizado em tempo real. Entretanto, Srinivasan, Choy e Cheu (2006) eliminaram duas limitações do método de Spall e Chin (1994): a falta de robustez, ao depender da repetição de padrões em determinados períodos do dia para obter uma solução ótima; e a baixa velocidade de adaptação, pois os pesos sinápticos de cada rede neural artificial só são atualizados em seu período específico do dia. Dessa maneira, foi elaborada uma única rede neural artificial, que, com o auxílio da lógica difusa, separa os possíveis estados do sistema e, para cada um, utiliza uma parte da rede neural artificial para determinar os tempos de verde dos semáforos.

A rede neural artificial proposta por Srinivasan, Choy e Cheu (2006) foi comparada à rede neural artificial híbrida de Choy, Srinivasan e Cheu (2003) e ao método de controle de sinais de trânsito GLIDE (KEONG, 1993). Ambas as redes neurais artificiais obtiveram desempenhos melhores que o método GLIDE em todos os cenários investigados. Na comparação entre as redes neurais artificiais, a proposta por Srinivasan, Choy e Cheu (2006) obteve resultados 8,7% melhores em termos de tempo médio de viagem em um cenário com duração de três horas e um único pico de demanda de veículos. Entretanto, em cenários com durações maiores e mais picos de demanda de veículos, o método de Choy, Srinivasan e Cheu (2003) obteve resultados melhores, pois seu método de aprendizado possibilita uma adaptação mais rápida aos diferentes estados do sistema de trânsito. Nesses casos, o algoritmo de aproximação estocástica com perturbação simultânea não converge ao ótimo global em tempo hábil.

Castán, Ibarra e Laria (2015) propuseram uma rede neural artificial, treinada com o algoritmo *backpropagation*, para determinar o tempo de verde ótimo de cada semáforo. O modelo dos autores possui três neurônios de entrada: um que representa a quantidade de veículos na via correspondente ao semáforo controlado; outro que representa o tempo atual de verde do semáforo; e um terceiro que representa a quantidade de veículos na via seguinte ao semáforo controlado. Os autores avaliaram dois critérios principais de desempenho para avaliar o modelo: a mobilidade, determinada a partir da quantidade de veículos em cada intersecção; e a o consumo de combustível, o qual afeta a emissão de gases poluentes. O modelo de Castán, Ibarra e Laria (2015) apresentou melhoras de 28% em relação ao primeiro critério e de 20% em relação ao segundo critério em comparação a um método de controle convencional, o qual possui tempos de verde fixos, programados para sincronizar a abertura de semáforos consecutivos.

Redes neurais têm a capacidade de representar um comportamento complexo por meio da configuração dos parâmetros dos neurônios e de suas conexões sinápticas; entretanto, é difícil interpretar o modelo resultante de um longo processo de aprendizado (GOKULAN; SRINIVASAN, 2014). Segundo Gokulan e Srinivasan (2014), métodos de aprendizado são pouco adequados à aplicação em problemas complexos, pois obter dados de treinamento que compreendam todos os possíveis estados do sistema é infactível; além disso, para o aprendizado em tempo real é necessário compreender a consequência de cada ação tomada pelo controlador, o que é complicado em sistemas com comportamento estocástico e com uma grande quantidade de variáveis fortemente acopladas.

3.1.1.5. Sistemas multiagente

Por distribuir a capacidade de controle, a teoria de sistemas multiagente é utilizada em conjunto com outros métodos computacionais para realizar o controle do trânsito urbano, como feito por Gokulan e Srinivasan (2010) com o controlador difuso, por Abdoos, Mozayani e Bazzan (2011) e por Zhu et al. (2015) com o aprendizado por reforço, por Srinivasan, Choy e Cheu (2006) com a rede neural artificial e por Oliveira e Camponogara (2010) com o controle preditivo baseado em modelo.

Uma subárea de sistemas multiagente é a teoria dos jogos, na qual os agentes participam de um jogo, dividido em rodadas (iterações), com regras pré-definidas, e tentam maximizar seu retorno. Cheng, Epelman e Smith (2006) propuseram um sistema multiagente baseado no paradigma de teoria dos jogos para determinar o plano semafórico ótimo de uma rede urbana. Em sua abordagem, cada agente representa um período de tempo de 10 segundos de uma intersecção e determina a

fase ativa desse período. O método de controle proposto pelos autores é capaz de utilizar informações históricas de origem e destino dos veículos para predizer o estado do trânsito e, assim, tomar decisões melhores. Como o objetivo de todos os agentes é comum, minimizar o tempo médio de viagem de todos os veículos da rede urbana, o problema de controle é representado como um jogo de interesses idênticos, situação em que o algoritmo de controle converge para um equilíbrio. O ponto de equilíbrio da teoria dos jogos, também chamado de ponto de equilíbrio de Nash, é o ponto no qual nenhum agente pode melhorar sua solução em relação a seus objetivos.

Os autores realizaram simulações comparativas para validar o método de controle proposto, obtendo um tempo médio de viagem 58% menor do que um controlador com tempos fixos. Entretanto, as simulações também revelaram um tempo de convergência de 20 iterações, o que corresponde a 169 horas em um computador regular ou 37 minutos em um cluster com processamento paralelo de 256 processadores. Esse tempo de convergência limita a reação do método de controle a mudanças abruptas na dinâmica do sistema, comuns no trânsito urbano. Além disso, outra limitação no tempo de reação é a arquitetura centralizada do método. Há ainda a dificuldade de incluir restrições, como tempos máximos e mínimos de verde, no processo decisório do sistema multiagente adotado, o que impede sua aplicação em sistemas de trânsito reais.

Alvarez, Poznyak e Malo (2007) propuseram um sistema multiagente para o controle de sinais de trânsito de uma única intersecção. Os autores adotaram uma abordagem não cooperativa de teoria dos jogos, na qual cada agente representa uma fase do sistema de semáforos de uma intersecção. Como cada agente tenta minimizar as filas de veículos correspondentes a sua fase, um processo competitivo é gerado. A cada ciclo de controle, um jogo é executado e o ponto de equilíbrio da disputa entre os agentes é determinado de acordo com filas de veículos. Essa solução corresponde às frações do ciclo semafórico concedidas a cada fase. O método proposto por Alvarez, Poznyak e Malo (2007) obteve filas 26,45% menores do que o método adaptativo em simulações comparativas, o que é justificado pelos autores por ser um método de controle que busca a solução ótima.

No sistema multiagente de Batista Junior e Coutinho (2013), cada agente controla os semáforos de uma intersecção e faz parte de uma organização social, que tem o objetivo de conciliar a formação de ondas verdes e o controle local

adaptativo. O agente proposto pelos autores é uma entidade com crenças (*Beliefs*), desejos (*Desires*) e intenções (*Intentions*), também denominada agente BDI, e possui um papel dentro da organização. A especificação organizacional do sistema multiagente define três papeis: agente base; agente externo; e agente do meio. Os agentes externos são os agentes localizados nas extremidades de uma rua principal, enquanto os agentes do meio são responsáveis pelo controle das intersecções intermediárias da rua. O agente base é um agente externo encarregado de informar aos agentes do meio qual é o plano que eles devem executar, o qual é considerado o desejo (*Desire*) deles. Dessa forma, a onda verde se forma quando todos os agentes de uma rua atingem seu desejo.

Para avaliar o método de controle proposto, os autores o comparam a um método com tempos fixos que formam uma onda verde. Os resultados das simulações demonstraram que o método de controle de Batista Junior e Coutinho (2013) reduziu em 84,8% o atraso dos veículos em percorrer a rua, o que é atribuído à capacidade de conciliar de forma dinâmica a formação de ondas verdes e o controle local de cada intersecção. Entretanto, uma limitação do método é adotar tempos fixos em seus planos, o que reduz a possibilidade de ação dos controladores e dificulta a formação das ondas verdes. Isso ocorre principalmente em situações em que o fluxo de veículos não é nem constante e nem igual ao valor utilizado para a elaboração dos planos dos agentes.

Vilarinho, Tavares e Rossetti (2016) propuseram um sistema multiagente com 7 tipos de agente para controlar os semáforos de uma única intersecção. Os autores desenvolveram o sistema multiagente de acordo com uma metodologia, denominada Gaia (ZAMBONELLI; JENNINGS; WOOLDRIDGE, 2003), de análise e *design* orientados por agentes para a solução de problemas. Além disso, a metodologia Gaia foi complementada pela metodologia Tropos (BRESCIANI et al., 2004) com a finalidade de identificar os papeis relevantes do sistema, seus objetivos, suas intenções e suas interdependências, assim como modelar esses papeis como atores sociais interativos. O sistema multiagente de Vilarinho, Tavares e Rossetti (2016) é responsável por definir e implementar um plano semafórico de forma autônoma. O processo de definição do plano semafórico é baseado na negociação entre agentes responsáveis por monitorar cada fluxo de veículos. Tal sistema multiagente ainda determina quando suspender um plano semafórico ativo e criar um novo plano, para, por exemplo, atender a variações de demanda.

3.1.2. Soluções baseadas na teoria de controle ótimo

3.1.2.1. Programação dinâmica

Heung, Ho e Fung (2005) elaboraram controladores difusos para cada intersecção, cuja coordenação é realizada por meio da programação dinâmica, com base na projeção de fluxo de veículos das intersecções vizinhas. Os controladores difusos determinam o tempo efetivo de verde de cada fase, que pode ser estendido ou reduzido de forma iterativa pelo método de programação dinâmica para originar a coordenação por meio da minimização da função objetivo. A função objetivo do método, que é a referência para o ajuste do parâmetro de coordenação, é composta pelo atraso e pelo número de paradas dos veículos durante sua viagem. Para avaliar o método de programação dinâmica como forma de coordenação, os autores o compararam a um método com controladores difusos independentes em simulações, nas quais a programação dinâmica foi responsável pela redução de 20% no atraso médio dos veículos.

Li, Zhao e Yi (2008) propuseram um método de controle cooperativo de múltiplas intersecções com base na programação dinâmica adaptativa, uma combinação de programação dinâmica com aprendizado por reforço. Em sua abordagem, os autores elaboraram duas redes neurais artificiais, uma que determina as ações do controlador e outra que as avalia, como forma de aproximar a equação de controle ótimo de Hamilton–Jacobi–Bellman. A otimização dos parâmetros de um controlador envolve não apenas o tempo de espera dos veículos na intersecção que ele controla, mas também o tempo de espera em intersecções vizinhas, o que aumenta a cooperação no controle do sistema. A proposta dos autores é avaliada em simulações, nas quais foi comparado ao mesmo método de controle, mas sem cooperação, e a um controlador acionado por veículos, e obteve melhores resultados em termos de tempo médio de espera dos veículos. As simulações também evidenciaram a sensibilidade do desempenho de controle aos parâmetros de aprendizado do método, o que indica pouca robustez na aproximação da equação de Hamilton–Jacobi–Bellman.

Cai, Wong e Heydecker (2009) elaboraram duas formas de aproximação linear para a equação de Hamilton–Jacobi–Bellman e as compararam no controle de sinais

de trânsito. A primeira é o aprendizado por diferença temporal, que consiste em monitorar a diferença entre o valor estimado e o medido e propagá-la para ajustar os parâmetros da função de aproximação. A segunda é o aprendizado por perturbação, que estima os gradientes de erro da função de aproximação diretamente ao perturbar o estado do sistema com sinais conhecidos. As simulações realizadas pelos autores demonstraram um desempenho equivalente das duas formas de aproximação. Além disso, o controle por meio das aproximações, realizado em tempo real, obteve um acréscimo de apenas 8,20% no atraso dos veículos em comparação ao controle utilizando a equação de Hamilton–Jacobi–Bellman, cujo custo computacional não permite o controle em tempo real.

Yin, Dridi e El Moudni (2016) propuseram um algoritmo de programação dinâmica que utiliza uma aproximação linear da função objetivo e que considera a coordenação entre intersecções na solução do problema de otimização. Dessa maneira, cada intersecção controlada utiliza a quantidade de veículos nas intersecções vizinhas para calcular os tempos de verde dos semáforos, o que possibilita uma ação conjunta das intersecções na melhora dos fluxos de veículos. Para avaliar seu 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 por Yin, Dridi e El Moudni (2016) foi melhor em todos os cenários simulados e ressaltam a importância da determinação do parâmetro de coordenação das intersecções para a obtenção de um melhor desempenho.

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 por eles e por Yin, Dridi e El Moudni (2016), 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 recursiva 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.

3.1.2.2. Controle preditivo baseado em modelo

Oliveira e Camponogara (2010) propuseram o controle preditivo distribuído do trânsito urbano por meio da decomposição do problema de controle centralizado dos preditivos baseados em modelo desenvolvido previamente controladores CAMPONOGARA: (CAMPONOGARA et al.. 2002: TALUKDAR, 2007: CAMPONOGARA; OLIVEIRA, 2009). O modelo utilizado no controle preditivo é macroscópico e não representa de forma realista a dinâmica complexa do trânsito. como o tempo de reação dos motoristas e sua aceleração e desaceleração, pois tem como objetivo apenas descrever a evolução do trânsito em longo prazo. Além disso, uma maior sofisticação do modelo impossibilitaria o controle em tempo real devido ao alto custo computacional adicional. A cada iteração do método, os controladores das intersecções tomam decisões e as comunicam a seus vizinhos. Como a decisão de um controlador afeta as variáveis de entrada dos controladores vizinhos, e, portanto, suas decisões, esse processo se repete até que as decisões dos controladores convirjam para um equilíbrio de Nash ou que o tempo destinado à tomada de decisões de um ciclo de controle acabe.

Para avaliar o controle proposto, Oliveira e Camponogara (2010) realizaram análises numéricas e simulações com dinâmica microscópica, comparando o controle preditivo distribuído com o centralizado e com um regulador linear quadrático, como o elaborado por Diakaki, Papageorgiou e Aboudolas (2002). O regulador linear quadrático é um método de controle baseado na otimização de uma função de custo. Neste caso, a mesma que a do controle preditivo baseado em modelo. No entanto, o regulador linear quadrático não incorpora as restrições do sistema e só otimiza o custo da ação atual. Nas análises numéricas, que utilizam o mesmo modelo utilizado na predição do estado do sistema, o método proposto pelos autores, com um horizonte de cinco ciclos de controle, teve um desempenho 10% melhor na minimização da função de custo do que o regulador quadrático. Apesar disso, no simulador microscópico, o desempenho da abordagem de Oliveira e Camponogara (2010) foi equivalente ao regulador linear quadrático quando o horizonte considerado foi de um ciclo de controle, e foi inferior quando o horizonte considerado foi de três ciclos de controle. A deterioração no desempenho de controle demonstra a dificuldade em prever o comportamento do sistema com base em um modelo macroscópico.

Lin, Ling e Xi (2013) elaboraram um controlador com arquitetura hierárquica de três níveis, dos quais dois, o global e o regional, são baseados no controle preditivo com modelo. Os dois níveis possuem objetivos de minimização e modelos base diferentes. O nível global é baseado em um modelo macroscópico que descreve apenas os fluxos de veículos entre regiões, enquanto o nível regional é baseado no modelo macroscópico proposto por Lin, Schutter e Hellendoorn (2011, 2012), que descreve os fluxos de veículos entre as intersecções. O objetivo do controlador global é de balancear a densidade de veículos em cada região, para, assim, aumentar os fluxos de veículos, como demonstrado por Geroliminis e Daganzo (2008). Por sua vez, os controladores regionais possuem dois objetivos: atender aos fluxos estipulados pelo controlador global em suas intersecções de fronteira com outras regiões; e reduzir o atraso dos veículos em suas regiões. O controlador local apenas executa as decisões tomadas nos níveis superiores. Para avaliar o desempenho do método de controle, os autores o compararam em simulações a dois controladores preditivos baseados em modelo: um com arguitetura centralizada; e um com arquitetura distribuída.

