

Controle Adaptativo de Intersecções em Trânsito Urbano Baseado em Parâmetros Reais de Vias

Nelson Murcia García, André R. Hirakawa
Departamento de Engenharia de Computação
Universidade de São Paulo, USP
São Paulo, Brasil
nelson.murcia@usp.br

Abstract— O desenvolvimento econômico mundial tem como desvantagem o aumento da população nos grandes centros urbanos, isto resulta em maior trânsito de veículos nas cidades, o que aumenta a possibilidade de engarrafamentos no trânsito. Inúmeras pesquisas são desenvolvidas com objetivo de fornecer soluções na área do trânsito urbano. Este trabalho visa como solução para o problema do engarrafamento de trânsito, aplicar um controle adaptativo das intersecções dependendo de parâmetros reais da rede de vias. Para atingir essa meta, é utilizado um modelo de Redes Neurais Bio-Inspiradas e três métodos diferentes para calcular o coeficiente de relação entre intersecções. Posteriormente são analisados os resultados obtidos com cada método e comparados com um método de controle de tempos fixo atualmente utilizado na cidade de São Paulo. O cenário escolhido para as simulações e análises apresenta características reais de uma região da cidade de São Paulo como: distribuição das vias, fluxos de veículos e tempos de ativação das fases dos semáforos. Para cada método foram realizados dois tipos de simulações, compreendendo demandas baixas e altas de veículos. Os resultados mostram que o método de Redes Neurais para o cálculo do coeficiente de relação entre as intersecções do modelo de Redes Neurais Bio-Inspiradas obteve os melhores resultados.

Keywords—*Bio-Inspired Neural Networks; Traffic Lights Control; Urban Traffic Control; Travel Average Time; Level Occupation Roads.*

I. INTRODUÇÃO

O desenvolvimento e o crescimento das grandes cidades hoje é regido pela economia e o desenvolvimento social. Isso explica como a população urbana tem aumentado significativamente nos últimos anos, de acordo com [1] em 2007, a população urbana excedeu à população rural, sugerindo que para o ano 2050, a população urbana vai representar o 70% da população mundial. Consequentemente, os pesquisadores apresentam soluções que procuram melhorar o problema da superlotação nos grandes centros urbanos. Por esta razão as pesquisas são conduzidas para resolver questões fundamentais, em temas tais como: energia, desenvolvimento sustentável, segurança, habitação, saúde e transporte [2]–[4].

O transporte é um elemento-chave para o desenvolvimento urbano nas cidades, soluções para problemas relacionados com esta área são ainda um desafio para os pesquisadores. O aumento do número de pessoas em um espaço de tamanho semelhante, provoca o aumento do trânsito, sendo um problema sério enfrentado hoje nas grandes cidades [5], [6]. O aumento da

infraestrutura de estradas e rodovias, do transporte público e o controle inteligente nas intersecções das vias são algumas das ações a serem realizadas para resolver problemas na área do transporte. Os semáforos são dispositivos comumente usados para controlar as intersecções, e o ajuste do tempo de cada fase do semáforo pode ajudar consideravelmente evitando engarrafamentos nas estradas [7]–[13].

Muitos estudos foram realizados para controlar os tempos de cada fase em um semáforo. A natureza imprevisível e estocástica da demanda de trânsito torna a tarefa de otimizar um controle adequado mais difícil. Como consequência encontramos na literatura os algoritmos e métodos mais variados, embora atualmente o controle de trânsito urbano moderno pode ser dividido em dois grupos: teoria do Controle Ótimo e a Inteligência Artificial [8].

Um controlador de semáforo adaptativo para o controle de semáforos é proposto por Taranjeet Kaur et al. em [13]. O controlador utiliza redes neurais e algoritmos genéticos para adaptar os horários do sinal de trânsito de acordo com o congestionamento de cada intersecção. A rede neural obtém os tempos do sinal como a entrada e fornece o comprimento da fila como a saída. Outro exemplo da utilização das redes neurais é apresentado em [10], a proposta dos autores é baseada em um ajuste ótimo nos tempos do semáforo, concluindo que a maior parte do tempo, os desempenhos dos dois algoritmos propostos têm um comportamento semelhante, mas categoricamente superior ao controlador de tempo fixo, uma observação deste é que o algoritmo é proposto e testado apenas para um único cruzamento de semáforo.

