


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

Aluno: Nelson Murcia García

Orientador: Prof. Dr. André Riyuiti Hirakawa

Dissertação de Mestrado






Introdução


- O desenvolvimento das grandes cidades é governado pela economia e pelo desenvolvimento social.

População total
(ano 2007)



aumentará

População total
(ano 2050)



■ População Urbana ■ População Rural

■ População Urbana ■ População Rural



Mobilidade



Engarrafamento de Trânsito




diminuição da qualidade de vida dos indivíduos

perda da produtividade da força de trabalho

aumento do custo operacional

poluição do ar



Problema

Ações a serem executadas para resolver os problemas de mobilidade

Aumento da infraestrutura de estradas e rodovias

Limitações: requer grandes orçamentos

Aumento das opções do transporte público

Limitações: Ônibus também somam grandes quantidades de veículos. Trens, metrô e trilhos precisam de grandes orçamentos e um longo tempo para a construção da sua infraestrutura.

Controle Inteligente nas interseções das vias
alternativa econômica e de rápida implementação



Problema

Sistema de Trânsito Urbano


- Estocástico
- Com Natureza Imprevisível
- Não Linear
- Parcialmente observável
- Possui variáveis dependentes do tempo
- Agentes que possuem relações de interdependência



Sistema com dinâmica complexa



Não existe uma posição comum sobre qual método de controle utilizar



Estratégias utilizadas para o controle do tempo de ativação das fases

- Tempo fixo
- Acionados por veículos
- Estratégias de controle adaptativas



Estratégias de controle adaptativas


- Dividem-se em: Métodos baseados em Controle Ótimo e Métodos baseados em Inteligência Artificial
- Visa implementar uma temporização ideal para maximizar ou minimizar uma função objetiva.
- Utilizam dados de sensores para estimar o fluxo de trânsito.

Limitações gerais

- Simplificação dos dados.
- Linearização da dinâmica.
- Discretização do problema em ciclos.



Perda de dados importantes da dinâmica do sistema



Metodologias baseadas em Teoria de Controle Ótimo


Revisão bibliográfica

Métodos	Vantagens	Desvantagens
Programação dinâmica	<ul style="list-style-type: none">• Podem utilizar aproximações lineares.• Otimiza o tempo de ativação das fases semaforicas.	<ul style="list-style-type: none">• Sofre com dados de entrada com grandes intervalos• Complexidade computacional não linear e tempo alto de resposta.• Não considera o caráter estocástico.
Controle preditivo baseado em modelos	<ul style="list-style-type: none">• Estima os estados futuros do fluxo de veículos.• Melhora o tempo de resposta.	<ul style="list-style-type: none">• Precisa de um modelo para prever os valores.• Utilizam modelos macroscópicos.
Contrapressão	<ul style="list-style-type: none">• Complexidade computacional é linear.• Atualização on-line do ciclo semaforico e do tempo de cada fase.	<ul style="list-style-type: none">• Consideram a capacidade das vias infinitas.• Para alta demanda de veículos, o engarrafamento se propaga pelas vias de interseções vizinhas.

Metodologias baseadas em Inteligência Artificial

Revisão bibliográfica

Métodos	Vantagens	Desvantagens
Lógica Difusa	<ul style="list-style-type: none">Lida com incertezas nas variáveis de entradas.	<ul style="list-style-type: none">Dificuldade em incorporar informações sobre a dinâmica do sistema.Definição das regras de controle e de seus parâmetros não é ótima.
Algoritmos evolucionários	<ul style="list-style-type: none">Atuam como base para utilizar junto com outros métodos.	<ul style="list-style-type: none">Tempo alto de resposta.
Aprendizado por Reforço	<ul style="list-style-type: none">Cálculo em tempo real.Analisa estados anteriores do sistema.	<ul style="list-style-type: none">Precisa de fatores de influência para outorgar as recompensasRequer uma estrutura de otimização inicial.
Redes Neurais Artificiais	<ul style="list-style-type: none">Podem ser utilizados em conjunto com outros métodos.	<ul style="list-style-type: none">Precisam de uma quantidade elevada de dados.Tempo de treinamento.