Por um lado, o controlador distribuído aumenta tanto os fluxos de veículos da rede urbana quanto o tempo médio de viagem do veículos. Isso ocorre por permitir que mais veículos entrem na rede urbana em seu processo de otimização, o qual maximiza o fluxo de veículos em cada intersecção e não possui visão global do sistema. Por outro lado, o controlador centralizado reduz o tempo médio de viagem dos veículos e os fluxos de veículos, pois limita a quantidade de veículos na rede urbana por meio da redução dos fluxos de entrada para manter a densidade de veículos na rede baixa, o que é possível por causa da visão holística da arquitetura centralizada. O método hierárquico proposto pelos autores reduziu em 19% o número de intersecções congestionadas, pois concilia o balanço de demandas entre regiões, para manter as densidades de veículos baixas em cada região, com a coordenação regional dos semáforos de cada intersecção, para aumentar os fluxos de veículos. Apesar de obter um desempenho superior em termos de fluxo de veículos e intersecções congestionadas, o método de Lin, Ling e Xi (2013) obteve um desempenho intermediário em relação aos outros métodos em termos de tempo médio de viagem e densidade da rede.

Segundo Tettamanti et al. (2014), a natureza estocástica do trânsito urbano gera discrepâncias entre os modelos matemáticos e a realidade, o que leva a uma pior predição de seu comportamento e, assim, a um desempenho de controle inapropriado. Os autores propuseram um método de controle preditivo baseado em modelo com arquitetura centralizada e que considera as incertezas do trânsito urbano. Para esse fim, a otimização determina a combinação de tempos de verde que minimiza a função objetivo no pior caso definido pelo intervalo de incerteza. Apesar de considerarem incertezas, os autores utilizam um modelo macroscópico simplificado do trânsito urbano em seus cálculos, com valores de fluxo de saturação, taxas de virada e de saída dos veículos constantes, o que limita a predição do seu comportamento e, portanto, o desempenho de controle. Como em outros métodos de controle preditivo baseados em modelo (OLIVEIRA; CAMPONOGARA, 2010; LIN; LING; XI, 2013), o tempo de ciclo e a sequência de fases também são considerados fixos para reduzir a complexidade do problema.

Como forma de avaliar o método de controle proposto, os autores (TETTAMANTI et al., 2014) o compararam a um controlador preditivo que não considera as incertezas do sistema. Nos cenários em que a demanda de veículos se aproximou mais do valor nominal, o controlador que não considera as incertezas foi em média 4,5% melhor em termos de tempo médio de viagem. Por outro lado, nos cenários em que o fluxo de veículos variou mais, o controlador proposto foi em média 13,4% melhor segundo o mesmo índice de desempenho. Os autores demonstraram também que sua abordagem é sensível à determinação do intervalo de incerteza, obtendo uma diferença de 5,6% de desempenho quando variado. Os limites superior e inferior do intervalo de incerteza foram de até 40% acima e abaixo do valor nominal em uma das intersecções, o que demonstra a pouca precisão de predição dos modelos matemáticos utilizados no controle preditivo baseado em modelo. Esse aspecto é reforçado pela análise de desempenho da variação do horizonte de predição, na gual o desempenho se deteriora em períodos superiores a três ciclos de controle. Dessa maneira, mesmo considerando intervalos de incerteza durante o processo de otimização, o desempenho de controle ainda é limitado pela dificuldade em predizer o comportamento do sistema.

Ye et al. (2016) propuseram um método de controle preditivo baseado em modelo com arquitetura hierárquica para reduzir a complexidade computacional de sua abordagem e manter a coordenação global da rede urbana. Dessa forma, cada
intersecção é controlada por um algoritmo de controle preditivo baseado em modelo, como na arquitetura de controle distribuída, e a coordenação entre intersecções é realizada por uma camada de controle superior, que aborda as interações entre intersecções vizinhas. O algoritmo responsável pela coordenação das intersecções utiliza multiplicadores de Lagrange para lidar com as restrições impostas pelas conexões entre intersecções. Multiplicadores de Lagrange são artifícios matemáticos para incorporar restrições em problemas de otimização. Como forma de avaliação do desempenho, Ye et al. (2016) compararam o tempo de computação e o tempo médio de viagem dos veículos da sua proposta com os valores obtidos pelo método de controle preditivo baseado em modelo com uma arquitetura centralizada. Os autores obtiveram um tempo de computação de até 70,25% inferior e um tempo médio de viagem equivalente ao método de controle com arquitetura centralizada.

3.1.2.3. Contrapressão

Por não se basear integralmente no método de contrapressão, a proposta de Wunderlich et al. (2008) pode ser considerada sua antecessora, pois também se baseia em conceitos de otimização de fluxos de dados em redes de comunicação. Do mesmo modo que os métodos de contrapressão, Wunderlich et al. (2008) utilizam as filas de veículos para ponderar a prioridade de ativação de cada semáforo. Entretanto, em vez de considerar a pressão da via seguinte ao semáforo controlado, os autores realizam um estudo de estabilidade para considerar a dinâmica de intersecções vizinhas. Dessa maneira, os casos em que uma intersecção pode se tornar instável devido a fluxos de veículos provenientes de intersecções vizinhas são estabelecidos no estudo e evitados pelo algoritmo. Wunderlich et al. (2008) avaliaram sua proposta a comparando com um controlador com tempos de verde fixos e com um controlador adaptativo em cenários com demanda de veículos balanceada e desbalanceada. De maneira geral, o método de controle proposto pelos autores apresentou resultados melhores do que os resultados dos outros dois métodos de controle, em especial nos cenários com uma demanda de veículos alta.

Wongpiromsarn et al. (2012) propuseram a primeira abordagem que utiliza o método de contrapressão aplicado ao controle do trânsito urbano. Os autores utilizaram uma arquitetura de controle distribuída, o que reduz a complexidade

computacional do método de controle. Segundo Gregoire et al. (2015), a complexidade computacional do método de controle de contrapressão é O(1). Além disso, Wongpiromsarn et al. (2012) provaram que o algoritmo proposto por eles garante o ótimo global do sistema, o que resulta em um fluxo de veículos máximo. Os resultados de simulações comparativas com o algoritmo de controle adaptativo SCATS (LOWRIE, 1982) mostram que o método de controle proposto por Wongpiromsarn et al. (2012) é superior em termos de tamanho das filas de veículos na rede urbana. Em um dos cenários investigados, os autores reduziram o tamanho das filas por um fator de 3.

Assim como a proposta de Wongpiromsarn et al. (2012), Le et al. (2015) também basearam seu método de controle no algoritmo de contrapressão proposto por Tassiulas e Ephremides (1992) para o controle de redes de comunicação. O objetivo da proposta de Le et al. (2015) é manter a estabilidade do algoritmo de Wongpiromsarn et al. (2012) e mitigar dois pontos fracos: a alocação de tempos de verde nulos em alguns casos; e a necessidade de informações *a priori* sobre as características das demandas de veículos. Dessa maneira, Le et. al (2015) estruturam seu método de controle em ciclos com tempos mínimos de verde para cada fase semafórica e utilizam estimadores de parâmetros para determinar as características das demandas de veículos. Os autores também realizaram uma análise da estabilidade do método de controle proposto, provando que este é estável mesmo para as maiores demandas de veículos possíveis. Ademais, o desempenho do método de controle de Le et. al (2015) obteve resultados 14,3% melhores que um controlador adaptativo em termos de tempo médio de viagem dos veículos.

Gregoire et al. (2015) ressaltam outro aspecto deficiente do método de controle de contrapressão proposto por Wongpiromsarn et al. (2012), o qual também está presente na abordagem de Le et al. (2015). Tal aspecto é considerar a capacidade das vias infinitas, como é feito na abordagem original de Tassiulas e Ephremides (1992) para o controle de redes de comunicação. Ao aplicar o método de controle que considera as capacidades das vias infinitas no trânsito urbano real, cujas vias possuem capacidades finitas, viola-se o princípio de conservação do trabalho. Dessa forma, em casos de alta demanda de veículos, congestionamentos se propagam pelas vias de intersecções vizinhas. Em sua abordagem, Gregoire et al. (2015) consideram as capacidades das vias finitas ao normalizar a pressão de cada via, o que mitiga a propagação de congestionamentos por não violar o princípio de

conservação do trabalho, como demonstrado pelos autores. Os autores avaliaram sua proposta em simulações comparativas a um método de controle de contrapressão convencional, assim como o de Wongpiromsarn et al. (2012). A abordagem de Gregoire et al. (2015) apresentou resultados equivalentes ao método de controle de contrapressão convencional nos cenários com baixa e média demanda, e resultados superiores em cenários com altas demandas.

3.2. Trabalhos relacionados a modelos de redes neurais bioinspiradas

Diferentes modelos de redes neurais bioinspiradas foram propostos para o controle de sistemas, principalmente na área de robótica (BILLARD; IJSPEERT, 2000; FOLGHERAITER et al., 2006; YANG et al., 2009; HIREL; GAUSSIER; QUOY, 2011; NICHOLS; MCDAID; SIDDIQUE, 2013; SAPUTRA et al., 2016). Além da estrutura única de cada rede neural, os trabalhos adotam diferentes modelos de neurônio, diferentes tipos de sinapses e diferentes modelos de plasticidades sinápticas em curto e longo prazos. O controle de robôs é semelhante ao controle de sistemas dinâmicos complexos, como o trânsito urbano, por causa do número de variáveis envolvidas, das não linearidades, da variação do estado do sistema com o tempo, e dos ambientes com incertezas.

Billard e Ijspeert (2000) propuseram uma rede neural bioinspirada para controlar um robô quadrupede. Os autores adotaram o modelo de neurônio *leaky-integrator* (integrador que vaza) (HOPFIELD, 1984) e sinapses tanto excitatórias quanto inibitórias para gerar um comportamento oscilatório, como analisado por Williams (1992) e Mao e Massaquoi (2007). Dessa maneira, as quatro pernas do robô são sincronizadas em três estados diferentes: caminhar, trotar e galopar. Ijspeert (2008) resume os elementos que favorecem o controle de robôs com sinais neurais oscilatórios como: ciclo limite intrínseco, o que indica estabilidade dos padrões oscilatórios; poucos parâmetros de controle, os quais modulam os sinais com flexibilidade; fácil integração de realimentação (*feedback*); e boa base para algoritmos de aprendizado e otimização.

Folgheraiter et al. (2006) propuseram uma rede neural bioinspirada para controlar robôs autônomos, imitando a arquitetura de subsunção (BROOKS, 1991) por meio de sinapses inibitórias com a finalidade de percorrer uma trajetória evitando obstáculos. Dessa maneira, os autores conectaram os neurônios de entrada

diretamente aos dois neurônios de saída, que controlam os motores da roda esquerda e da roda direita do robô. O modelo de neurônio adotado pelos autores é semelhante ao das redes neurais artificiais, cujo potencial de membrana é calculado pela soma ponderada de suas entradas e cuja saída é determinada por uma função de ativação.

Yang et al. (2009) se basearam no oscilador neural proposto por Matsuoka (1985, 1987) para controlar um braço robótico. O oscilador é composto por dois neurônios que se inibem mutualmente e geram saídas oscilatórias com frequências ajustáveis. O modelo de neurônio utilizado também é semelhante ao das redes neurais artificiais quanto ao cálculo do potencial de membrana e da saída, mas com um fator adicional de adaptação, que atua como um filtro passa-alta e é essencial no comportamento oscilatório. Os autores adotaram um oscilador para cada uma das três articulações do braço robótico com a finalidade de atingir um ponto desejado de forma robusta. Ao contrário de Billard e Ijspeert (2000), que adotaram três padrões de oscilação uniformes, Yang et al. (2009) ajustam as frequências de oscilação para que o braço robótico percorra a trajetória desejada mesmo com distúrbios externos. Taga, Yamagushi e Shimizu (1991) demonstraram que o oscilador neural de Matsuoka (1985, 1987) aplicado ao controle de robôs e estendido com um *feedback* sensorial, como feito por Yang et al. (2009), é robusto à distúrbios de ambientes imprevisíveis.

Hirel, Gaussier e Quoy (2011) propuseram um modelo de rede neural bioinspirada com a finalidade de controlar a navegação de um robô. O modelo permite o reconhecimento de cadeias de eventos, com noções temporais, e de sua associação direta a ações motoras. Por considerar a temporalidade dos eventos e ações, o modelo tem a capacidade de predizer o estado futuro do robô. Dessa maneira, a estrutura da rede neural é dividida em três partes: predição, utilizada para associar eventos espaço-temporais passados a percepções atuais e tentar predizer o que ocorrerá; avaliação, para determinar se a predição feita ocorreu ou não e, caso ela não ocorra, modificar o comportamento do robô de acordo com seu estado atual; e ação, que define as ações do robô com base nas predições, nas avaliações, e em seu estado atual. A rede neural adota sinapses excitatórias e inibitórias e diferencia sinapses distais, que não possuem plasticidade, de sinapses proximais, que possuem plasticidade.

Nichols, McDaid e Siddique (2013) propuseram um modelo de rede neural pulsante para o controle de robôs. Assim como Billard e Ijspeert (2000), os autores adotaram o modelo leaky-integrator de neurônio por possuir um baixo custo computacional. Segundo os autores, os diferentes modelos de neurônios, como os de Hodgkin e Huxley (1952), Izhikevich (2003), e FitzHugh-Nagumo (NAGUMO; ARIMOTO; YOSHIZAWA, 1962), possuem diferentes níveis de realismo em relação ao neurônio biológico e, assim, diferentes níveis de custo computacional - quanto mais realismo na representação do potencial de membrana, maior o custo computacional. Com a finalidade de controlar a trajetória de um robô em ambientes complexos, e permitir que ele aprenda a seguir caminhos específicos de forma autônoma, os autores elaboraram uma rede neural não recorrente de cinco camadas, cujas sinapses possuem plasticidade em curto e em longo prazos. A plasticidade em curto prazo – ou adaptação, como nomeado por Matsuoka (1985, 1987) – é baseada no modelo de facilitação e depressão de sinapses proposto por Tsodyks, Pawelzik e Markram (1998). Por sua vez, a plasticidade em longo prazo adota a regra de diferença temporal (SUTTON; BARTO, 1998), um tipo de aprendizado por reforço baseado em expectativas pré-estabelecidas.

Yu et al. (2014) analisaram diferentes tipos de osciladores neurais para gerar padrões rítmicos e controlar a locomoção de robôs. Os autores ressaltaram as principais vantagens do uso de redes neurais com comportamento oscilatório para o controle de sistemas complexos: estabilidade, por ser matematicamente equivalente a ciclos limite estáveis e robustos a pequenas perturbações; e adaptabilidade, pois os sinais de realimentação modificam diretamente o padrão das oscilações e permitem adaptações rápidas à mudanças no ambiente de atuação. No entanto, os autores mencionam que os osciladores neurais ainda são como caixas pretas: seus componentes não foram completamente caracterizados. Eles afirmam que a modelagem de redes neurais biológicas com comportamento oscilatório é um desafio de pesquisa urgente e ainda em aberto. Em especial, a falta de fundamentação teórica sobre um oscilador neural que seja estável, robusto a perturbações pequenas, possua transição contínua entre seus estados, e integre sinais de realimentação impede uma aplicação mais ampla na área de controle. Segundo os autores, modelos atuais de osciladores neurais têm muitos parâmetros e não há uma metodologia solidificada capaz de determiná-los. O comportamento desejado é obtido, então, de forma empírica ou por meio de algoritmos de aprendizado.

Saputra et al. (2016) adotaram o oscilador neural de Matsuoka (1985, 1987) para controlar a locomoção de um robô bípede. Os autores usaram o oscilador neural para gerar sinais rítmicos que ditam a ativação de neurônios motores, responsáveis por controlar as articulações do robô. Além da informação exteroceptiva proveniente dos neurônios sensoriais e do oscilador neural, os neurônios motores também tem uma capacidade proprioceptiva, devido a uma sinapse recorrente (autapse). Dessa maneira, o movimento coordenado de 16 articulações, com seus respectivos 16 graus de liberdade, é realizado.