Finalmente em [7], é desenvolvida uma rede neural de inspiração biológica (BiNN, "Bio-Inspired Neural Network") que é capaz de monitorar continuamente o status do sistema e tomar decisões, estabelecendo um sistema multiagente e permitindo o controle coordenado de várias intersecções. Considerando como variável de entrada do sistema o nível de ocupação dos veículos nas intersecções das ruas. Além disso propõe um método para a determinação de parâmetros de acordo com o comportamento desejado e proporciona um método para a análise de estabilidade. O algoritmo é validado utilizando um simulador de mobilidade urbana e comparado com um controlador iterativo convencional, obtivendo melhores resultados em simulações para demandas de trânsito baixa, moderada e pesada. Este modelo estende-se a um modelo multiagente, no qual cada agente controla uma única intersecção e interage com os agentes vizinhos para conseguir o controle coordenado de várias intersecções. A proposta evita a saturação

$B (q_{a,B})$, nos casos em que o nível de ocupação da via comum da próxima interseção esteja alta, o que significa que essa via comum não está pronta para receber um fluxo de veículo pois está lotada, evitando engarrafamentos.

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

III. COEFICIENTE DE RELAÇÃO ENTRE INTERSEÇÕES

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

Para diferenciar a relação existente na coordenação entre quaisquer duas interseções pode-se utilizar as sinapses w_{bp} e w_a , (Figura 1). A sinapse w_{bp} descreve o grau de influência do estado de ocupação da via comum da próxima interseção (nível de ocupação da fase a da interseção B, Figura 2) na interseção em questão (interseção A, Figura 2), no caso de inibição da fase comum na interseção em questão pois a próxima interseção não está pronta para receber um fluxo de veículos, evitando o engarrafamento.

Um valor alto do parâmetro w_{bp} significa que a interseção A possui uma alta influência na interseção B, provocando que os veículos cheguem com maior rapidez. Portanto, a interseção B diminui rapidamente a ativação da fase comum da interseção A pois não está pronta para receber um fluxo de veículos. A alta influência da interseção A na interseção B, pode ser devido a fatores como: pequena distância entre as interseções, alta velocidade média atingida pelos veículos ou um aumento do número de faixas com respeito à via anterior.

Pelo contrário, um valor baixo do parâmetro significa que o grau de influência da interseção A na interseção B é baixo, e não afeta em grande medida na inibição da interseção A, pois os veículos vão demorar para chegarem na próxima B.

A sinapse w_a também descreve o grau de influência da interseção A na interseção B, mas é utilizada, como explicado anteriormente, para concretizar a segunda função do modelo para a coordenação de interseções. Portanto pode se concluir que os coeficientes de relação para duas interseções vizinhas com uma fase comum são:

$$|w_a| = 1 - |w_{bp}|$$

$$w_{bp} = f(d, v_{max}, \#_f)$$

Onde d é a distância desde uma interseção até a próxima interseção vizinha, v_{max} é a velocidade máxima que podem

atingir os veículos na via comum entre as duas interseções vizinhas e $\#_f$ é o número de faixas da via comum.

IV. CÁLCULO DO COEFICIENTE DE RELAÇÃO

Posteriormente, para obter o melhor coeficiente de relação (w_{bp}) possível para cada via comum com diferentes valores nos parâmetros reais das vias, foram realizadas várias simulações variando os coeficientes de relação (entre 0.01 e 0.99) e escolhendo a melhor resposta para cada grupo de parâmetros. O cenário usado para realizar esses testes consiste em duas ruas paralelas e uma rua perpendicular (via comum entre as duas interseções). A faixa de distância entre as duas interseções analisada foi entre 50 e 500 metros e as velocidades máximas das vias analisadas foram 40, 50 e 60 km/h. Por último, o número de faixas na via comum foi variado entre 1 e 4.

Depois dessa análise obtiveram-se 60 pontos (Figura 3) para as diferentes configurações de distância, velocidade máxima e número de faixa e o respectivo coeficiente de relação, que significa a melhor resposta possível para cada configuração analisando desde o ponto de vista do Nível de Ocupação das Vias e o Tempo Meio de Viagem.