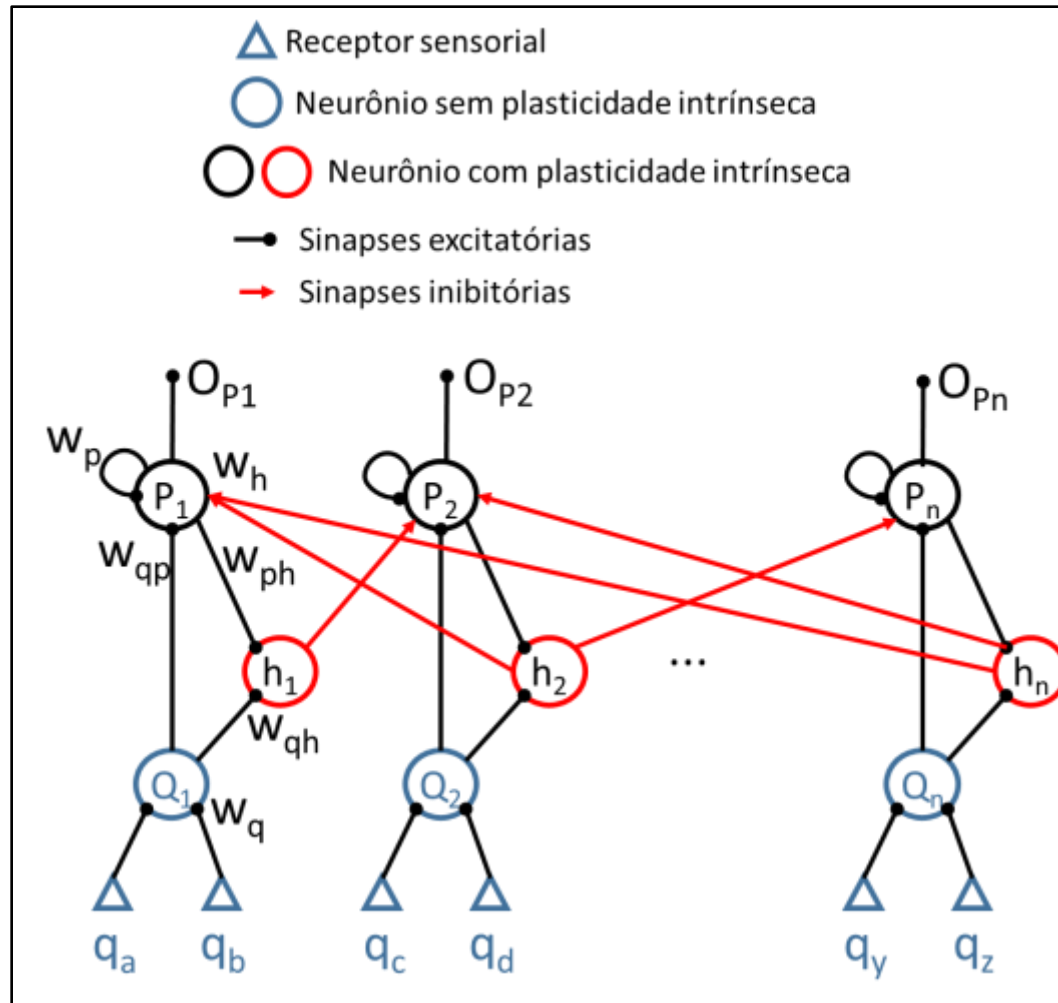
Modelo de Redes Neurais Bio-Inspiradas para o Controle de Trânsito Urbano (Castro G. B. , 2017)

Vantagens

- Concentra-se na dinâmica local.
- Baseia-se em equações analíticas.
- Uso da informação adquirida para determinar uma estratégia de controle.
- Coordena as atividades dos agentes vizinhos provocando ondas de luzes verdes nas interseções vizinhas.
- Não possui um estágio de treinamento.
- Apresenta resultados satisfatórios na estabilidade dinâmica e adaptação instantânea a mudanças no ambiente.

Modelo BiNN para o Controle de interseções

Estrutura Dinâmica



$O_{p1,p2 \dots Pn}$ - saídas do modelo
 $p_{1,2 \dots n}$ - neurônios excitatórios
 $h_{1,2 \dots n}$ - interneurônios inibitórios
 $Q_{1,2 \dots n}$ - neurônios sensoriais
 $q_{a,b,c,d \dots y,z}$ - receptores sensoriais

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

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


$$s_i^{t+1} = \frac{v O_i^t + s_i^t}{v + 1}$$



Modelo BiNN para o Controle de Interseções

Princípios Fundamentais


- Inibição lateral
 - Inibição das atividades de outras fases semaforicas.
- Plasticidade intrínseca
 - Limita a quantidade máxima de tempo que uma fase está inativa.
- Plasticidade sináptica
 - Priorização dos fluxos dos veículos, por causa da atualização dos pesos sinápticos.