3.2.1. Similaridades e diferenças entre o modelo proposto e modelos relacionados

O modelo de rede neural bioinspirada proposto para o controle do trânsito urbano é baseado no modelo apresentado por Peláez e Andina (2013) e investigado por Peláez, Aguiar-Furucho e Andina (2016). Os dois elementos principais do modelo apresentado por Peláez e Andina (2013), a plasticidade sináptica e a plasticidade intrínseca, foram utilizados anteriormente em redes neurais bioinspiradas para reconhecer a direção de um movimento (KINTO et al., 2007), analisar a ilusão de movimento em imagens estáticas (PELÁEZ et al., 2008) e simular a doença de Alzheimer (MONTEIRO et al., 2008). Além desses dois elementos, o modelo de rede neural bioinspirada investigado por Peláez, Aguiar-Furucho e Andina (2016) também adota a inibição lateral, a qual foi utilizada por Peláez e Godoi (2013) para obter a competição natural entre neurônios.

O modelo aqui proposto adota o mesmo modelo de neurônio adotado por Peláez e Andina (2013) e Yang et al. (2009), o qual também está presente nas redes neurais artificiais e representa o comportamento de neurônios biológicos com um baixo custo computacional. De forma similar à Peláez e Andina (2013), Yang et al. (2009) e Nichols, McDaid e Siddique (2013), o modelo proposto possui um mecanismo de adaptação – ou plasticidade em curto prazo. Além disso, o modelo proposto adota autapses como mecanismo proprioceptivo, como feito por Peláez, Aguiar-Furucho e Andina (2016) e Saputra et al. (2016). Todas as características do modelo proposto geram uma competição entre neurônios excitatórios – ou neurônios motores – e, dessa maneira, geram um comportamento oscilatório, como observado nos trabalhos revisados.

Em contraste com as propostas de Billard e lispeert (2000) e Yang et al. (2009), cujos modelos possuem neurônios com saídas tanto excitatórias quanto inibitórias, o modelo aqui proposto possui neurônios excitatórios e neurônios inibitórios, assim como o modelo investigado por Peláez, Aguiar-Furucho e Andina (2016). Tais neurônios têm saídas só excitatórias e só inibitórias, respectivamente, e são mais realistas em relação aos neurônios biológicos. No entanto, Peláez, Aguiar-Furucho e Andina (2016) adotam apenas inibição por realimentação, enquanto o modelo proposto adota dois tipos de inibição: por realimentação (feedback) e por antecipação (feed-forward). Além disso, o modelo proposto adota inibição axoaxônica e neurônios bipolares - ou neurônios sensoriais - e não adota neurônios do tipo shunting basket e neurônios tálamo-corticais, como feito por Peláez, Aguiar-Furucho e Andina (2016). A principal diferença entre o modelo aqui proposto e o modelo proposto por Peláez, Aguiar-Furucho e Andina (2016) é a plasticidade sináptica - ou plasticidade em longo prazo. Enquanto Peláez, Aguiar-Furucho e Andina (2016) adotaram a plasticidade sináptica para o aprendizado de padrões, o modelo proposto não adota plasticidade sináptica e foca no controle de um sistema dinâmico. Dessa maneira, enquanto as entradas do modelo de Peláez, Aguiar-Furucho e Andina (2016) são pixels de imagens, as entradas do modelo proposto são variáveis contínuas.

4. MODELO DE REDE NEURAL BIOINSPIRADA PARA O CONTROLE DO TRÂNSITO URBANO

Este capítulo aborda a metodologia de pesquisa adotada, assim como a elucidação do modelo de rede neural bioinspirada proposto.

4.1. Metodologia

A metodologia deste trabalho compreende o estudo e a utilização de: modelos de redes neurais; métodos de análise do comportamento de sistemas dinâmicos complexos; e métodos de modelagem e simulação de sistemas.

O modelo de rede neural proposto para o controle de sistemas complexos tem como base alguns dos modelos de redes neurais bioinspiradas da literatura (GROSSBERG, 1976; DESAI, 2003; MAO; MASSAQUOI, 2007; PELÁEZ; ANDINA, 2013), os quais são detalhados na próxima seção. Tanto a estrutura da rede neural, quanto os modelos de neurônio e plasticidades adotados definem seu comportamento e a maneira como ela incorpora conhecimento sobre o sistema. No caso do controle do trânsito urbano, adotou-se uma abordagem modular, na qual o modelo geral proposto para o controle das fases semafóricas de uma intersecção pode ser aplicado em todas as intersecções. Há apenas diferenças estruturais na rede neural bioinspirada aplicada a cada intersecção, o que é reflexo das características específicas de cada intersecção, como a quantidade de fases semafóricas, vias e faixas. Devido ao alto número de possíveis combinações dos parâmetros da rede neural bioinspirada (cerca de 10 milhões), e seu amplo espectro de comportamentos resultantes, um método de determinação dos parâmetros foi proposto para simplificar a definição do comportamento desejado.

Com a finalidade de analisar a convergência do modelo de controle proposto, e, assim, determinar sua reatividade e capacidade de adaptação, foi adotado o método de análise dos pontos fixos, ou pontos de mínimo, descrito por Fuchs (2013). O método consiste em determinar os pontos fixos do sistema, nos quais a derivada no tempo das variáveis de estado é nula, e, por conseguinte, determinar seus possíveis estados de operação. Além disso, foi adotado o método de análise de estabilidade por meio da determinação dos autovalores do sistema, também elucidado por Fuchs (2013). O método permite definir se o sistema é estável ou instável em seus pontos

fixos, além de estabelecer o tipo de estabilidade: pontual, de ciclo limite ou de atrator estranho. Análises da complexidade computacional e do tempo de computação da rede neural bioinspirada para controlar diferentes quantidades de intersecções com diferentes arquiteturas de controle foram realizadas para avaliar a escalabilidade do modelo proposto.

A verificação do comportamento do modelo de controle proposto e a avaliação do seu desempenho são realizadas por meio de estudos de caso do controle do trânsito urbano. Foram executadas simulações de diferentes cenários, para avaliar não somente o desempenho do modelo em situações controladas, mas também para avaliá-lo em situações típicas do trânsito urbano, como no caso da ocorrência de eventos não programados. Essa é a principal dificuldade de métodos de controle que se baseiam em modelos macroscópicos, pois, ao simplificar a dinâmica complexa do trânsito urbano, eles obtêm disparidades entre o modelo e a realidade e não têm a capacidade de reagir a fatores estocásticos. Os índices de desempenho adotados são o tempo médio de viagem dos veículos e a quantidade de veículos na rede urbana, os quais se alinham ao objetivo do modelo de controle, de evitar quedas drásticas na mobilidade do sistema.

Na próxima seção, será apresentado o modelo de rede neural bioinspirada proposto, assim como serão detalhados os modelos de neurônio e de plasticidades utilizados como base para a sua elaboração.

4.2. Modelo proposto

As equações que governam o modelo de rede neural bioinspirada proposto são baseadas nos princípios de Peláez e Andina (2013), cujas formas gerais são dadas pelas eqs.(5), (6) e (7). A 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. A equação determina a saída O de um neurônio com base na sua ativação A e no deslocamento s da sua função de ativação, o qual representa o mecanismo de adaptação do modelo, isto é, a plasticidade intrínseca (DESAI, 2003). Essa função de ativação simplifica o comportamento dos neurônios ao tratar os potenciais de ação como sinais contínuos e dispensar sua decodificação ao calcular o potencial de membrana. A eq.(7) determina o deslocamento s da função

de ativação de um neurônio com base em sua saída. Na equação, *v* é o coeficiente de adaptação: uma constante com valor pequeno que determina a taxa de adaptação dos neurônios. Dessa maneira, quanto maior é o valor de *s*, mais ativação *A* é necessária para produzir uma saída *O*. Da mesma forma, quanto menor é o valor de *s*, menos ativação *A* é necessária para produzir uma saída *O*.

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

$$O_i^{t+1} = 1/\left[1 + e^{-m(A_i^t - s_i^t)}\right]$$
(6)

$$s_i^{t+1} = (vO_i^t + s_i^t) / (v+1)$$
(7)

As entradas Q dos neurônios obedecem à restrição imposta pela eq.(8), cujo intervalo de valores também se aplica a saída O dos neurônios por causa da função sigmoide (eq.(6)). Esses dois fatores impõem a mesma restrição ao deslocamento *s* da função de ativação dos neurônios, o que é representado pela eq.(9).

$$0 < Q_j^t < 1 \tag{8}$$

$$0 < s_i^t < 1 \tag{9}$$

Assim como no mecanismo de adaptação proposto por Matsuoka (1985, 1987), a plasticidade intrínseca tem um papel central no comportamento oscilatório dos neurônios, utilizado para gerar a competição não supervisionada entre os neurônios e evitando que uma fase fique sempre inativa. Dessa maneira, a plasticidade intrínseca promove a transição entre neurônios ativos, e, portanto, entre fases semafóricas. Esse modelo de plasticidade é adequado ao modelo de neurônio adotado, concedendo-lhe a característica dos neurônios biológicos de adaptação. A Figura 14 ilustra a função de ativação adotada, correspondente à eq.(6), e seu deslocamento como consequência da plasticidade intrínseca. A figura mostra que um neurônio com alta atividade tem sua função de ativação deslocada para direita, necessitando assim uma maior ativação pós-sináptica para aumentar a probabilidade de disparo e gerar uma saída. O contrário ocorre com um neurônio



Figura 14 – Função de ativação e plasticidade intrínseca

Fonte: adaptado de Peláez e Andina (2013)

que apresenta baixa atividade, pois sua função de ativação é deslocada para a esquerda, o que causa seu disparo com menores níveis de ativação pós-sináptica.

A estrutura da rede neural bioinspirada proposta para controlar o trânsito urbano pode ser dividida em duas partes: 1) controle de uma intersecção e 2) coordenação de intersecções. A primeira parte é relativa ao controle de uma única intersecção, enquanto a segunda parte é responsável por coordenar a atividade de intersecções vizinhas para, por exemplo, formar ondas verdes.

4.2.1. Controle de uma intersecção

O controle de uma intersecção é feito pela parte da rede neural bioinspirada ilustrada na Figura 15. Na estrutura ilustrada, cada conjunto de neurônios q, p e h representa uma fase semafórica. Dessa maneira, intersecções com duas fases semafóricas possuem dois conjuntos de neurônios, enquanto intersecções com três fases semafóricas possuem três conjuntos e assim por diante. De acordo com Kandel et al. (2012), as células do sistema nervoso podem ser classificadas em três categorias funcionais: neurônios sensoriais, neurônios motores e interneurônios. Na Figura 15, os neurônios q representam neurônios sensoriais, os neurônios p

Figura 15 – Estrutura da rede neural bioinspirada para o controle de uma intersecção

A Receptor sensorial

O Neurônio sem plasticidade intrínseca

O Neurônios com plasticidade intrínseca

--- Inibitória --- Excitatória



Fonte: autoria própria

representam neurônios motores – ou excitatórios – e os neurônios *h* representam interneurônios.

Além disso, q_a , q_b , q_c , q_d , q_e e q_f representam receptores sensoriais, os quais medem a ocupação das vias relativas a cada fase semafórica. Dessa maneira, q_a mede a ocupação de uma faixa e q_b de outra em uma via com duas faixas. De acordo com Gokulan e Srinivasan (2014), o uso das ocupações das vias como entrada do sistema de controle é adequado porque elas refletem o atraso dos veículos ao atravessar a intersecção controlada. Geroliminis e Skabardonis (2011) e Zhang (2013) reforçam essa declaração, demonstrando que uma redução da eficiência do sistema de trânsito urbano quando uma via satura e causa o efeito de transbordamento (*spillover*). Esse efeito restringe a mobilidade dos veículos na rede urbana ao preveni-los de continuar seu trajeto pelas vias saturadas, o que, consequentemente, propaga o congestionamento para vias vizinhas (JANG; KIM; JANG, 2015). Os neurônios sensoriais, ou bipolares, q_1 , $q_2 e q_n$ agregam as entradas das fases semafóricas correspondentes e não possuem plasticidade intrínseca. De forma análoga, no corpo humano esse tipo de neurônio é responsável por transmitir a informação de sensores periféricos para o sistema nervoso. Os neurônios p_1 , $p_2 e p_n$ representam as fases semafóricas e produzem uma saída (O_{p1} , O_{p2} ou O_{pn}) igual a 1 quando sua fase semafórica correspondente está ativa. Como os neurônios p_1 , p_2 e p_n competem entre si, só um deles é capaz de produzir uma saída em cada momento, o que gera o comportamento oscilatório da rede neural bioinspirada. Essa competição natural (não supervisionada), ilustrada pela Figura 16 para o caso de uma intersecção com duas fases semafóricas, é consequência da ação dos interneurônios inibitórios *h*, das autapses, e da plasticidade intrínseca. Em relação à base biológica dessa estrutura neural, a influência dos interneurônios inibitórios no comportamento oscilatório de redes neurais biológicas foi investigada por Whittington e Traub (2003).

Na Figura 15, os neurônios h_1 , h_2 e h_n são os interneurônios inibitórios de cada fase semafórica. Tais 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 está ativa em cada momento. Os interneurônios se assemelham aos interneurônios biológicos locais, os quais possuem axônios curtos e formam sinapses com neurônios próximos em redes



Figura 16 – Comportamento dos neurônios p com entradas iguais e constantes

Fonte: autoria própria

locais (KANDEL et al., 2012). A rede neural bioinspirada proposta concilia dois tipos de inibição: por antecipação (*feed-forward*), a qual conecta as entradas da rede diretamente aos interneurônios inibitórios, antecipando variações na entrada e facilitando a transição de estados do neurônio; e por realimentação (*feedback*), a qual reflete o estado atual dos neurônios p e mantém sua ativação ao inibir os demais neurônios p.

Em relação às sinapses e seus pesos, as sinapses entre neurônios q e h originam inibição por antecipação, enquanto as sinapses entre neurônios p e h originam inibição por realimentação. As sinapses recorrentes dos neurônios p reforçam sua ativação, representando o efeito das autapses, as quais estão presentes em neurônios do koniocortex cerebral (OKHOTIN, 2006) e podem ser consideradas um mecanismo proprioceptivo (SAPUTRA et al., 2016). Os pesos sinápticos relacionados aos neurônios correspondentes à fase semafórica 1 são equivalentes aos pesos sinápticos relacionados aos neurônios correspondentes à fase semafórica 2. Dessa maneira, seus valores são determinados de acordo com o método apresentado na Subseção 4.2.3. Ao contrário dos trabalhos relacionados à utilização de redes neurais com plasticidade em longo prazo para o controle (SPALL; CHIN, 1994; CHOY et al. 2003; SRINIVASAN et al. 2006; HIREL et al. 2011; NICHOLS; MCDAID; SIDDIQUE, 2013; PELÁEZ; AGUIAR-FURUCHO; ANDINA, 2016), a rede neural bioinspirada proposta não tem como principal característica a plasticidade em longo prazo, ou seja, o aprendizado de trajetórias ou de modelos. Seus pesos sinápticos são determinados de acordo com o comportamento desejado, podendo ser oscilatório ou não.

Conforme corroborado por Yu et al. (2014), as principais vantagens do uso de redes neurais com comportamento oscilatório, característico da rede neural bioinspirada proposta, para o controle de sistemas complexos são sua estabilidade e sua adaptabilidade. Dessa maneira, a reatividade desejada está presente ao permitir a mudança imediata do comportamento oscilatório com base nas entradas do sistema, ao contrário da maior parte das redes neurais com comportamento oscilatório. O modelo proposto ainda permite incorporar conhecimento acerca do sistema controlado a partir das entradas da rede, de seus parâmetros, assim como da adição de novos neurônios e conexões sinápticas. Esses aspectos alteram o comportamento oscilatório da rede neural com base nas novas informações incorporadas.

4.2.2. Coordenação de intersecções

Como os fluxos de entrada de veículos de uma intersecção são os fluxos de saída de veículos de seus vizinhos imediatos, e vice-versa, uma relação de interdependência entre as intersecções vizinhas é estabelecida. No entanto, apesar de auxiliar a formação de ondas verdes, essa relação de interdependência não é suficiente para obter uma coordenação ótima entre as intersecções e ela não evita o efeito de transbordamento (*spillover*). Portanto, a coordenação das intersecções é realizada pela rede neural bioinspirada ilustrada na Figura 17, a qual coordena a atividade de duas redes neurais bioinspiradas responsáveis por controlar as intersecções-exemplo *A* e *B*. Os neurônios da rede neural bioinspirada apresentada na Figura 17 se assemelham aos interneurônios biológicos de projeção, os quais possuem axônios longos e transmitem sinais a distâncias consideráveis, de uma região cerebral para outra (KANDEL et al., 2012).