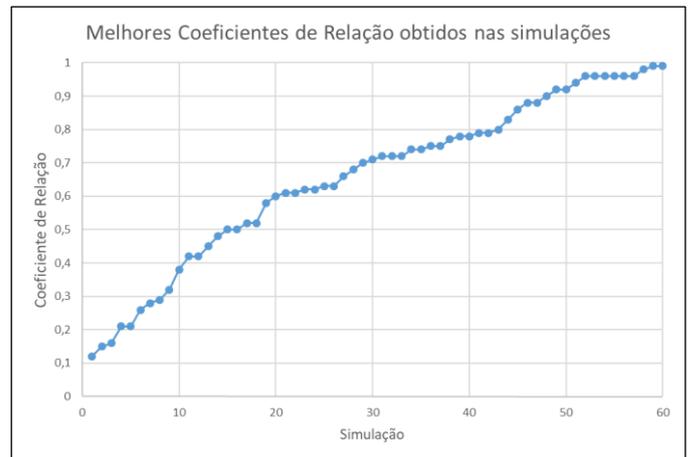


Figura 3. Melhores coeficientes de relação obtidos nas simulações

Para obter a função (1) a partir desses pontos usaram-se três métodos: Rede Neural Artificial (três entradas: $d, v_{max}, \#_f$ y uma saída), Regressão Polinomial com duas variáveis de entrada e grau 4 (tempo para os veículos chegarem na próxima interseção - $t_{min} = \frac{v_{max}}{d}$ e $\#_f$) e Regressão Polinomial com uma variável de entrada e grau 13 ($t_{min} = \frac{v_{max}}{d}$). Nas figuras 4, 5 e 6 apresentamos tanto a resposta de cada função $f(d, v_{max}, \#_f)$ quanto o erro de aproximação das respostas.

Para analisar o desempenho desses algoritmos no cálculo de um coeficiente de relação, a seguir se analisam as respostas em um cenário com características e demanda de veículos reais. Como foi explicado anteriormente, os parâmetros que são adicionados ao modelo BiNN são invariantes no tempo, portanto, é possível realizar um cálculo inicial off-line para obter esse o valor do coeficiente de relação para quaisquer duas interseções vizinhas com vias comuns. Esse cálculo é realizado pelos três algoritmos e posteriormente é aplicado o modelo BiNN em um cenário com características e demandas reais.

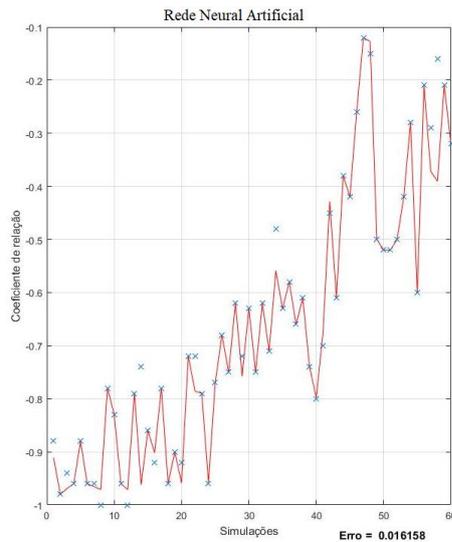


Figura 4. Resposta do método de Redes Neurais Artificiais.

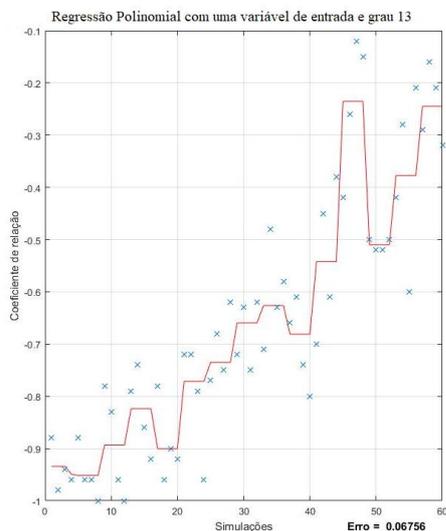


Figura 5. Método de Regressão Polinomial com uma variável.