Modelo BiNN para a Coordenação entre Interseções

Funções

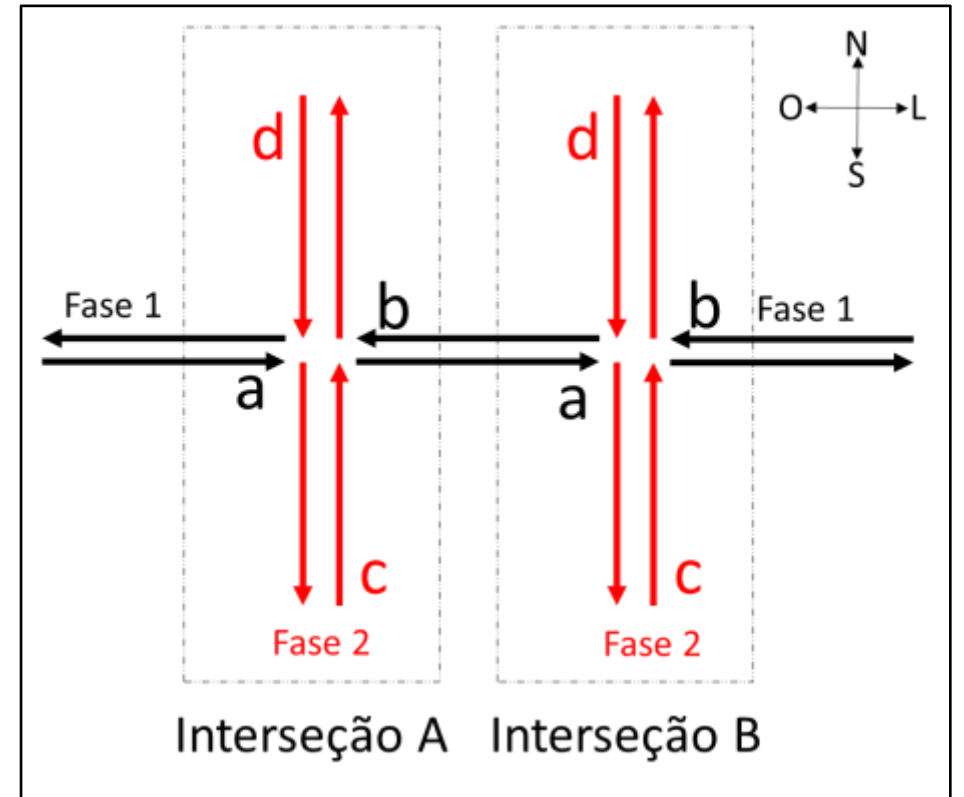

1. Armazenar a informação quando uma fase de um agente vizinho for ativada até que a fase comum do seguinte agente correspondente esteja pronta para se tornar ativa.
2. Inibir a fase ativa atual de um agente nos casos em que o nível de ocupação na via comum da próxima interseção estiver alta.






Modelo BiNN para a Coordenação entre interseções

Estrutura Dinâmica



Justificativa e Motivação



Limitações do modelo BiNN desenvolvido por Castro G. B., 2017 para o Controle do Trânsito Urbano :

- Não diferencia as relações de coordenação existentes entre as interseções vizinhas.
- Os cenários adotados para os testes foram idealizados.

Objetivo

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




Metodologia

- Distância entre as interseções, Velocidade máxima dos veículos, e o Número de Faixas da via são independentes e não determinísticas.
- Encontrar a relação de forma empírica.
- Realizar um estudo para determinar quanto influencia cada fator na relação de coordenação entre duas interseções.
- Adicionar uma função para incluir as informações ao modelo.
- Incorporar essas informações sem modificar os comportamentos do modelo como a estabilidade da rede neural e a complexidade computacional escalar demonstrados anteriormente.
- Analisar e validar a extensão proposta ao modelo, com simulações realizadas em um cenário réplica de um cenário real da cidade de São Paulo.