Na figura, o neurônio $p_{1,A}$ representa o neurônio p da fase semafórica 1 da intersecção A, enquanto o neurônio $p_{1,B}$ representa o neurônio p da fase semafórica



Figura 17 – Estrutura da rede neural bioinspirada para a coordenação de intersecções

Fonte: autoria própria

1 da intersecção *B*. Dessa maneira, as fases semafóricas 1 – que controlam fluxos de veículos na mesma direção – das intersecções são coordenadas. Além disso, $q_{a,A}$ é o receptor sensorial q_a da intersecção *A* e $q_{a,B}$ é o receptor sensorial q_a da intersecção *B*. Todos os outros neurônios não fazem parte das redes neurais bioinspiradas responsáveis pelo controle das intersecções; e todas as sinapses não possuem rótulos porque seus pesos sinápticos não são ajustáveis, sendo iguais a 1. Uma estrutura neural semelhante à apresentada na Figura 17 é necessária para coordenar a atividade de quaisquer duas intersecções. Tal rede neural bioinspirada tem dois princípios básicos de funcionamento: 1) armazenar a informação que uma fase semafórica foi ativada até que a fase semafórica correspondente da intersecção seguinte esteja pronta para se tornar ativa, melhorando sua coordenação; e 2) inibir a fase semafórica nos casos em que a ocupação da intersecção seguinte está alta, como forma de evitar o efeito de transbordamento.

O segundo princípio é realizado pelos interneurônios *b*, os quais inibem os neurônios *p* de forma direta de acordo com a ocupação da intersecção seguinte. Em relação ao primeiro princípio, o momento ótimo para que a fase semafórica da intersecção seguinte se torne ativa depende de sua ocupação. Se a intersecção seguinte tiver uma alta ocupação, sua fase semafórica deve se tornar ativa assim que a fase semafórica da intersecção precedente for ativada, para aliviar a ocupação antes que um novo pelotão de veículos chegue. De forma contrária, se a intersecção seguinte tiver uma baixa ocupação, sua fase semafórica deve esperar que o pelotão de veículos se aproxime do cruzamento antes de ser ativada. Dessa maneira, essa rede neural bioinspirada age como segue.

Quando a fase semafórica 1 da intersecção *A* se torna ativa, o neurônio $p_{1,A}$ produz uma saída, ativando o interneurônio excitatório c_{A-B} . O interneurônio c_{A-B} se mantém ativo devido a sua autapse e a não possuir plasticidade intrínseca, a qual reduziria gradualmente sua saída. No entanto, por causa da inibição axo-axônica do interneurônio a_{A-B} , a saída do interneurônio c_{A-B} somente chega aos neurônios h_{A-B} e $p_{1,B}$ caso o interneurônio inibitório a_{A-B} não esteja produzindo uma saída. O interneurônio inibitório a_{A-B} produz uma saída quando a ocupação $q_{a,B}$ está baixa, o que significa que o sinal de coordenação (saída do interneurônio c_{A-B}) deve esperar para chegar ao neurônio $p_{1,A}$ e ativá-lo. Quando a ocupação $q_{a,B}$ se torna mais alta devido ao pelotão de veículos que entra na intersecção, o interneurônio a_{A-B} para de produzir uma saída e os neurônios h_{A-B} e $p_{1,B}$ são ativados. Dessa maneira, a

atividade do neurônio $p_{1,B}$ é coordenada com a atividade do neurônio $p_{1,A}$ e o interneurônio h_{A-B} inibe o interneurônio c_{A-B} , cessando sua auto ativação. Somogyi, Freund and Cowey (1982) investigaram os interneurônios axo-axônicos no córtex cerebral de ratos, gatos e macacos. De acordo com os autores, a ação inibitória das sinapses axo-axônicas permite a sincronização da atividade de neurônios excitatórios, gerando uma coordenação natural.

4.2.3. Determinação dos parâmetros

A rede neural bioinspirada apresentada na Figura 15 possui 7 parâmetros: 6 pesos sinápticos e o coeficiente de adaptação *v*. Devido ao grande número de combinações possíveis (cerca de 10 milhões), e a seu amplo espectro de comportamentos resultantes, um método para determinar os parâmetros do modelo de acordo com o comportamento desejado é proposto. O comportamento de cada rede neural bioinspirada para o controle de uma intersecção pode ser caracterizado por duas propriedades intrínsecas do modelo: a frequência natural de oscilação Ω e a sensibilidade às entradas *S*. A primeira propriedade intrínseca é referente à frequência de oscilação das saídas dos neurônios *p* quando as entradas do sistema são constantes, o que ocorre, por exemplo, em redes urbanas saturadas. Apesar da frequência de oscilação poder variar de Ω , esse parâmetro define o comportamento em regime permanente do modelo.

Como cada parâmetro da rede neural bioinspirada tem um nível diferente de influência em Ω , uma análise de sensibilidade experimental foi conduzida para determinar os parâmetros mais influentes. A analise consistiu em variar cada parâmetro de seu limite inferior a seu limite superior (0 e 1, respectivamente), enquanto os outros parâmetros foram mantidos em seu valor base, definido empiricamente em (CASTRO; MARTINI; HIRAKAWA, 2014). O valor base dos parâmetros é: *v* igual a 0,07, *w_n* e *w_q* iguais a 1, *w_p*, *w_{qp}* e *w_{qh}* iguais a 0,4 e *w_h* e *w_{ph} iguais* a 0,3. A Tabela 1 apresenta a influência relativa de cada parâmetro sobre Ω e mostra que *w_p* e *v* têm uma influência relativa combinada de 88,32%. Portanto, Ω pode ser definido como uma função de *w_p* e *v*, como representado na Figura 18. O gráfico da figura não abrange todos os valores de *w_p* e *v* porque os valores apresentados são suficientes para representar Ω . Ademais, como pequenas

	Wp	υ	W _{ph}	W _{qp}	W _h	W _{qh}
Influência (%)	56,88	31,44	4,15	3,57	2,44	1,52

Tabela 1 – Influência relativa dos parâmetros da rede neural bioinspirada em Ω

variações de Ω não causam um impacto significante na dinâmica do trânsito urbano, Ω é discretizado em 5 valores, como mostrado na Tabela 2.

A segunda propriedade intrínseca da rede neural bioinspirada proposta é a sensibilidade às entradas *S*, a qual considera como variações das entradas do sistema (ocupações das vias) afetam a transição entre fases semafóricas. Dessa maneira, *S* é uma medida de quão reativo é o modelo, como determinado pela eq.(10). Na equação, w_{qp} e w_{qh} têm valores iguais para garantir uma dinâmica inibitória balanceada, como imposto pela eq.(11). Um valor alto de *S* estabelece uma influência alta das entradas do sistema sobre a dinâmica dos neurônios, tendo como consequência uma alta reatividade do modelo. Por sua vez, valores baixos de *S* requerem maiores variações das entradas do sistema a frequência de oscilação da rede neural bioinspirada próxima de Ω devido a uma maior inércia.

$$S = \left(w_{qp} + w_{qh}\right) / w_p \tag{10}$$



Figura 18 – Estrutura da rede neural bioinspirada para a coordenação de intersecções

Fonte: Castro et al. (2015)

Wp	0.6	0.5	0.4	0.3	0.3
V	0.05	0.11	0.16	0.19	0.30
Ω	0.05	0.10	0.15	0.20	0.25

Tabela 2 – Frequência natural de oscilação Ω como uma função de w_p e v

$$w_{qp} = w_{qh} \tag{11}$$

. . . .

De acordo com o método proposto, w_p e v são determinados primeiro, com base no Ω desejado. Depois, w_{qp} e w_{qh} são determinados de acordo com o S desejado. Os parâmetros remanescentes são mantidos em seu valor base: w_q igual a 1 e w_{ph} e w_h iguais a 0,3. Em vez de otimizar 7 parâmetros – com cerca de 10 milhões de combinações, visto que cada parâmetro é discretizado em 10 valores possíveis – de acordo com as características físicas de cada cenário e com o comportamento desejado, apenas Ω e S precisam ser otimizados (25 combinações, pois cada parâmetro possui 5 valores possíveis). Além disso, devido ao pequeno número de combinações, essa otimização pode ser feita empiricamente.

Os principais parâmetros da rede neural bioinspirada responsável por coordenar intersecções não são os pesos sinápticos, os quais são todos iguais a 1, mas os deslocamentos *s* das funções de ativação dos neurônios. Enquanto os neurônios *p* e *h* fazem parte da rede neural bioinspirada responsável pelo controle de intersecções e mantém seus parâmetros, os parâmetros dos interneurônios *a*, *b* e *c* precisam ser determinados.

O deslocamento *s* da função de ativação dos interneurônios *c*, ou s_c , é igual a 0,1 para que qualquer saída dos neurônios *p* os ative. Os interneurônios *b* possuem o valor de seu limite inferior alterado, igual a 0,8. Portanto, só uma ocupação superior a 0,8 é capaz de produzir uma saída significativa, indicando que a intersecção está quase saturada. Os neurônios *a* são interneurônios inibitórios sem plasticidade intrínseca. Desse modo, o deslocamento *s* da sua função de ativação determina o momento em que o sinal de coordenação é enviado ao neurônio *p* da intersecção seguinte. Como a coordenação ótima de intersecções depende das características físicas das vias que as conectam (por exemplo, do número de faixas e do

comprimento da via), o parâmetro *s* dos interneurônios *a*, ou s_a , também é otimizado empiricamente, assim como Ω e *S*.

5. RESULTADOS

Nesse capítulo, são analisadas a convergência e a estabilidade da rede neural bioinspirada proposta, assim como seu tempo de computação, sua complexidade computacional e seu desempenho no controle do trânsito urbano. Tais análises e as simulações a elas correspondentes foram realizadas com o auxílio das ferramentas MATLAB e SUMO (Simulation of Urban MObility) (BEHRISCH et al., 2011). O modelo da rede neural bioinspirada foi programado na linguagem M do MATLAB, utilizando o mesmo método apresentado por Peláez, Aguiar-Furucho e Andina (2016), no qual w é uma matriz que representa todas as conexões da rede neural bioinspirada e Q, O e s são vetores (ver eqs.(5)-(7)). Por sua vez, o modelo do sistema de trânsito urbano foi programado em XML (eXtensible Markup Language), linguagem utilizada pelo SUMO. Todos os veículos gerados nas simulações têm o mesmo tamanho, de acordo com a suposição Passenger Car Equivalent (PCE) (KELLER; SAKLAS, 1984), e um comportamento de direção estocástico, com sigma (parâmetro do simulador SUMO) igual a 0,5. Para executar as simulações e analisar os resultados, foi utilizado o protocolo TraCl4Matlab (GIL et al., 2014), que adota o paradigma cliente-servidor e permite a interação entre o SUMO (servidor) e o MATLAB (cliente).

A Figura 19 ilustra, por meio de um fluxograma, o funcionamento do algoritmo programado no MATLAB, o qual contempla a rede neural bioinspirada e a interação entre o MATLAB e o SUMO para a execução da simulação. Após o início da execução do arquivo do MATLAB, os parâmetros da rede neural bioinspirada são inicializados. Dessa maneira, tanto a inclinação da função sigmoide *m*, quanto o coeficiente de adaptação *v* e a matriz de todas as conexões da rede neural bioinspirada *w* tem seus valores determinados. Em seguida, os parâmetros do SUMO (programados separadamente em XML) são importados, para que o cenário de simulação, assim como suas configurações, se tornem conhecidas no MATLAB. Define-se, também, a duração da simulação que será executada. Com a informação acerca do número de semáforos no cenário em questão, configura-se as possíveis fases semafóricas; ou seja, determina-se as combinações de semáforos com sinais verdes e vermelhos que serão utilizadas.

Após tais configurações, é executado o comando que inicia a simulação no SUMO. A primeira etapa do algoritmo durante a simulação é importar do SUMO para







o MATLAB a quantidade de veículos em cada um das vias do cenário simulado. Tais valores compõem a entrada da rede neural bioinspirada e, após sua obtenção, determina-se a ativação *A*, a saída *O* e o deslocamento *s* da função sigmoide dos neurônios. Com os valores das saídas *O* dos neurônios, são determinadas as fases semafóricas ativas e, desse modo, essa informação é exportada do MATLAB ao SUMO. Caso a simulação ainda não tenha atingido sua duração total, o ciclo se repete a partir da importação da quantidade de veículos nas vias.

5.1. Convergência e estabilidade

Como todos os neurônios p da rede neural bioinspirada proposta estão interconectados por meio dos interneurônios h, o comportamento de um neurônio p

reflete o comportamento da rede neural como um todo. Dessa maneira, conforme o método elucidado por Fuchs (2013) e previamente aplicado à rede neural bioinspirada proposta (CASTRO; MIGUEL; MACHADO; HIRAKAWA, 2015), a partir da avaliação de convergência da rede neural bioinspirada e da análise da estabilidade de um neurônio p, é possível inferir a estabilidade da rede neural bioinspirada. Com esse objetivo, os autovalores do Jacobiano de um neurônio p são avaliados no ponto de equilíbrio da rede neural bioinspirada.

Para realizar a análise de convergência e estabilidade do modelo proposto, a intersecção 1 do cenário ilustrado na Figura 20 é utilizada. Como essa intersecção possui duas fases semafóricas, a rede neural bioinspirada da Figura 21 é adotada para controlá-la. Ademais, como a rede neural responsável por coordenar as intersecções gera somente sinais de facilitação na forma de impulsos, apenas a convergência e a estabilidade da rede neural bioinspirada para o controle de uma única intersecção são analisadas. Tal rede neural bioinspirada deve originar um comportamento oscilatório, promovendo a transição entre fases semafóricas ativas.

Iniciando a análise pela convergência da rede neural bioinspirada, suas variáveis de estado para o controle de uma única intersecção com duas fases semafóricas são apresentadas na eq. (12).