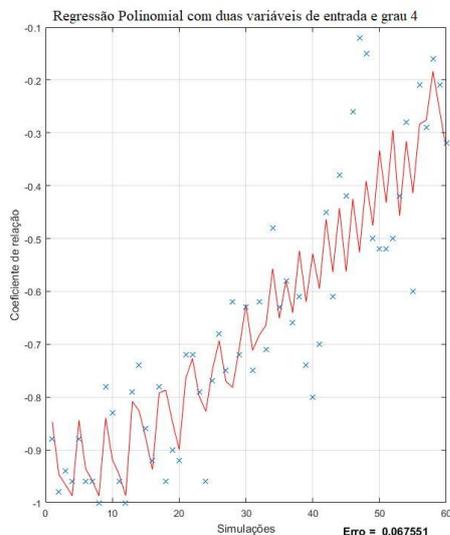


Figura 6. Método de Regressão Polinomial com duas variáveis.

V. SCENARIO

A cidade de São Paulo tem grandes problemas com o nível engarrafamento no trânsito. Sendo um de os maiores aglomerados urbanos no mundo, segundo [15], com uma população de 12.038.175 só em sua região metropolitana, a qual tem uma extensão de 1521,11 km² tendo uma densidade de população de 7.914,07 habitantes/km², em toda sua área. A cidade conta com uma frota veicular de aproximadamente 7 milhões de veículos e uma extensão de vias de aproximadamente 17.000 km [16]. Por este fato, São Paulo tem uns dos maiores índices de engarrafamento no trânsito, chegando a ter segundo [16], engarrafamentos de mais de 150 km na região do centro expandido com muita frequência nos horários de picos do trânsito.



Figura 7. Cenário escolhido

O cenário escolhido encontra-se na região de Butantã perto da estação do mesmo nome, é bem do tem um total de 7,4 km de ruas e avenidas (Figura 7), com 9 intersecções com semáforos. A Rodovia Raposo Tavares tem um fluxo bem alto de veículos procedente da região Sudoeste da Grande São Paulo, mesma característica apresentada pela Av. Professor Francisco Morato. Além disso esta região tem uma característica muito importante na hora de avaliar nossa proposta, as distâncias das vias comuns entre as intersecções vizinhas, essas distancias variam entre 70 e 400 metros, as velocidades máximas permitidas nessas vias também variam entre 40 e 60 km/h. As rotas dos veículos foram programadas com as mesmas características das rotas de trânsito descritas e observadas em [16], [20].

VI. SIMULAÇÃO

As simulações correspondentes foram realizadas com o auxílio das ferramentas MATLAB e SUMO (“Simulation of Urban Mobility”) [17], [18]. O modelo BiNN foi programado na linguagem M do MATLAB, enquanto o modelo do sistema de trânsito urbano foi programado em XML (“eXtensible Markup Language”), linguagem utilizada pelo SUMO. Para executar as simulações e analisar os resultados, foi utilizado o protocolo TraCI4Matlab [19], que adota o paradigma cliente-servidor e permite a interação entre o SUMO (servidor) e o MATLAB (cliente). Todas as simulações tem um tempo de duração de 3600 s (uma hora).

Para o análises dos resultados foram realizadas 8 tipos de simulações diferentes, 6 simulações com o modelo BiNN e os três algoritmos apresentados para o cálculo do coeficiente de relação, além de um algoritmo de Controle de Semáforos com Tempos Fixos, atualmente usado para o controle dessas intersecções. As demandas de veículos usadas para avaliar o desempenho da nossa proposta são: demanda baixa, com 2.2 veículos por segundo começando o percorrido (entrando ao cenário) e demanda alta com 2.9 veículos começando o percorrido.

Por último, todos os veículos utilizados têm as mesmas características, 5 metros de comprimento, com aceleração de 0.8 m/s^2 e velocidade máxima de 16.67 m/s . Além de um comportamento de direção estocástico: sigma (parâmetro do simulador SUMO) igual a 0,5.