Modelo BiNN proposto para a Coordenação diferenciada entre interseções


Estrutura



$$w_a = 1 - f(d, v_{max}, n_f)$$



- d – distância entre as interseções
- v_{max} – velocidade máxima atingida pelos veículos
- n_f – número de faixas da via comum


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




Análise de Regressão

- Encontrar uma função entre variáveis independentes e dependentes por meio de relações empíricas.
- Necessita de uma coleta de dados inicial e do uso de métodos estatísticos, para conhecer a natureza da relação entre as variáveis de entrada e saída.
- Foi utilizado para prever os possíveis valores do coeficiente de relação entre duas intersecções, dependendo dos parâmetros reais das vias.





Dados Necessários para Análise de Regressão



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

60 conjuntos de dados $f(d_i, v_{max_i}, n_{f_i}) \rightarrow CR_i$

CR_i é o CR da Melhor Resposta avaliado por:

- Tempo Médio de Viagem
- Nível Médio de Ocupação das Vias

De 100 simulações (0.01 - 0.02 - 0.03 - ... - 1)

Configuração dos Dados


- Configuração do cenário varia dependendo das variáveis de entrada (distância entre interseções e número de faixas)
- Demanda de veículos: 2.75 veículos/segundo
- Programação – MATLAB / Simulação - SUMO
- Duração de 3600 segundos
- Aplicado o novo modelo BiNN com $w_{bp} = 1 - w_a = CR$
- Valores iniciais dos parâmetros usados por Castro, Hirakawa e Martini (2017)

Número de Série de Simulação	Variáveis de Entradas			Variável de Saída
	Distância d	Velocidade Máxima v_{max}	Velocidade Máxima v_{max}	Coefficiente de Relação $\frac{O}{CR} \rightarrow L$
1	450	60	3	0,12
2	450	60	4	0,15
Fase 1	450	40	2	0,16
4	450	40	3	0,21
5	450	50	4	0,21
.
.
.
55	60	60	4	0,96
56	150	40	4	0,96
57	150	50	2	0,96
58	50	60	2	0,98
59	50	40	4	1
60	50	50	4	1

Para obter a relação entre d_i, v_{max_i}, n_{f_i} e CR foram utilizados 3 funções:

- Função polinomial com uma variável (P1V)
- Função polinomial com duas variáveis (P2V)
- Redes Neurais Artificiais Supervisionadas (RNA)







Métodos de Ajuste de Curvas

Função polinomial com uma variável (P1V)

- $P(x) = a_0x^n + a_1x^{n-1} + a_2x^{n-2} + \dots + a_{n-1}x + a_n$
- Variável de entrada: $t_{min} = \frac{d}{v_{max}}$, não compreende $n_f \rightarrow CR = f(t_{min})$
- $\rho_{t_{min} \leftrightarrow CR} = -0.877$ (Correlação)
- Melhor solução: Função polinomial de grau 8 com $\bar{E} = 6.42\%$






Métodos de Ajuste de Curvas

Função polinomial com duas variáveis (P2V)

- Variáveis de entradas : $t_{min} = \frac{d}{v_{max}}$, n_f $CR = f(t_{min}, n_f)$
- $\rho_{t_{min} \leftrightarrow CR} = -0.877$, $\rho_{n_f \leftrightarrow CR} = 0.021$
- $\bar{E} = 6.01\%$




• Coeficiente de Referência obtido das simulações — Resposta Função polinomial com duas variáveis



Métodos de Aprendizado


Redes Neurais Artificiais Supervisionadas (RNA)

- Variáveis de entradas : d, v_{max}, n_f $CR = f(d, v_{max}, n_f)$
- RNA com 3 camadas (9,4,1) / Ft: Tangente Hiperbólica
- Algoritmo de Treinamento: Backpropagation Levenberg-Marquardt.
- Função de desempenho: Erro Quadrático Médio
- $\rho_{d \leftrightarrow CR} = -0.908, \rho_{v_{max} \leftrightarrow CR} = 0.157, \rho_{n_f \leftrightarrow CR} = 0.021$
- $\bar{E} = 1.95\%$



Prova de conceito

- Analisar o comportamento das 3 funções de cálculo do CR obtidos.
- Avaliar em um cenário réplica de um cenário real.
- Analisar a resposta em termos de TMV e NOV.
- Comparar o modelo BiNN usando os métodos de cálculo do CR com o algoritmo BiNN original e com Controle com Fases Prefixadas (CFP).