Figura 20 - Cenário da análise

Fonte: autoria própria

Figura 21 – Estrutura da rede neural bioinspirada para controlar uma intersecção com duas fases



Fonte: autoria própria

$$x^{t} = \left[A_{p1}^{t}; A_{p2}^{t}; A_{h1}^{t}; A_{h2}^{t}; s_{p1}^{t}; s_{p2}^{t}; s_{h1}^{t}; s_{h2}^{t}\right]$$
(12)

De acordo com Fuchs (2013), os pontos-fixos (pontos de equilíbrio/convergência) de um sistema dinâmico discreto são obtidos ao substituir as varáveis de estado do sistema na eq. (13).

$$x^{t+1} - x^t = 0 \tag{13}$$

O sistema de 8 equações resultante da substituição das variáveis apresentadas na eq.(12) na eq. (13) está representado na eq.(14).

$$\begin{cases}
A_{p1}^{t+1} - A_{p1}^{t} = 0 \\
A_{p2}^{t+1} - A_{p2}^{t} = 0 \\
A_{h1}^{t+1} - A_{h1}^{t} = 0 \\
A_{h2}^{t+1} - A_{h2}^{t} = 0 \\
s_{p1}^{t+1} - s_{p1}^{t} = 0 \\
s_{p2}^{t+1} - s_{p2}^{t} = 0 \\
s_{h1}^{t+1} - s_{h1}^{t} = 0 \\
s_{h2}^{t+1} - s_{h2}^{t} = 0
\end{cases}$$
(14)

Dessa maneira, identificam-se duas formas gerais nessas equações, uma referente à ativação A_i dos neurônios, representada na eq.(15), e uma referente ao deslocamento s_i das funções de ativação dos neurônios, representada na eq.(16).

$$A_i^{t+1} - A_i^t = 0 (15)$$

$$s_i^{t+1} - s_i^t = 0 (16)$$

A eq.(16) é desenvolvida ao substituir o termo s_i^{t+1} pela eq.(7), como apresentado na eq.(17a) e na eq.(17b).

$$\frac{v O_i^t + s_i^t}{v+1} - s_i^t = 0$$
(17a)

$$O_i^t = s_i^t \tag{17b}$$

Substituindo esse resultado na eq.(6), a relação entre a ativação dos neurônios e o deslocamento de sua curva de ativação no ponto de equilíbrio do sistema é estabelecida, como apresentado na eq.(18a), na eq.(18b) e na eq.(18c).

$$s_i^t = \frac{1}{1 + e^{-m(A_i^t - s_i^t)}}$$
 (18a)

$$e^{-m(A_i^t - s_i^t)} = \frac{1 - s_i^t}{s_i^t}$$
 (18b)

$$A_i^t = s_i^t - \frac{1}{m} ln \left(\frac{1}{s_i^t} - 1\right)$$
(18c)

Substituindo o termo A_i^t da eq.(15) pelo resultado da eq.(18c) e o termo A_i^{t+1} da eq.(15) pela eq.(5), conclui-se que o ponto-fixo da rede neural bioinspirada depende de suas entradas, as ocupações Q_j das vias da intersecção controlada, como apresentado na eq.(19).

$$\sum_{j \in N_i} w_{xy} Q_j^t - s_i^t + \frac{1}{m} ln \left(\frac{1}{s_i^t} - 1 \right) = 0$$
(19)

Utilizando a equação geral representada pela eq.(19) nas equações específicas da ativação A_i cada neurônio, apresentadas na eq.(14), e solucionando numericamente o novo sistema de equações com o MATLAB, obtém-se os pontos-fixos do sistema. Dessa maneira, a resolução numérica desse sistema de equações demonstra que a rede neural bioinspirada possui apenas um ponto-fixo, o qual é dependente das entradas do sistema. Tal resultado era esperado por se tratar de um sistema de 8 equações e 8 variáveis. Portanto, quando as entradas do sistema (ocupações das vias) variam, também varia o ponto-fixo da rede neural bioinspirada.

A partir do ponto-fixo da rede neural bioinspirada, determinam-se os autovalores λ do Jacobiano de um neurônio p no ponto-fixo obtido para estabelecer a estabilidade do neurônio e, assim, a estabilidade da rede neural bioinspirada. Tais autovalores são obtidos de acordo com a eq. (20). Na equação, *I* é referente a uma matriz identidade e *det()* é relativo ao determinante da matriz que está dentro dos parênteses.

$$det(J - \lambda I) = 0 \tag{20}$$

O Jacobiano do neurônio p_1 , escolhido para avaliar a estabilidade da rede neural bioinspirada, é calculado a partir das derivadas parciais de suas variáveis de estado A_{p1} e s_{p1} , como demonstrado pela eq.(21). O resultado dessas derivadas parciais, ou seja, o Jacobiano do neurônio p_1 , está representado na eq. (22).

$$J = \begin{bmatrix} \frac{\partial A_{p1}}{\partial A_{p1}} & \frac{\partial A_{p1}}{\partial s_{p1}} \\ \frac{\partial s_{p1}}{\partial A_{p1}} & \frac{\partial s_{p1}}{\partial s_{p1}} \end{bmatrix}$$
(21)

$$J = \begin{bmatrix} \frac{mw_{p}e^{m(s_{p1}+A_{p1})}}{\left(e^{ms_{p1}}+e^{mA_{p1}}\right)^{2}} & -\frac{mw_{p}e^{m(s_{p1}+A_{p1})}}{\left(e^{ms_{p1}}+e^{mA_{p1}}\right)^{2}} \\ \frac{1}{v+1}\left(\frac{mve^{m(A_{p1}+s_{p1})}}{\left(e^{mA_{p1}}+e^{ms_{p1}}\right)^{2}}\right) & \frac{1}{v+1}\left(1-\frac{mve^{m(A_{p1}+s_{p1})}}{\left(e^{mA_{p1}}+e^{ms_{p1}}\right)^{2}}\right) \end{bmatrix}$$
(22)

De acordo com Fuchs (2013), ao substituir A_{p1} e s_{p1} por seus valores correspondentes ao ponto-fixo do sistema na eq.(20) obtêm-se os autovalores do Jacobiano do neurônio.

Como o ponto-fixo do sistema é dependente das entradas da rede neural bioinspirada, é possível representar os autovalores do Jacobiano de p_1 como uma função delas. Ademais, apesar de possuir dois neurônios que agregam as entradas da rede neural bioinspirada ($q_1 e q_2$), como as saídas desses neurônios são normalizadas, é possível representar os autovalores do Jacobiano de p_1 como uma função de apenas uma delas (O_{q1} , por exemplo). As restrições estabelecidas pela normalização das saídas de $q_1 e q_2$ estão apresentadas na eq.(23) e na eq.(24).

$$O_{q1} = O_{q1} / (O_{q1} + O_{q2}) \tag{23}$$

$$O_{q2} = 1 - O_{q1} \tag{24}$$

Como o neurônio p_1 possui duas variáveis de estado (A_{p1} e s_{p1}), e é, portanto, um sistema de segunda ordem, seu Jacobiano tem dois autovalores, os quais são ilustrados na Figura 22 como funções de O_{q1} . As partes real e imaginária dos autovalores estão representadas por linhas cheias e tracejadas, respectivamente, indicando a presença de duas bifurcações de Hopf (SARMAH; BAISHYA; DAS, 2014), para valores de O_{q1} iguais a 0,1 e 0,9. Bifurcações de Hopf caracterizam transições entre um ponto de equilíbrio e uma solução periódica, a qual, nesse caso, ocorre quando os autovalores com partes somente reais se tornam um par de complexos conjugados. No caso do controle do trânsito urbano, uma solução periódica representa a transição sequencial entre fases semafóricas, enquanto um



Figura 22 – Autovalores λ do Jacobiano do neurônio p_1 como funções da saída O_{q1} do neurônio q_1

Fonte: Castro et al. (2015)

ponto de equilíbrio representa a manutenção de uma única fase semafórica. De acordo com a Figura 22, quando O_{q1} é igual ou menor a 0,1 ou maior ou igual a 0,9, pontos de equilíbrio são obtidos. Dessa maneira, no primeiro caso, a fase semafórica 1 permanece inativa e, no segundo caso, a fase semafórica 1 permanece ativa.

As Figuras 23 e 24 apresentam as variáveis de estado do neurônio p_1 em um gráfico de duas dimensões, mostrando o comportamento discutido e que as bifurcações de Hopf em questão são supercríticas, isto é, a solução periódica resultante corresponde a um ciclo-limite estável. Na Figura 23, O_{q1} tem um valor maior que 0,9, enquanto na Figura 24 O_{q1} é igual a 0,5. Ademais, nas figuras, os pontos pretos correspondem às condições iniciais das variáveis de estado, enquanto o ponto vermelho da Figura 23 corresponde ao ponto de equilíbrio e as flechas vermelhas da Figura 24 representam o ciclo-limite estável.

A análise de estabilidade apresentada nessa subseção pode ser aplicada a qualquer conjunto de parâmetros da rede neural bioinspirada, revelando seu comportamento dinâmico de forma direta. Como mostrado na Figura 22, o gráfico de estabilidade é simétrico, o que indica que a convergência de O_{p1} para um equilíbrio inativo causa a convergência de O_{p2} para um equilíbrio ativo, e vice-versa. Além disso, quando um comportamento oscilatório é obtido, ambos os neurônios produzem saídas oscilatórias. Dessa maneira, o comportamento da rede neural bioinspirada é extrapolado do comportamento do neurônio p_1 .





Fonte: Castro et al. (2015)



Figura 24 – Trajetória das variáveis de estado (A e s) do neurônio p_1 para O_{q_1} igual a 0,5

Fonte: Castro et al. (2015)

5.2. Tempo de computação e complexidade computacional

Como forma de avaliar o tempo de computação e a complexidade computacional do modelo proposto, foram realizadas simulações com diferentes quantidades de intersecções controladas e, desse modo, com diferentes quantidades de neurônios. Assim como na subseção anterior, as intersecções utilizadas nas simulações possuem duas fases semafóricas e quatro vizinhos, como é o caso da intersecção 1, ilustrada na Figura 20. O computador utilizado para realizar as simulações possui um processador Intel Core i7-3517U com 1,9GHz e 8GB de RAM. Cada iteração da rede neural bioinspirada é composta pelas eqs.(5)-(7), as quais são calculadas uma vez para cada neurônio. As simulações realizadas comtemplaram o controle de 1, 1000, 2000, 3000, 4000, 5000, 6000, 7000, 8000, 9000 e 10.000 intersecções. Tais quantidades de intersecções foram utilizadas, pois, segundo um estudo da Companhia de Engenharia de Tráfego de São Paulo (CET SP) realizado em 2013 (COMPANHIA DE ENGENHARIA DE TRÁFEGO, 2013), a cidade de São Paulo possuía, na época, cerca de 6.000 intersecções com semáforos.

Considerando que 22 neurônios são necessários para controlar cada intersecção, o número de neurônios de cada configuração simulada é: 22; 22.000; 44.000; 66.000; 88.000; 110.000; 132.000; 154.000; 176.000; 198.000; e 220.000. Dos 22 neurônios relativos a cada intersecção, 6 fazem parte da rede neural bioinspirada responsável pelo controle da intersecção (Figura 15), enquanto 16

neurônios fazem parte da rede neural bioinspirada responsável pela coordenação das intersecções (Figura 17). Esses 16 neurônios são divididos em quatro redes neurais bioinspiradas, uma para a coordenação com cada vizinho da intersecção. Ademais, cada intersecção computa somente metade da rede neural bioinspirada ilustrada na Figura 17: 1 neurônio a, 1 neurônio b, 1 neurônio c e 1 neurônio h, em adição ao neurônio p que já é computado pela rede neural bioinspirada para o controle da intersecção.

Os resultados de 100 simulações para cada configuração estão apresentados na Figura 25 por meio do tempo de processamento médio de cada configuração e de uma função de ajuste linear dos pontos obtidos. Os coeficientes de variação dos pontos não estão ilustrados na figura devido a seu valor pequeno: cerca de 1% para cada ponto. O tempo de processamento da rede neural bioinspirada para controlar uma intersecção é de 0,0534ms, o qual representa o tempo de processamento de cada intersecção para uma arquitetura de controle distribuída. Por sua vez, o tempo de processamento da rede neural bioinspirada para controlar 10.000 intersecções é de 0,5185s, o que mostra que o processamento do modelo proposto não seria um impeditivo para realizar o controle do trânsito urbano com uma arquitetura centralizada. Desse modo, a equação presente na Figura 25 estima o tempo de processamento y de x intersecções controladas em uma arquitetura de controle centralizada. Uma rede urbana com 10.000 intersecções também poderia ser



Figura 25 – Avaliação do tempo de processamento e da complexidade computacional

Fonte: autoria própria

dividida, por exemplo, em 5 regiões com 2.000 intersecções cada, as quais possuiriam controladores regionais com um tempo de processamento de 0,1035s.

Como referências, o tempo de processamento de cada intersecção com o método de controle de Tettamanti et al. (2014) é de 7,60s e com o método de controle de Ye et al. (2016) é de 1,15s. No entanto, uma comparação direta dos tempos de processamento não é conclusiva, pois as abordagens de controle são baseadas em princípios diferentes. Enquanto a rede neural bioinspirada estrutura o conhecimento de uma maneira computacionalmente eficiente, abordagens baseadas em controle preditivo baseado em modelo são métodos iterativos. Ademais, apesar dos resultados obtidos serem satisfatórios, o tempo de processamento da rede neural bioinspirada poderia ser reduzido por uma implementação em *hardware*. Enquanto o MATLAB processa o estado de cada neurônio de forma sequencial, uma implementação em hardware aproveitaria a natureza paralela da rede neural bioinspirada. De acordo com o mesmo princípio, em vez de reduzir o tempo de processamento, um processador com menor capacidade e mais barato poderia ser utilizado para obter os mesmos resultados das simulações em *software*.

A Figura 25 também mostra que a complexidade computacional da rede neural bioinspirada proposta é linear (O(N)), isto é, o tempo de processamento da rede neural bioinspirada aumenta de forma linear com o aumento do número de neurônios. Esse resultado é contraintuitivo, pois a multiplicação da matriz w com o vetor Q na eq.(5) deveria gerar uma complexidade computacional quadrática (O(N²)). No entanto, a complexidade computacional obtida é linear porque a maior parte da matriz w é composta por zeros, o que ocorre quando não há uma sinapse entre os neurônios em questão. Esse fato ocorre porque a matriz w representa todos os pesos sinápticos da rede neural bioinspirada, assim como o vetor Q representa a saída de todos os neurônios da rede, e o maior número de sinapses feitas por um único neurônio é 3. Sendo assim, o peso sináptico do neurônio cuja ativação está sendo calculada pela eq.(5) com os neurônios representados no vetor Q com os quais ele não se conecta é zero. Dessa maneira, uma rede neural na qual todos os neurônios se conectassem entre si teria uma complexidade computacional quadrática. Além disso, a eq.(6) e a eq.(7) só possuem multiplicações escalares e adições e subtrações de matrizes, as quais originam uma complexidade computacional linear.

5.3. Simulações do trânsito urbano

Para avaliar o desempenho da rede neural bioinspirada no controle do trânsito urbano, esta foi comparada a um método de controle adaptativo, o qual representa as principais características dos métodos de controle revisados no Capítulo 3: adaptabilidade e tomada de decisão após cada ciclo semafórico. Da mesma forma como feito por Zhu et al. (2015), o método de controle adaptativo é baseado no algoritmo de Wunderlich et al. (2008), precursor dos métodos de controle baseados em contrapressão. Tal algoritmo adota ciclos semafóricos de 2 minutos e prioriza, proporcionalmente, as fases semafóricas com filas de veículos mais longas para determinar os tempos de verde. Dessa maneira, a distribuição do tempo de verde de duas fases semafóricas (f1 e f2) é representado pelas eqs.(25) e (26). Nas equações, t_{r1} é o tempo de verde da fase semafórica f_1 em segundos, enquanto t_{r2} é o tempo de verde da fase semafórica f_1 e q_{r2} é a ocupação das vias relacionadas à fase semafórica f_2 .

$$t_{f1} = 120 \, q_{f1} / (q_{f1} + q_{f2}) \tag{25}$$

$$t_{f2} = 120 - t_{f1} \tag{26}$$

As simulações realizadas utilizam o cenário ilustrado na Figura 20 e são divididas em dois conjuntos: demanda balanceada, no qual os fluxos de veículos de todas as vias são equivalentes; e demanda desbalanceada, no qual a adaptabilidade dos métodos de controle é investigada. Assim como adotado por Diakaki, Papageorgiou e Aboudolas (2002) e Ye et al. (2016), o indicador de desempenho adotado é o tempo médio de viagem dos veículos além do número total de veículos na intersecção 1. Todas as simulações duram 1 hora e 10 simulações foram feitas para cada configuração. Os tempos médios de viagem apresentados são valores médios e seus coeficientes de variação não são apresentados devido a seus valores pequenos, cerca de 1% em todos os casos.

Os parâmetros da rede neural bioinspirada utilizados nas simulações foram determinados de acordo com o método apresentado no Capítulo 4. Dessa maneira, Ω , S e s_a foram determinados empiricamente, e seus valores são respectivamente:

0,20; 2,67; e 0,55. Ainda segundo o método proposto, os parâmetros restantes são: coeficiente de adaptação *v* igual a 0,195; w_p igual a 0,3; w_{qp} e w_{qh} iguais a 0,4; w_h e w_{ph} iguais a 0,3; e w_q igual a 1.

5.3.1. Demanda balanceada

O primeiro conjunto de simulações avalia o desempenho dos métodos de controle com diferentes níveis de demanda constante. Em cada configuração de demanda, fluxos de veículos igualmente distribuídos são gerados nas extremidades do cenário. A Figura 26 mostra o tempo médio de viagem dos veículos para cada configuração de demanda, enquanto a Figura 27 mostra o número total de veículos na intersecção 1 ao longo de uma simulação com 2,7 veículos por segundo de demanda.