VII. RESULTADOS

Os indicadores de desempenhos adotados são o Tempo Médio de Viagem dos veículos (TMV), que foi utilizado no análises realizado por [7], [21], e o Nível de Ocupação das Vias do cenário (NOV) que foi utilizado por [8], [9]. Para o cálculo do tempo médio de viagem dos veículos calculou-se a média do tempo de viagem de todos os veículos que iniciaram e a acabaram o percorrido no cenário. Na Figura 8 mostram-se os valores de Tempo Médio de Viagem, obtidos nas 4 simulações realizadas para a análise dos resultados.

Para a demanda de trânsito baixa, o melhor resultado em termos de TMV foi obtido com o modelo BiNN e o método de Redes Neurais para o cálculo do coeficiente de relação entre as intersecções (166 segundos). Enquanto o pior resultado foi obtido pelo Método de Controle de Intersecções com Tempos Fixos. A diferença entre estes resultados é de 31 segundo, e representa uma melhor de um 15.7%.

Para uma demanda alta de trânsito as respostas apresentam um comportamento semelhante com a demanda baixa. Mas a diferença entre o melhor e o pior resultado aumenta em 40 segundos, que significa uma melhora de 16.5%, ligeiramente superior do que a anterior.

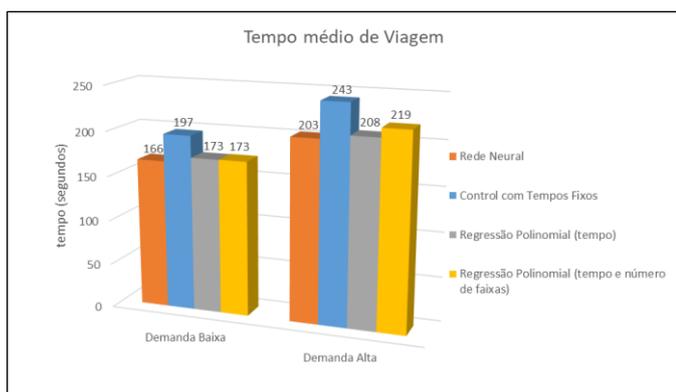


Figura 8. Tempo Médio de Viagem dos veículos

Em relação ao NOV, as simulações realizadas forneceram os resultados mostrados nas Figuras 9 e 10 e os valores médios deste parâmetro apresentam-se na Figura 11. No caso das respostas para a demanda baixa de trânsito, o melhor resultado também foi obtido pelo modelo BiNN com o método de Redes Neurais para o cálculo do coeficiente de relação e a pior resposta

foi obtido pelo Método de Controle de Intersecções com Tempos Fixos (Figura 9). Mesmo comportamento que o analisado para o parâmetro anterior. Neste caso na Figura 9 podemos observar que a curva da resposta do parâmetro NOV com Redes Neurais estabiliza-se num valor próximo aos 450 veículos, enquanto a resposta de Tempos Fixos no consegue se estabilizar. Analisando o valor médio deste parâmetro (Figura 11), o primeiro método apresenta uma melhoria de um 15.6% com respeito ao controle com Tempos Fixos.

No caso da demanda alta de trânsito podemos observar que a resposta não tem ponto de estabilização para nenhum dos métodos utilizados, portanto podemos inferir que esta demanda cumpre com o objetivo proposto de saturar as vias. Neste caso, o comportamento das respostas dos diferentes métodos também apresenta a mesma característica, a melhor resposta continua sendo o método de Redes Neurais para o cálculo do coeficiente de relação no modelo BiNN e a melhora do primeiro método com respeito ao segundo é de 17.7%.