Cenário

- Início da Rodovia Raposo Tavares e Av. Professor Francisco Morato
- Total de 7,4 km de vias
- 9 interseções com semáforos
- Apresenta engarrafamento sobretudo nos horários de picos.
- $d\{70 \dots 400\}$, $v_{max}\{40,50,60\}$, $n_f\{1,2,3,4\}$
- Rotas dos veículos: Pesquisas de campo e CET








Resultados


Tempo Médio de Viagem



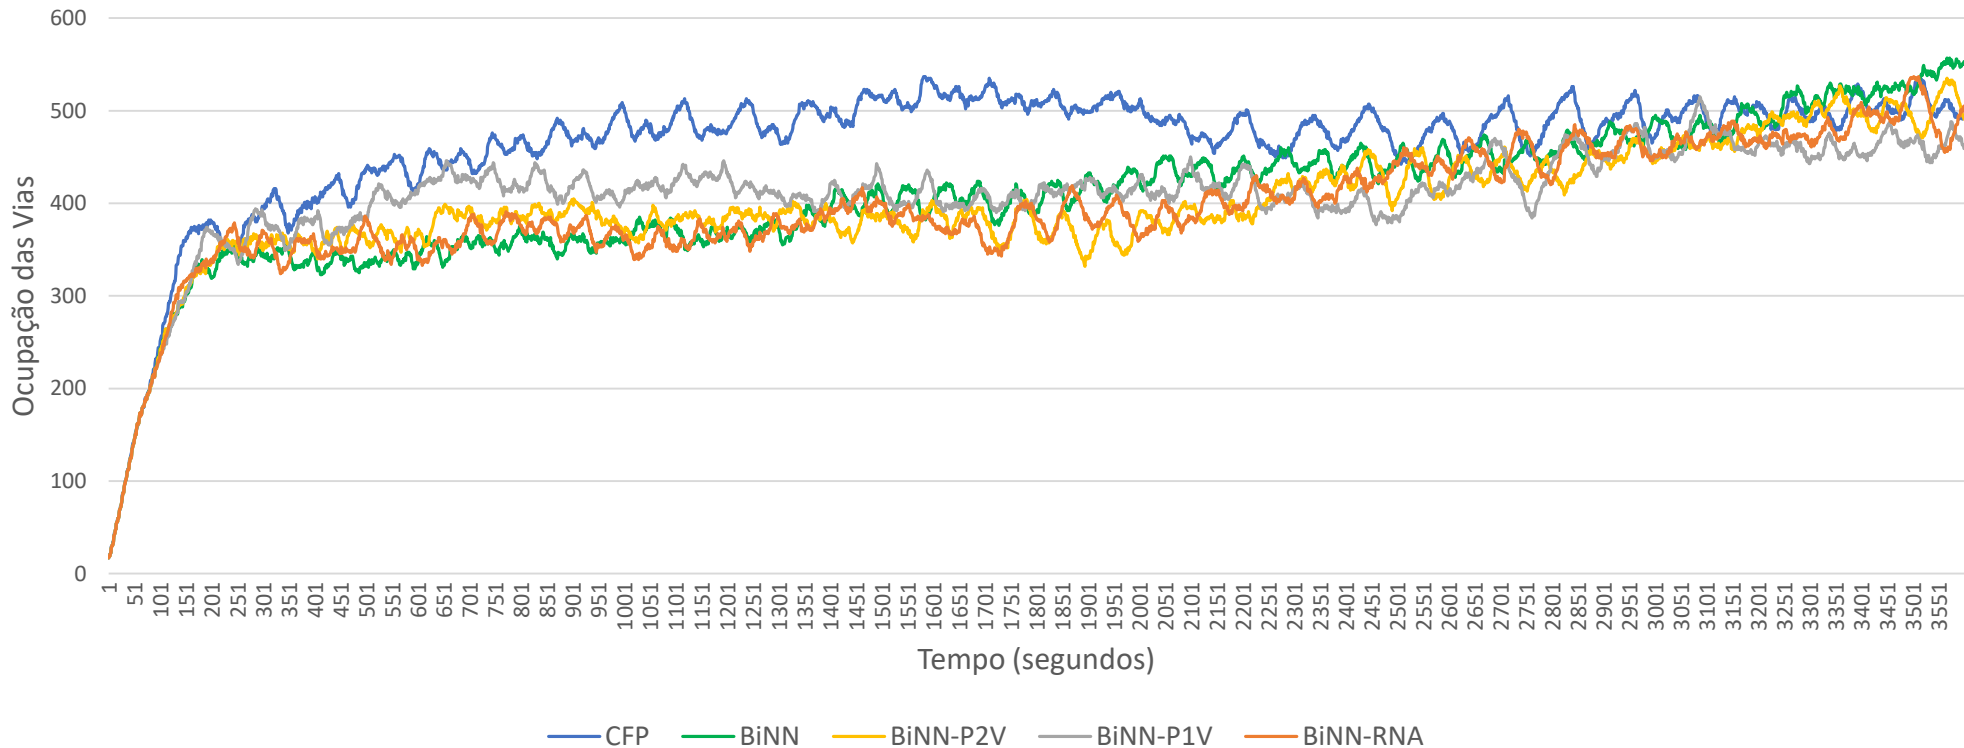
Resultados

Nível de Ocupação das Vias

Nível de Médio de Ocupação das Vias sob demanda baixa de veículos





Nível de Ocupação das Vias sob demanda baixa de veículos





Resultados

Nível de Ocupação das Vias



Resultados

Nível de Ocupação das Vias



Considerações sobre os resultados

Porcentagem de melhoria do modelo BiNN-RNA com relação à BiNN:

Modelo	Demanda Baixa	Demanda Média	Demanda Intensa	Geral (ponderada)
TMV	2,1%	5,3%	10,6%	6,6%
NMOV	2,8%	7,2%	8,1%	6,4%

- Método BiNN-RNA apresentou os melhores resultados.
- Métodos que diferenciam as relações entre interseções apresentaram melhores do que o método sem diferenciar relações





Conclusões

- Melhoria do modelo BiNN, acrescentando características físicas reais dos cenários, para diferenciar as relações existentes entre interseções vizinhas.
- Foi adicionado o CR, que descreve o nível de influência que existe entre as interseções.
- O CR foi utilizado para calcular os valores das sinapses w_{bp} e w_a no modelo de Coordenação de interseções.
- O cálculo do valor de w_{bp} e w_a é off-line, portanto não influencia nem na complexidade computacional, nem na estabilidade do algoritmo.
- Para encontrar $f(d, v_{max}, n_f)$ realizou-se uma análise de regressão utilizando 3 funções diferentes: P1V, P2V e RNA.



Conclusões

- Os resultados mostraram que RNA apresentou o melhor resultado (melhor \bar{E})
- As simulações foram realizadas em um cenário réplica de um cenário real.