Na Figura 26, a demanda de 2,5 veículos por segundo representa um trânsito leve, enquanto a demanda de 3,0 veículos por segundo representa um trânsito congestionado e os outros valores de demanda representam cenários intermediários. Os resultados apresentados na Figura 26 mostram que a rede neural bioinspirada é, em média, 25,94% melhor do que o método de controle adaptativo. Tais resultados são atribuídos à resposta rápida da rede neural bioinspirada, o que a permite adequar os tempos de verde às pequenas variações nos fluxos de veículos, decorrentes do comportamento dos motoristas, e a sua capacidade de coordenar as intersecções considerando estas variações. Dessa maneira, as ondas verdes







Figura 27 - Número de veículos na intersecção 1 ao longo do tempo (demanda balanceada)

Fonte: autoria própria

formadas pela rede neural bioinspirada são mais eficazes do que as formadas pelo método de controle adaptativo, as quais são interrompidas quando o comportamento dos motoristas varia muito.

Por sua vez, a Figura 27 mostra a diferença no desempenho dos dois métodos de controle com gráficos do número de veículos na intersecção 1 ao longo do tempo. A diferença do número de veículos nesta intersecção permanece constante ao longo da simulação, mantendo um valor de 40 veículos de diferença. Dessa maneira, o número de veículos no caso do método de controle adaptativo é, aproximadamente, o dobro do número de veículos no caso da rede neural bioinspirada.

5.3.2. Demanda desbalanceada

Cenários com demanda desbalanceada ocorrem com frequência no trânsito urbano (WUNDERLICH et al., 2008). O primeiro cenário investigado (Cenário 1) é relativo a um aumento repentino da demanda em um dos pontos de origem dos fluxos de veículos. Uma demanda inicial de 2,5 veículos por segundo é aumentada para 2,75 veículos por segundo, com o adicional de 0,25 sendo gerado pelo lado direito da intersecção 3 dos 2.000 aos 2.300 segundos do tempo de simulação. O segundo cenário avaliado (Cenário 2) considera a diferença entre vias arteriais e vias secundárias. Dessa maneira, as vias que conectam as intersecções numeradas
são consideradas arteriais e possuem uma demanda duas vezes maior que as vias secundárias. O Cenário 2 possui uma demanda total de 3,0 veículos por segundo.

A Figura 28 evidencia a capacidade de adaptação da rede neural bioinspirada, assim como a importância de uma coordenação refinada entre intersecções. A rede neural bioinspirada apresenta um resultado 29,53% melhor que o método de controle adaptativo em relação ao Cenário 1 e 10,53% melhor em relação ao Cenário 2. A diferença percentual menor de desempenho no Cenário 2 é devida à alta demanda das vias arteriais, a qual causou um nível de congestionamento extremo. No entanto, mesmo em um cenário com alto nível de congestionamento, a rede neural bioinspirada foi capaz de se diferenciar do método de controle adaptativo em termos de desempenho. Apesar de a diferença percentual ser de 10,53% no Cenário 2, contra 29,53% no Cenário 1, a diferença entre tempos médios de viagem foi de 32 segundos no Cenário 2, enquanto essa diferença foi de 44 segundos no Cenário 1.

O número de veículos na intersecção 1 durante uma simulação do Cenário 1 é apresentado na Figura 29. Observa-se que o método de controle adaptativo possui um número de veículos maior por um período após o aumento de demanda, enquanto a rede neural bioinspirada foi capaz de adaptar seu comportamento para compensar tal distúrbio, mantendo o número de veículos na intersecção no mesmo nível que possuía anteriormente à ocorrência do distúrbio. A adaptação do comportamento da rede neural bioinspirada também se mostra nas oscilações do



Figura 28 – Tempo médio de viagem dos veículos em cenários com demanda desbalanceada

Fonte: autoria própria



Figura 29 – Número de veículos na intersecção 1 ao longo do tempo (demanda desbalanceada)

Fonte: autoria própria

número de veículos da intersecção em torno de seu valor médio. É notável que o padrão de oscilação muda pouco depois do início do distúrbio, o qual ocorre aos 2.000s de simulação. Essa simulação evidencia tanto a importância da resposta rápida a distúrbios, quanto o papel crítico da coordenação entre intersecções para melhorar o controle do trânsito urbano.

5.4. Discussão acerca dos resultados

Os resultados obtidos nos três tipos de investigação realizados resumem a contribuição do modelo de rede neural bioinspirada para o controle do trânsito urbano. A análise de convergência e estabilidade do modelo prova de maneira formal a existência de um único ponto de equilíbrio do controlador para cada estado do sistema. Além disso, tal análise ainda fundamenta matematicamente o comportamento da rede neural bioinspirada como uma função de seus parâmetros e das entradas do sistema controlado. A importância da abordagem matemática quanto à convergência e a estabilidade de redes neurais bioinspiradas foi discutida por Yu et al. (2014). Os autores ressaltam a falta de uma análise matemática do comportamento das redes neurais bioinspiradas dos trabalhos revisados por eles.

Em relação ao estudo do tempo de processamento e da complexidade computacional, os resultados obtidos evidenciam uma contribuição central: a

capacidade de resposta rápida da rede neural bioinspirada. Dessa maneira, os tempos de processamento obtidos possibilitam a aplicação prática do modelo proposto em um sistema de controle real. Ademais, apesar de ser proposta como um sistema distribuído, a rede neural bioinspirada pode ser implementada como um sistema de controle centralizado, devido à sua complexidade computacional linear. Essa característica permite a obtenção de tempos de processamento menores que o intervalo de controle mesmo ao controlar 10.000 intersecções com uma arquitetura centralizada. É notável que, apesar de mencionarem o tempo de processamento e a complexidade computacional como desvantagens, a maior parte dos trabalhos relacionados ao controle do trânsito urbano revisados nesse trabalho não divulgam valores para efeito de comparação.

As simulações relativas ao controle do trânsito urbano mostraram que as características do modelo de rede neural bioinspirada proposto foram responsáveis por um desempenho superior a um método de controle adaptativo. Desse modo, as principais características da rede neural bioinspirada que originaram o desempenho obtido são: contínuo monitoramento do estado do sistema controlado e capacidade de agir de acordo com o estado do sistema em qualquer momento, o que possibilita uma alta reatividade e adaptabilidade; e coordenação entre partes interdependentes do sistema controlado (intersecções vizinhas), fazendo com que as tomadas de decisão em cada parte do sistema — ou seja, em cada intersecção controlada — estejam em sintonia para a melhora do desempenho do sistema como um todo. Portanto, além de reagir em qualquer momento a variações nos fluxos de veículos, a rede neural bioinspirada foi capaz de formar ondas verdes e evitar o efeito de transbordamento.

Por fim, como mencionado no Capítulo 1 desse trabalho, Haddad e Vieira (2015) estimaram que uma redução de 27,63% no tempo de viagem dos motoristas da Região Metropolitana de São Paulo geraria um aumento de 110 bilhões de reais no PIB brasileiro no ano de 2010. A rede neural bioinspirada proposta foi capaz de reduzir o tempo de viagem dos veículos, em média, 25,94% no cenário estudado em comparação a um método de controle adaptativo para diferentes níveis de demanda. Dessa maneira, é possível estimar que tal redução no tempo de viagem dos veículos se manteria – ou até aumentaria – na aplicação em um sistema real de controle do trânsito urbano, visto que os controladores atuais da cidade de São Paulo são baseados em tempos fixos, não possuindo a adaptabilidade do método de controle

investigado nas simulações. Sendo assim, a aplicação prática da rede neural bioinspirada proposta teria um grande impacto na economia do país.

5.5. Aspectos relacionados à implementação de um sistema de controle de semáforos

Além do método de controle, outros aspectos devem ser considerados para a implementação de um sistema de controle de semáforos. Entre eles, está a arquitetura de controle, que tem implicações na forma de processamento e comunicação dos dados relativos ao trânsito urbano. Como mencionado na Seção 2.1.2., três alternativas de controle são possíveis: centralizado; hierárquico; e distribuído. O controle centralizado recebe todos os dados coletados e os processa em um único local, o centro de controle, permitindo a tomada de decisão com informações completas sobre o sistema controlado. No entanto, uma desvantagem do controle centralizado é o tempo necessário para agregar todos os dados do sistema e os processar para tomar uma decisão. Além disso, precisa-se viabilizar a comunicação de cada intersecção controlada com o centro de controle.

Ao adotar uma arquitetura distribuída de controle, reduz-se o tempo de coleta e processamento de dados, pois há um controlador em cada intersecção, o qual se comunica apenas com seus vizinhos imediatos e toma as decisões pertinentes à sua intersecção. Porém, apesar de obter-se uma maior reatividade, perde-se a visão global do sistema na tomada de decisão. A arquitetura de controle hierárquica tem como objetivo conciliar a maior reatividade do controle distribuído e manter a visão global do sistema. Entretanto, as diversas camadas de controle tornam o processo de tomada de decisão mais complexo e demandam uma maior estrutura de controle e de comunicação, visto que o controle hierárquico possui tanto controladores em cada intersecção, quanto controladores regionais e um centro de controle global.

Outro aspecto relacionado à implementação de um sistema de controle de semáforos é a comunicação. A comunicação entre os controladores de cada intersecção, nos casos do controle distribuído e do controle hierárquico, pode ser cabeada ou sem fio. A comunicação cabeada é mais confiável, pois tem menos fatores externos de interferência, mas possui um maior custo de instalação. Por sua vez, Miguel, Castro e Hirakawa (2015) analisaram a comunicação sem fio entre controladores de intersecções vizinhas com o padrão IEEE 802.11g. Os autores

verificaram que, com as configurações adequadas, o tempo de comunicação possibilita a utilização do padrão mesmo em sistemas de controle que exijam uma tomada de decisão rápida – em menos de 1 segundo, por exemplo –, como é o caso da rede neural bioinspirada. A comunicação com centros de controle, como é o caso nas arquiteturas de controle centralizada e hierárquica, deve ser, preferencialmente, cabeada, devido às distâncias entre as intersecções controladas e os centros de controle. Tal fator faz com que a prioridade seja a velocidade de comunicação, que é mais alta na comunicação cabeada.

Um terceiro aspecto relevante para a implementação de um sistema de controle de semáforos é o sensoriamento. A obtenção das informações necessárias para a tomada de decisão pode ser feita de diversos modos. Entretanto, dois modos se destacam: câmeras e sensores indutivos. Enquanto os sensores indutivos são posicionados abaixo das vias e detectam a passagem dos veículos, as câmeras filmam as vias e utilizam algoritmos de visão computacional para identificar e contar os veículos no vídeo. Como a instalação ubíqua de sensores não é economicamente viável, métodos computacionais são utilizados para estimar a quantidade de veículos a partir dos dados obtidos pelos sensores. Tal assunto foi abordado por Li e Jia (2009), que investigaram estratégias de posicionamento de sensores e suas implicações para o controle de semáforos.

Devido aos diversos aspectos envolvidos na implementação de um sistema de controle de semáforos, deve-se adotar uma estratégia de implementação. Tal estratégia compreende, além da escolha de um método de controle, a escolha de uma arquitetura de controle, a escolha de um *hardware* adequado para o processamento do método de controle, a escolha de um modo de sensoriamento, a escolha de um modo de comunicação e o desenvolvimento de um projeto para estabelecer como cada um desses aspectos será implementado.

6. CONCLUSÕES

Este trabalho propôs um modelo de rede neural bioinspirada para o controle do trânsito urbano, um sistema dinâmico complexo com múltiplos impactos na sociedade. O modelo proposto é dividido em duas partes: uma para o controle de uma única intersecção, na qual os neurônios competem entre si para determinar a fase semafórica ativa; e outra para a coordenação entre intersecções, cujos interneurônios inibitórios formam sinapses axo-axônicas para coordenar as atividades das redes neurais bioinspiradas responsáveis por controlar as intersecções. Dessa maneira, forma-se ondas verdes e evita-se o efeito de transbordamento. Além da estrutura da rede neural bioinspirada e das equações que regem o comportamento dos neurônios, também foi abordado um método de determinação dos parâmetros do modelo proposto. Tal método simplifica a otimização dos parâmetros do modelo de acordo com cada cenário do trânsito urbano.

Em relação aos resultados obtidos, foram analisadas a convergência e a estabilidade da rede neural bioinspirada. Demonstrou-se que o modelo proposto possui apenas um ponto de equilíbrio para quaisquer valores dos parâmetros ou das entradas da rede neural bioinspirada. Além disso, a partir da análise de estabilidade de um neurônio excitatório foi possível inferir a estabilidade da rede neural bioinspirada como um todo. Dessa forma, por meio da análise dos autovalores do Jacobiano desse neurônio, pode-se identificar o comportamento da rede neural bioinspirada para quaisquer valores de parâmetros escolhidos.

Também foram realizadas análises do tempo de processamento e da complexidade computacional do modelo proposto. Os resultados obtidos mostram que a rede neural bioinspirada possui uma complexidade computacional linear, com um tempo de processamento variando de 0,0534ms para controlar uma intersecção a 0,5185s para controlar 10.000 intersecções com uma arquitetura de controle centralizada. Dessa maneira, a resposta rápida da rede neural bioinspirada possibilita o monitoramento contínuo do estado do trânsito urbano, assim como a tomada de decisão para agir quando necessário. Ademais, supera-se o efeito de *aliasing*, o qual deteriora o desempenho de outros métodos de controle por impossibilitar a caracterização completa do sistema controlado.

Em comparação a um método de controle adaptativo, a rede neural bioinspirada foi, em média, 25,94% melhor em simulações com trânsito leve, moderado e congestionado. As simulações realizadas também mostraram que a rede neural bioinspirada é mais capaz de se adaptar às diferentes situações presentes em um sistema dinâmico complexo, como distúrbios momentâneos e variações não previstas. Os resultados obtidos evidenciam, portanto, as principais contribuições do modelo proposto: a capacidade de resposta rápida e o controle coordenado de um sistema dinâmico complexo.

Apesar de não fazerem parte do foco dessa pesquisa, os principais aspectos práticos relacionados a um sistema de controle de semáforos com base no modelo proposto de rede neural bioinspirada foram elucidados: arquitetura do sistema; sensoriamento; comunicação; e processamento. Demonstrou-se, assim, que o método de controle é apenas uma parte do sistema de controle de semáforos, e discutiu-se, de forma não exaustiva, como um sistema completo poderia ser implementado.

Uma possível direção de pesquisa futura relacionada à rede neural bioinspirada proposta é a adição de mais características de redes neurais biológicas. Seria possível propor uma terceira parte da rede neural bioinspirada, com o objetivo de predizer o comportamento do estado de uma intersecção com base no estado de intersecções vizinhas mais distantes. Poder-se-ia, assim, realizar uma previsão da demanda de veículos em uma intersecção por meio de estruturas neurais semelhantes ao tipo de predição feita pelo cérebro humano. Outra extensão possível do modelo de rede neural bioinspirada proposto seria utilizar a plasticidade sináptica como forma de priorização de vias com maior demanda. Ademais, também seria possível utilizar o aprendizado por reforço, característica central do aprendizado biológico, para otimizar, durante sua operação, os parâmetros principais da rede neural bioinspirada (Ω , $S \in s_a$) de acordo com as características físicas de cada intersecção.

Outra direção de pesquisa futura é a aplicação da rede neural bioinspirada em *hardware* para o controle do sistema de trânsito urbano real. Dessa maneira, poderse-ia comparar tanto as características dos sistemas em *software* e *hardware*, quanto às semelhanças e diferenças entre realizar o controle no simulador e realizar o controle do sistema real. Além disso, pode-se investigar a aplicação do modelo proposto para o controle de outros sistemas dinâmicos complexos, como é o caso de robôs e de sistemas de distribuição de energia elétrica ou de água. Outra alternativa de pesquisa é a utilização do modelo proposto de rede neural bioinspirada para a investigação do funcionamento de mecanismos biológicos do cérebro humano e animal. Dessa maneira, utilizar-se-ia as estruturas e equações propostas para replicar o comportamento dinâmico de determinadas redes neurais biológicas.