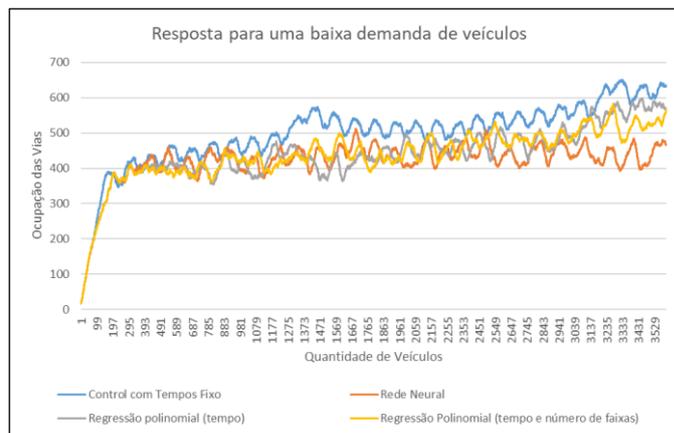


Figura 9. Nível de Ocupação das Vias para demanda baixa de trânsito

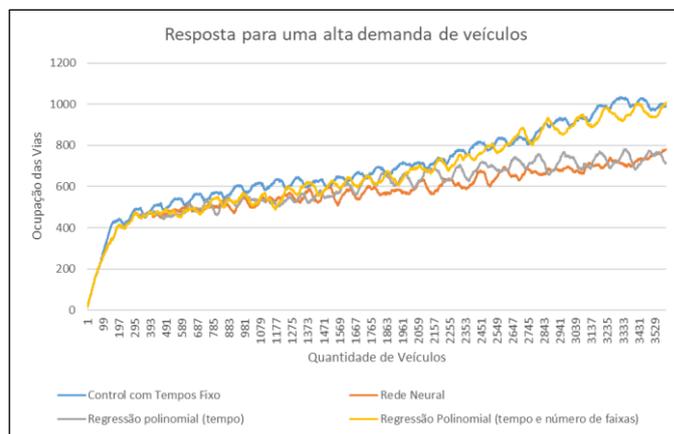


Figura 10. Nível de Ocupação das Vias para demanda alta de trânsito

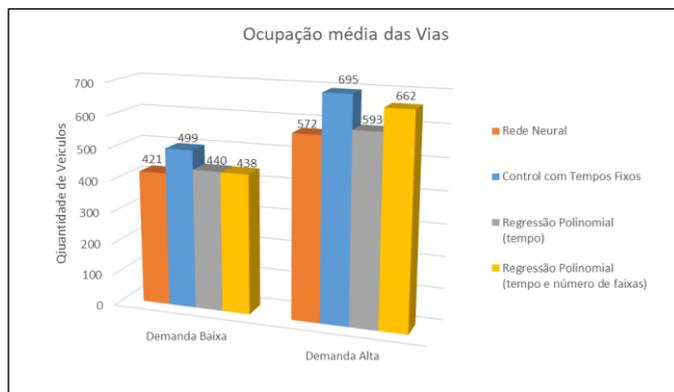


Figura 11. Valor médio do Nível de Ocupação das Vias

VIII. CONCLUSIONS

Este trabalho descreveu a aplicação de um Algoritmo de Controle Adaptativo para o controle multiagente e a sincronização das intersecções vizinhas, diferenciando a relação entre cada intersecção dependendo de parâmetros reais das vias como: distância entre intersecções, velocidade máxima possível da via comum entre as intersecções e número de faixas da via comum. O algoritmo utilizado foi baseado em Redes Neurais Bio-Inspiradas, mas para o cálculo dos coeficientes de relação entre as intersecções foram analisados três métodos: Redes Neurais Artificiais, Regressão Polinomial com duas variáveis de entrada e Regressão Polinomial com uma variável de entrada. Os resultados mostraram que o método de Redes Neurais fornece a melhor solução, obtivendo uma melhoria em média e em comparação com um método de Controle de Tempos Fixos de 16.38% em termos de Tempo Médio de Viagem e Nível de Ocupação das Vias. Portanto podemos concluir que com um modelo adaptativo de controle de trânsito pode se conseguir uma diminuição dos engarrafamentos de trânsito.

ACKNOWLEDGMENT

Este trabalho foi apoiado pela Coordenação de aperfeiçoamento de pessoal de nível superior (CAPES). Agradecemos o apoio do Instituto de Sistemas de Transporte (DLR) por permitir o uso do software de simulação SUMO.