REFERÊNCIAS

ABDOOS, M.; MOZAYANI, N.; BAZZAN, A. L. C. Traffic light control in non-stationary environments based on multi agent Q-learning. In: 14th INTERNATIONAL IEEE CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS, 2011, Washington. **Proceedings**... p. 1580-1585.

ABDULHAI, B.; PRINGLE, R.; GRIGORIS, J. K. Reinforcement learning for true adaptive traffic signal control. **Journal of Transportation Engineering**, v. 129, n. 3, p. 278-285, 2003.

ALVAREZ, I.; POZNYAK, A.; MALO, A. Urban Traffic Control Problem via a Game Theory Application. In: 46th IEEE CONFERENCE ON DECISION AND CONTROL, 2007, New Orleans. **Proceedings**... p. 2957-2961.

ANTONELLI, G. Interconnected Dynamic Systems: An Overview on Distributed Control. **IEEE Control Systems**, v. 33, n. 1, p. 76-88, 2013.

ARAGHI, S.; KHOSRAVI, A.; JOHNSTONE, M.; CREIGHTON, D. Q-learning method for controlling traffic signal phase time in a single intersection. In: 16th INTERNATIONAL IEEE CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS, 2013, The Hague. **Proceedings**... p. 1261-1265.

BATISTA JUNIOR, A. 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, 2013, The Hague. **Proceedings**... p. 2439-2444.

BEDE, B. Mathematics of Fuzzy Sets and Fuzzy Logic. Springer, 2013.

BEHRISCH, M.; BIEKER, L.; ERDMANN, J.; KRAJZEWICZ, D. SUMO-Simulation of Urban MObility: An Overview. In: THIRD INTERNATIONAL CONFERENCE ON ADVANCES IN SYSTEM SIMULATION, 2011, Barcelona. **Proceedings**... p. 63-68. BELLMAN, R. Dynamic Programming. Princeton University Press, 1957.

BILLARD, A.; IJSPEERT, A. J. Biologically inspired neural controllers for motor control in a quadruped robot. In: IEEE-INNS-ENNS INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2000, Como. **Proceedings**... v. 6, p. 637-641.

BOSSOMAIER, T. R. J.; GREEN, D. G. **Complex Systems.** Cambridge University Press, 2007.

BRESCIANI, P; PERINI, A.; GIORGINI, P.; GIUNCHIGLIA, F.; MYLOPOULOS, J.
Tropos: an Agent-Oriented Software Development Methodology. Autonomous
Agents and Multi-Agent Systems, v. 8, n. 3, p. 203-236, 2004.

BROOKS, R. A. Intelligence without representation. **Artificial Intelligence Journal**, v. 47, n. 1-3, p. 139-159, 1991.

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, 2009.

CAMACHO, E. F.; BORDONS, C. Model Predictive Control. Springer-Verlag, 2004.

CAMPONOGARA, E.; JIA, D.; KROGH, B.H.; TALUKDAR, S.N. Distributed model predictive control. **IEEE Control Systems Magazine**, v. 22, n. 1, p. 44-52, 2002.

CAMPONOGARA, E.; TALUKDAR, S.N. Distributed model predictive control: synchronous and asynchronous computation. **IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans**, v. 37, n. 5, p. 732-745, 2007.

CAMPONOGARA, E.; OLIVEIRA, L. B. Distributed Optimization for Model Predictive Control of Linear-Dynamic Networks. **IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans**, v. 39, n. 6, p. 1331-1338, 2009.

118

CASTÁN, J.; IBARRA, S.; LARIA, J. Sophisticated Traffic Lights Control using Neural Networks. **IEEE Latin America Transactions**, v. 13, n. 1, p. 96-101, 2015.

CASTRO, G. B.; MARTINI, J. S. C.; HIRAKAWA, A. R. Multilayer distributed model predictive control of urban traffic. **WIT Transactions on Ecology and the Environment**, v. 179, p. 967-976, 2013. Apresentado a SUSTAINABLE CITY VIII, 2013, Putrajaya.

CASTRO, G. B.; MARTINI, J. S. C.; HIRAKAWA, A. R. Biologically-inspired neural network for traffic signal control. In: IEEE INTERNATIONAL CONFERENCE ON INTELLIGENT TRANSPORTATION SYSYTEMS, Qingdao, 2014. **Proceedings**... p. 2144-2149.

CASTRO, G. B.; MIGUEL, D. S.; MACHADO, B. P.; HIRAKAWA, A. R. Biologicallyinspired Neural Network for Coordinated Urban Traffic Control: Parameter Determination and Stability Analysis. In: INTERNATIONAL CONFERENCE ON COMPUTATIONAL SCIENCE AND COMPUTATIONAL INTELLIGENCE, Las Vegas, 2015. **Proceedings**... p. 209-214.

CEYLAN, H.; BELL, M. G. H. Traffic signal timing optimisation based on genetic algorithm approach, including drivers' routing. **Transportation Research Part B: Methodological**, v. 38, n. 4, p. 329-342, 2004.

CINTRA, M. Os custos dos congestionamentos na cidade de São Paulo. 2014. 38 p. Disponível em:

CHENG, S. F.; EPELMAN, M. A.; SMITH, R. L. CoSIGN: A Parallel Algorithm for Coordinated Traffic Signal Control. **IEEE Transactions on Intelligent Transportation Systems**, v. 7, n. 4, p. 551-564, 2006. CHOU, C.; TENG, J. A fuzzy logic controller for traffic junction signals. **Information Sciences**, v. 143, n. 1-4, p. 73-97, 2002.

CHOY, M. C.; SRINIVASAN, D.; 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.

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, 2006.

COMPANHIA DE ENGENHARIA DE TRÁFEGO. **Sinalização semafórica**. São Paulo, 2013.

COUPLAND, S.; JOHN, R. Geometric type-1 and type-2 fuzzy logic systems. **IEEE Transactions on Fuzzy Systems**, v. 15, n. 1, p. 3-15, 2007.

CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics of Control, Signals and Systems**, v. 2, n. 4, p. 303-314, 1989.

DESAI, N. S. Homeostatic plasticity in the CNS: synaptic and intrinsic forms. **Journal** of Physiology, v. 97, n. 4-6, p. 391-402, 2003.

DIAKAKI, C. Integrated control of traffic flow in corridor networks. 1999. 209 p. Tese (Doutorado) - Technical University of Crete, Creta, 1999.

DIAKAKI, C.; PAPAGEORGIOU, M.; ABOUDOLAS, K. A multivariable regulator approach to traffic-responsive network-wide signal control. **Control Engineering Practice**, v. 10, n. 2, p. 183-195, 2002.

FOLGHERAITER, M.; GINI, G.; NAVA, A.; MOTTOLA, N. A BioInspired Neural Controller for a Mobile Robot. In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND BIOMIMETICS, 2006, Kunming. **Proceedings**... p. 1646-1651. FOY, M. D.; BENEKOHAL, R. F.; GOLDBERG, D. E. Signal timing determination using genetic algorithms. **Transportation Research Record**, v. 1365, p. 108-115, 1992.

FREJO, J. R. D.; CAMACHO, E. F. Global Versus Local MPC Algorithms in Freeway Traffic Control With Ramp Metering and Variable Speed Limits. **IEEE Transactions on Intelligent Transportation Systems**, v. 13, n. 4, p. 1556-1565, 2012.

FUCHS, A. **Nonlinear Dynamics in Complex Systems**: Theory and Applications for the Life-, Neuro- and Natural Sciences. Springer, 2013.

GARTNER, N. H.; ASSMANN, S. F.; LASAGA, F.; HOU, D. L. A multiband approach to arterial traffic signal optimization. **Transportation Research Part B: Methodological**, v. 25, n. 1, p. 55-74, 1991.

GAZIS, D. C.; POTTS, R. B. The oversaturated intersection. In: 2nd INTERNATIONAL SYMPOSIUM ON TRAFFIC THEORY, 1963, London. **Proceedings**... p. 221-237.

GEROLIMINIS, N.; DAGANZO, C. Existence of urban-scale macroscopic
fundamental diagrams: Some experimental findings. Transportation Research Part
B: Methodological, v. 42, n. 9, p. 759-770, 2008.

GEROLIMINIS, N; SKABARDONIS, A. Identification and Analysis of Queue Spillovers in City Street Networks. **IEEE Transactions on Intelligent Transportation Systems**, v. 12, n. 4, p. 1107-1115, 2011.

GIL, A. F. A.; ESPINOSA, J.; ESPINOSA, J. E. TraCl4Matlab: Re-engineering the Python implementation of the TraCl interface. In: SUMO2014 - MODELING MOBILITY WITH OPEN DATA, 2014, Berlin. **Proceedings**... p. 145-155.

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, 2010. GOKULAN, B. P.; SRINIVASAN, D. Modified Symbiotic Evolutionary Learning for Type-2 Fuzzy System. **IEEE Transactions on Intelligent Transportation Systems**, v. 8, n. 2, p. 353-362, 2014.

GREGOIRE, J.; QIAN, X.; FRAZZOLI, E.; FORTELLE, A.; WONGPIROMSARN, T. Capacity-Aware Backpressure Traffic Signal Control. **IEEE Transactions on Control of Network Systems**, v. 2, n. 2, p. 164-173, 2015.

GRILLO, F.; LAPERROUZE, J. Measuring the Cost of Congestion on Urban Area and the Flexible Congestion Rights. **Journal of Management and Sustainability**, v. 3, n. 2, p. 40-55, 2013.

GROS, C. **Complex and Adaptive Dynamical Systems**: A Primer. 3rd ed. Springer, 2013.

GROSSBERG, S. Adaptive pattern classification and universal recoding: I. Parallel development and coding of neural feature detectors. **Biological Cybernetics**, v. 23, p. 121-134, 1976.

HADDAD, E. A.; VIEIRA, R. S. Mobilidade, acessibilidade e produtividade: nota sobre a valoração econômica do tempo de viagem na região metropolitana de São Paulo. 2015. 26 p. Disponível em: http://www.usp.br/nereus/wp-content/uploads/TD_Nereus_08_2015.pdf>. Acesso em: 27 jan. 2016.

HEALEY, J. A.; PICARD, R. W. Detecting Stress During Real-World Driving Tasks Using Physiological Sensors. **IEEE Transactions on Intelligent Transportation Systems**, v. 6, n. 2, p. 156-166, 2005.

HELGADOTTIR, L. I.; HAENICKE, J.; LANDGRAF, T.; ROJAS, R.; NAWROT, M. P. Conditioned behavior in a robot controlled by a spiking neural network. In: INTERNATIONAL IEEE/EMBS CONFERENCE ON NEURAL ENGINEERING, 2013, San Diego. **Proceedings**... p. 891-894. HEUNG, T. H.; HO, T. K.; FUNG, Y. F. Coordinated Road-Junction Traffic Control by Dynamic Programming. **IEEE Transactions on Intelligent Transportation Systems**, v. 6, n. 3, p. 341-350, 2005.

HIREL, J.; GAUSSIER, P.; QUOY, M. Biologically inspired neural networks for spatiotemporal planning in robotic navigation tasks. In: IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND BIOMIMETICS, 2011, Phuket. **Proceedings**... p. 1627-1632.

HODGKIN, A. L.; HUXLEY, A. F. A quantitative description of membrane current and its application to conduction and excitation in nerve. **Journal of Physiology**, v. 117, n. 4, p. 500-544, 1952.

HOMOLOV'A, J.; NAGY, I. Traffic model of a microregion. In: 16th WORLD CONGRESS OF THE INTERNATIONAL FEDERATION OF AUTOMATIC CONTROL, 2005, Prague. **Proceedings**... p. 1-6.

HOPFIELD, J. J. Neurons with graded response have collective computational properties like those of two-state neurons. **Proceedings of the National Academy of Sciences**, v. 81, n. 10, p. 3088-3092, 1984.

HUNT, P. B.; ROBERTSON, D. L.; BRETHERTON, R. D. The SCOOT on-line traffic signal optimization technique. **Traffic Engineering & Control**, v. 23, n.4, p. 190-192, 1982.

IJSPEERT, A. J. Central pattern generators for locomotion control in animals and robots: A review. **Neural Networks**, v. 21, n. 4, p. 642-653, 2008.

IZHIKEVICH, E. M. Simple model of spiking neurons. **IEEE Transactions on Neural Networks**, v. 14, n. 6, p. 1569-1572, 2003.

JANG, K.; KIM, H.; JANG, I. G. Traffic signal optimization for oversaturated urban networks: queue growth equalization. **IEEE Transactions on Intelligent Transportation Systems**, v. 16, n. 4, p. 2121-2128, 2015. JUANG, C. F.; LIN, J. Y.; LIN, C. T. Genetic reinforcement learning through symbiotic evolution for fuzzy controller design. **IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics**, v. 30, n. 2, p. 290-302, 2000.

KANDEL, E. R.; SCHWARTZ, J. H.; JESSEL, T. M.; SIEGELBAUM, S. A.; HUDSPETH, A. J. **Principles of Neural Science**. 5th ed. McGraw-Hill Education, 2012.

KARNIK, N. N.; MENDEL, J. M.; LIANG, Q. Type-2 fuzzy logic systems. **IEEE Transactions on Fuzzy Systems**, v. 7, n. 6, p. 643-658, 1999.

KELLER, E.; SAKLAS, J. Passenger car equivalents from network simulation. **Journal of Transportation Engineering**, v. 110, n. 4, p. 397-411, 1984.

KEONG, C. K. The GLIDE system—Singapore's urban traffic control system. **Transport Reviews**, v. 13, n. 4, p. 295-305,1993.

KINSNER, W. Complexity and its measures in cognitive and other complex systems. In: IEEE INTERNATIONAL CONFERENCE ON COGNITIVE INFORMATICS, 2008, Stanford. **Proceedings**... p. 13-29.

KINTO, E. A.; DEL MORAL HERNANDEZ, E.; MARCANO, A.; PELÁEZ, F. J. R. A Preliminary Neural Model for Movement Direction Recognition Based on Biologically Plausible Plasticity Rules. In: INTERNATIONAL WORK-CONFERENCE ON THE INTERPLAY BETWEEN NATURAL AND ARTIFICIAL COMPUTATION, 2007, La Manga del Mar Menor. **Proceedings**... p. 628-636.

KUMAR, P.; MERZOUKI, R.; CONRARD, B.; COELEN, V.; BOUAMAMA, B. O. Multilevel Modeling of the Traffic Dynamic. **IEEE Transactions on Intelligent Transportation Systems**, v. 15, n. 3, p. 1066-1082, 2014. LE, T.; KOVÁCS, P.; WALTON, N.; VU, H. L.; ANDREW, L. L. H. Decentralized signal control for urban road networks. **Transportation Research Part C: Emerging Technologies**, v. 58, n. 1, p. 431-450, 2015.

LEE, J.; LEE-KWANG, H. Distributed and cooperative fuzzy controllers for traffic intersections group. **IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews**, v. 29, n. 2, p. 263-271, 1999.

LEWIS, M. A.; KLEIN, T. J. Neurorobotics Primer. In: SUKHATME, G. **The Path to Autonomous Robots**. Springer Verlag, 2009. p. 1-25.

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, 2011.

LI, R.; JIA, L. On the layout of fixed urban traffic detectors: an application study. **IEEE Intelligent Transportation Systems Magazine**, v. 1, n. 2, p. 6-12, 2009.

LI, T.; ZHAO, D.; YI, J. Adaptive Dynamic Programming for Multi-intersections Traffic Signal Intelligent Control. In: 11th INTERNATIONAL IEEE CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS, 2008, Beijing. **Proceedings**... p. 286-291.

LIN, S.; LING, T.; XI, Y. Model Predictive Control for Large-scale Urban Traffic Networks with a Multi-level Hierarchy. In: 16th INTERNATIONAL IEEE CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS, 2013, The Hague. **Proceedings**... p. 211-216.