REFERENCES

- [1] United Nations, "World population prospects. Key finding and advance tables," New York, 2017.
- [2] A. Arroub, B. Zahi, E. Sabir, and M. Sadik, "A literature review on Smart Cities: Paradigms, opportunities and open problems," *2016 Int. Conf. Wirel. Networks Mob. Commun.*, pp. 180–186, 2016.
- [3] Y. Hernafi, M. Ben Ahmed, and M. Bouhorma, "An Approaches ' based on Intelligent Transportation Systems to Dissect Driver Behavior and Smart Mobility in Smart City," pp. 886–895, 2016.
- [4] F. Vit, N. Mirko, S. Miroslav, and V. Zdenek, "System alliances as a tool for solving Smart Cities problems," *2015 Smart Cities Symp. Prague, SCSP 2015*, 2015.
- [5] I. S. and S. SIEMENS, "Solutions for Urban Traffic, Intelligent Traffic Systems."
- [6] J. Von Stritzky and C. Cabrerizo, "Ideas paras las ciudades inteligentes del futuro," p. 64, 2011.
- [7] G. B. Castro, J. S. C. Martini, and A. R. Hirakawa, "Biologically-Inspired Neural Network for Traffic Signal Control," in *IEEE 17th International Conference on Intelligent Transportation Systems (ITSC)*, 2014, pp. 2144–2149.
- [8] G. B. Castro, D. S. Miguel, B. P. Machado, and A. R. Hirakawa, "Biologically-Inspired Neural Network for Coordinated Urban Traffic Control: Parameter Determination and Stability Analysis," in *2015 International Conference on Computational Science and Computational Intelligence (CSCI)*, 2015, pp. 209–214.
- [9] A. Diveev, E. Sofronova, and V. Mikhalev, "Model Predictive Control for Urban Traffic Flows," *IEEE Int. Conf. Syst. Man, Cybern.*, pp. 3051–3056, 2016.
- [10] S. Araghi, A. Khosravi, and D. Creighton, "Optimal Design of Traffic Signal Controller Using Neural Networks and Fuzzy Logic Systems," *Int. Jt. Conf. Neural Networks*, pp. 42–47, 2014.
- [11] M. B. W. de Oliveira and A. de A. Neto, "Optimization of Traffic Lights Timing based on Artificial Neural," *IEEE 17th Int. Conf. Intell. Transp. Syst.*, pp. 1921–1922, 2014.
- [12] M. Elgarej, M. Khalifa, and M. Youssfi, "Traffic Lights Optimization with Distributed Ant Colony Optimization Based on Multi-agent System," *Springer Int. Publ. AG*, pp. 266–279, 2016.
- [13] T. Kaur and S. Agrawal, "Adaptive Traffic Lights Based On Hybrid of Neural Network and Genetic Algorithm for Reduced Traffic Congestion," *Eng. Comput. Sci. (RAECS), 2014 Recent Adv.*, pp. 266–279, 2014.
- [14] J. R. Peláez and D. Andina, "Do biological synapses perform probabilistic computations?," *Neurocomputing*, vol. 114, pp. 24–31, 2013.
- [15] "Demographia World Urban Areas: 12th Annual Edition," *Demographia*. Frontier Centre for Public Policy, p. 112, 2016.
- [16] Prefeitura de São Paulo, "Companhia de Engenharia de Tráfego de São Paulo," 2017. [Online]. Available: <http://www.cetsp.com.br/>. [Accessed: 02-Mar-2018].
- [17] M. Behrisch, L. Bieker, J. Erdmann, and D. Krajzewicz, "SUMO – Simulation of Urban MObility An Overview," *Inst. Transp. Syst.*, pp. 1–6, 2011.
- [18] R. Hilbrich, "SUMO – Simulation of Urban MObility," *Institute of Transportation Systems*. [Online]. Available: http://www.dlr.de/ts/en/desktopdefault.aspx/tabid-9883/16931_read-41000/. [Accessed: 07-Apr-2017].
- [19] A. F. Acosta Gil, "TraCI4Matlab: User's Manual," 1, 2014.
- [20] Globo Comunicação e Participações S.A, "Radar do trânsito em tempo real de São Paulo," 2017. [Online]. Available: <http://g1.globo.com/sao-paulo/transito/radar-tempo-transito-agora.html>.
- [21] B. L. Ye, W. Wu, L. Li, and W. Mao, "A hierarchical model predictive control approach for signal splits optimization in large-scale urban road networks," *IEEE Trans. Intell. Transp. Syst.*, vol. 17, no. 8, pp. 2182–2192, 2016.