LIN, S.; SCHUTTER, B.; XI, Y.; HELLENDOORN, H. Fast model predictive control for urban road networks via MILP. **IEEE Transactions on Intelligent Transportation Systems**, v. 12, n. 3, p. 846-856, 2011. LIN, S.; SCHUTTER, B.; XI, Y.; HELLENDOORN, H. Efficient network-wide modelbased predictive control for urban traffic networks. **Transportation Research Part C: Emerging Technologies**, v. 24, n. 1, p. 122-140, 2012.

LITTLE, J. D. C. The synchronization of traffic signals by mixed-integerlinearprogramming. **Operations Research**, v. 14, n. 4, p. 568-594, 1966.

LOWRIE, P.R. The Sydney co-ordinated adaptive traffic system – principles, methodology and algorithms. In: PROCEEDINGS OF THE IEE INTERNATIONAL CONFERENCE ON ROAD TRAFFIC SIGNALLING, 1982, London. **Proceedings**... p. 67-70.

MAHMOD, M.; AREM, B.; PUEBOOBPAPHAN, R.; LANGE, D. Reducing local traffic emissions at urban intersection using ITS countermeasures. **IET Intelligent Transport Systems**, v. 7, n. 1, p. 78-86, 2013.

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. 1585-1588, 1974.

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, 2007.

MATSUOKA, K. Sustained Oscillations Generated by Mutually Inhibiting Neurons with Adaptation. **Biological Cybernetics**, v. 52, n. 6, p. 367-376, 1985.

MATSUOKA, K. Mechanisms of Frequency and Pattern Control in the Neural Rhythm Generators. **Biological Cybernetics**, v. 56, n. 5-6, p. 345-353, 1987.

MIGUEL, D. S.; CASTRO, G. B.; HIRAKAWA, A. R. Analysis of IEEE 802.11g standard for communication in a traffic lights distributed control system. In: INTERNATIONAL CONFERENCE ON COMPUTATIONAL SCIENCE AND COMPUTATIONAL INTELLIGENCE, Las Vegas, 2015. **Proceedings**... p. 662-667. MILLER, A. J. Settings for fixed-cycle traffic signals. **Journal of the Operational Research Society**, v. 14, n. 4, p. 373-386, 1963.

MITCHELL, T. M. Machine learning. McGraw-Hill, 1997.

MONTEIRO, J. L. R.; NETTO, M. L.; ANDINA, D.; PELÁEZ, F. J. R. Using neural networks to simulate the Alzheimer's disease. In: WORLD AUTOMATION CONGRESS, 2008, Waikoloa (Hawaii). **Proceedings**... p. 1-6.

MORIARTY, D. E.; MIIKKULAINEN, R. Efficient reinforcement learning through symbiotic evolution. **Machine Learning**, v. 22, n. 1-3, p. 11-32, 1996.

MURAT, Y. S.; GEDIZLIOGLU, E. A fuzzy logic multi-phased signal control model for isolated junctions. **Transportation Research Part C: Emerging Technologies**, v. 13, n. 1, p. 19-36, 2005.

MURRAY, J. J.; CHADWICK, J. C.; LENDARIS, G. G.; SAEKS, R. Adaptive Dynamic Programming. IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, v. 32, n. 2, p. 140-153, 2002.

NAGUMO, J.; ARIMOTO, S.; YOSHIZAWA, S. An active pulse transmission line simulating nerve axon. **Proceedings of the IRE**, v. 50, n. 10, p. 2061-2070, 1962.

NATAKSUJI, T.; KAKU, T. Development of a Self-organizing Traffic Control System Using Neural Network Models. **Transportation Research Record**, v. 1324, p. 137-145, 1991.

NICHOLS, E.; MCDAID, L. J.; SIDDIQUE, N. Biologically Inspired SNN for Robot Control. **IEEE Transactions on Cybernetics**, v. 43, n. 1, p. 115-128, 2013.

NYQUIST, H. Certain topics in telegraph transmission theory. **Transactions of the American Institute of Electrical Engineers**, v. 47, n. 2, p. 617-644, 1928. ODEH, S. M.; MORA, A. M.; MORENO, M. N.; MERELO, J. J. A Hybrid Fuzzy Genetic Algorithm for an Adaptive Traffic Signal System. **Advances in Fuzzy Systems**, v. 2015, p. 1-11, 2015.

OKHOTIN, V. E. Cytophysiology of spiny stellate cells in the striate cortex and their role in the excitatory mechanisms of intracortical synaptic circulation. **Neuroscience and Behavioral Physiology**, v. 36, n. 8, p. 825–836, 2006.

OLIVEIRA, L. B.; CAMPONOGARA, E. Multi-agent model predictive control of signaling split in urban traffic networks. **Transportation Research Part C: Emerging Technologies**, v. 18, n. 1, p. 120-139, 2010.

ORTJOHANN, E.; WIRASANTI, P.; LINGEMANN, M.; SINSUKTHAVORN, W.; JALOUDI, S.; MORTON, D. Multi-level hierarchical control strategy for smart grid using clustering concept. In: INTERNATIONAL CONFERENCE ON CLEAN ELECTRICAL POWER, 2011, Ischia. **Proceedings**... p. 648-653.

PAPAGEORGIOU, M. Overview of road traffic control strategies. In: 2004 INTERNATIONAL CONFERENCE ON INFORMATION AND COMMUNICATION TECHNOLOGIES: FROM THEORY TO APPLICATIONS, 2004, Damascus. **Proceedings**... p. 59-60.

PAPPIS, C. P.; MAMDANI, E. H. A Fuzzy Logic Controller for a Traffic Junction. **IEEE Transactions on Systems, Man and Cybernetics**, v. 7, n. 10, p. 707-717, 1977.

PEIRCE, J. R.; WEBB, P. J. MOVA control of isolated traffic signals – recent experience. In: 3rd INTERNATIONAL CONFERENCE ON ROAD TRAFFIC CONTROL, 1990, London. **Proceedings**... p. 110-113.

PELÁEZ, F. J. R.; AGUIAR-FURUCHO, M. A.; ANDINA, D. Intrinsic Plasticity for Natural Competition in Koniocortex-Like Neural Networks. **International Journal of Neural Systems**, v. 26, n. 5, p. 1650040, 2016. PELÁEZ, F. J. R.; ANDINA, D. Do biological synapses perform probabilistic computations? **Neurocomputing**, v. 114, p. 24-31, 2013.

PELÁEZ, F.J. R.; GODOI, A. C. From Forced to Natural Competition in a Biologically Plausible Neural Network. **Advances in Intelligent Systems and Computing**, v. 198, p 95-104, 2013.

PELÁEZ, F. J. R.; RANVAUD, R.; SZAFIR, S.; RAMÍREZ-FERNÁNDEZ, F.J. The illusion of movement in static images analyzed with a biologically plausible unsupervised neural network model. In: BRAIN INSPIRED COGNITIVE SYSTEMS, 2008, São Luiz. **Proceedings**... p. 346-351.

PETERSON, A.; BERGH, T.; STEEN, K. LHOVRA, a new traffic signal control strategy for isolated junctions. In: 2nd INTERNATIONAL CONFERENCE ON ROAD TRAFFIC CONTROL, 1986, London. **Proceedings**... p. 98-101.

PRASHANTH, L. A.; BHATNAGAR, S. Reinforcement Learning with Function Approximation for Traffic Signal Control. **IEEE Transactions on Intelligent Transportation Systems**, v. 12, n. 2, p. 412-421, 2011.

PRIKRYL, J. Simple model for urban traffic between two signalized intersections. In: 16th INTERNATIONAL IEEE CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS, 2013, The Hague. **Proceedings**... p. 41-46.

PUIG, V.; OCAMPO-MARTINEZ, C.; OCA, S. M. Hierarchical Temporal Multi-Layer Decentralized MPC Strategy for Drinking Water Networks: Application to the Barcelona Case Study. In: 20th MEDITERRANEAN CONFERENCE ON CONTROL & AUTOMATION, 2012, Barcelona. **Proceedings**... p. 740-745.

QIAO, J.; YANG, N. D.; GAO, J. Two-stage fuzzy logic controller for signalized intersection. **IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans**, v. 41, n. 1, p. 178-184, 2011.

ROBERTSON, D. L. TRANSYT method for area traffic control. Traffic

Engineering & Control, v. 11, n.6, p. 276-281, 1969.

RUSSELL, S.; NORVIG, P. Artificial Intelligence: A Modern Approach. 3rd ed. Pearson, 2009.

SAPUTRA, A. A.; BOTZHEIM, J.; SULISTIJONO, I. A.; KUBOTA, N. Biologically Inspired Control System for 3-D Locomotion of a Humanoid Biped Robot. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 46, n. 7, p. 898-911, 2016.

SARMAH, H. K.; BAISHYA, T. K.; DAS, M. C. Hopf-bifurcation in a two dimensional nonlinear differential equation. **International Journal of Modern Engineering Research**, v. 4, n. 1, p. 168-178, 2014.

SCHMÖCKER, J. D.; AHUJA, S.; BELL, M. G. H. Multi-objective signal control of urban junctions: Framework and a London case study. **Transportation Research Part C: Emerging Technologies**, v. 16, n. 4, p. 454-470, 2008.

SHANNON, C. E. Communication in the presence of noise. **Proceedings of the Institute of Radio Engineers**, v. 37, n. 1, p. 10-21, 1949.

SOMOGYI, P.; FREUND, T. F.; COWEY, A. The axo-axonic interneuron in the cerebral cortex of the rat, cat and monkey. **Neuroscience**, v. 7, n. 11, p. 2577-2607, 1982.

SPALL, J. C. Multivariate Stochastic Approximation Using a Simultaneous
Perturbation Gradient Approximation. IEEE Transactions on Automatic Control, v.
37, n. 3, p. 332-341, 1992.

SPALL, J. C.; CHIN, D. C. A Model-free Approach to Optimal Signal Light Timing for System-Wide Traffic Control. In: 33rd CONFERENCE ON DECISION AND CONTROL, 1994, Lake Buena Vista. **Proceedings**... p. 1868-1875.

SRINIVASAN, D.; CHOY, M. C.; CHEU, R. L. Neural Networks for Real-Time Traffic Signal Control. **IEEE Transactions on Intelligent Transportation Systems**, v. 7, n. 3, p. 261-272, 2006.

SUTTON, R. S.; BARTO, A. G. Reinforcement Learning: An Introduction. MIT Press, 1998.

TAGA, G.; YAMAGUSHI, Y.; SHIMIZU, H. Self-organized Control of Bipedal Locomotion by Neural Oscillators in Unpredictable Environment. **Biological Cybernetics**, v. 65, n. 3, p. 147-159, 1991.

TASSIULAS, L.; EPHREMIDES, A. Stability properties of constrained queueing systems and scheduling policies for maximum throughput in multihop radio networks. **IEEE Transactions on Automatic Control**, v. 37, n. 12, p. 1936-1948, 1992.

TETTAMANTI, T.; LUSPAY, T.; KULCSÁR, B.; PÉNI, T.; VARGA, I. Robust Control for Urban Road Traffic Networks. **IEEE Transactions on Intelligent Transportation Systems**, v. 15, n. 1, p. 385-398, 2014.

TRABIA, M. B.; KASEKO, M. S.; ANDE, M. A two-stage fuzzy logic controller for traffic signals. **Transportation Research Part C: Emerging Technologies**, v. 7, n. 6, p. 353-367, 1999.

TSODYKS, M. V.; PAWELZIK, K.; MARKRAM, H. Neural networks with dynamic synapses. **Neural Computation**, v. 10, n. 4, p. 821-835, 1998.

VILARINHO, C.; TAVARES, J. P.; ROSSETTI, R. J. F. Design of a Multiagent System for Real-Time Traffic Control. **IEEE Intelligent Transportation Systems**, v. 31, n. 4, p. 68-80, 2016.

VRANCKEN, J.; SOARES, M. S. Multi-level control of networks: the case of road traffic control. In: IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN AND CYBERNETICS, 2007, Montreal. **Proceedings**... p. 1741-1745.

WEBSTER, F. V. **Traffic signal setting**. Road Res. Lab., HMSO, London, U.K., Tech. Paper 39, p. 1-44, 1958.

WEISBROD, G.; VARY, D.; TREYZ, G. Measuring the Economic Costs of Urban Traffic Congestion to Business. **Journal of the Transportation Research Board**, p. 1-22, 2003.

WHITTINGTON, M. A.; TRAUB, R. D. Interneuron diversity series: inhibitory interneurons and network oscillations in vitro. **Trends in Neurosciences**, v. 26, n. 2, p. 676-682, 2003.

WILLIAMS, T. L. Phase coupling by synaptic spread in chains of coupled neuronal oscillators. **Science**, v. 258, n. 5082, p. 662-665, 1992.

WOLSHON, P. B.; TAYLOR, W. C. Analysis of intersection delay under realtime adaptive signal control. **Transportation Research. Part C, Emerging technologies**, v. 7, n. 1, p. 53-72, 1999.

WONGPIROMSARN, T.; UTHAICHAROENPONG, T.; WANG, Y.; FRAZZOLI, E.; WANG, D. Distributed traffic signal control for maximum network throughput. In: 15th IEEE INTERNATIONAL CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS, 2012, Anchorage. **Proceedings**... p. 588-595.

WOOLDRIDGE, M. J. An Introduction to MultiAgent Systems. John Wiley & Sons, 2009.

WU, H.; MENDEL, J. M. Uncertainty bounds and their use in the design of interval type-2 fuzzy logic systems. **IEEE Transactions on Fuzzy Systems**, v. 10, n. 5, p. 622-639, 2002.

WUNDERLICH, R.; CUIBI, L.; ELHANANY, I.; URBANIK, T. A novel signalscheduling algorithm with quality-of-service provisioning for an isolated intersection. **IEEE Transactions on Intelligent Transportation Systems**, v. 9, n. 3, p. 536–547, 2008.

132

YANG, W.; BAE, J. H.; OH, Y.; CHONG, N. Y.; YOU, B. J. Biologically inspired control for robotic arm using neural oscillator network. In: IEEE/RSJ INTERNATIONAL CONFERENCE ON INTELLIGENT ROBOTS AND SYSTEMS, 2009, St. Louis. **Proceedings**... p. 135-141.

YE, B.; WU, W.; LI, L. MAO, W. A Hierarchical Model Predictive Control Approach for Signal Splits Optimization in Large-Scale Urban Road Networks. **IEEE Transactions on Intelligent Transportation Systems**, v. 17, n. 8, p. 2182-2192, 2016.

YIN, B; DRIDI, M.; EL MOUDNI, A. Traffic network micro-simulation model and control algorithm based on approximate dynamic programming. **IET Intelligent Transport Systems**, v. 10, n. 3, p. 186-196, 2016.

YU, J.; TAN, M.; CHEN, J.; ZHANG, J. A Survey on CPG-Inspired Control Models and System Implementation. **IEEE Transactions on Neural Networks and Learning Systems**, v. 25, n. 3, p. 441-456, 2014.

ZADEH, L. A. Fuzzy Sets. Information and Control, v. 8, n. 3, p. 338-353, 1965.

ZADEH, L. A. The concept of linguistic variables and its application to approximate reasoning. **Information Sciences**, v. 8, n. 3, p. 199-249, 1975.

ZAMBONELLI, F.; JENNINGS, N. R.; WOOLDRIDGE, M. Developing Multiagent Systems: The Gaia Methodology. **ACM Transactions on Software Engineering and Methodology**, v. 12, n. 3, p. 317-370, 2003.

ZHANG, X. Effects of queue spillover in networks considering simultaneous departure time and route choices. **Transportation Planning and Technology**, v. 36, n. 3, p. 267-286, 2013.

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, 2012.

ZHAO, Y.; TIAN, Z. An Overview of the Usage of Adaptive Signal Control System in the United States of America. **Applied Mechanics and Materials**, v. 178-181, p. 2591-2598, 2012.

ZHU, F.; AZIZ, H. M. A.; QIAN, X.; UKKSURI, S. V. A junction-tree based learning algorithm to optimize network wide traffic control: A coordinated multi-agent framework. **Transportation Research. Part C, Emerging technologies**, v. 58, n. 1, p. 487-501, 2015.