- Baseados nos indicadores de desempenho TMV e NOV foi concluído que o BiNN-RNA obteve o melhor desempenho, apresentando uma melhoria de 6,6% e 6,4%, respectivamente.
- Pode-se concluir que o modelo proposto (BiNN-RNA) melhora os resultados obtidos anteriormente pelo modelo BiNN.



Trabalhos Futuros

- Utilizar um método de aprendizado por reforço para otimizar o cálculo do parâmetro CR, sendo possível a atualização on-line.
- A aplicação do método proposto em hardware e aplicar no controle de um grupo de interseções com semáforos para conseguir avaliar os resultados na prática.

Publicações

- Murcia, N., Hirakawa, A. R., & Castro, G. B. (2017). *Bio-Inspired Neural Network Model Applied to Urban Traffic Control in a Real Scenario*. In H. R. Arabnia, L. Deligiannidis, F. G. Tinetti, Q.-N. Tran, & M. Q. Yang (Eds.), *4th Annual Conf. on Computational Science & Computational Intelligence* (pp. 303–308). IEEE Computer Society. <https://ieeexplore.ieee.org/document/8560806>
- Murcia, N., Hirakawa, A. R., & Castro, G. B. (2018). *Bio-inspired Neural Network Model applied in Urban Traffic Control*. *Memórias do XII Workshop de Tecnologia Adaptativa - WTA 2018*. São Paulo. Retrieved from <http://lta.poli.usp.br/lta/publicacoes/artigos/2018/garcia-hirakawa-e-castro-2018-bio-inspired-neural-network-applied-to-urban-traffic-control-in-a-real-scenario/view>
- Murcia, N. & Hirakawa, A. (2019). *Controle adaptativo de interseções em trânsito urbano baseado em parâmetros reais de vias*. *Memórias do XIII Workshop de Tecnologia Adaptativa - WTA 2019*. São Paulo. Retrieved from <http://lta.poli.usp.br/lta/publicacoes/artigos/2019/garcia-e-hirakawa-2019-controle-adaptativo-de-intersecoes-em-transito-urbano-baseado-em-parametros-reais-de-vias/view>

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

Muito Obrigado!
Muchas Gracias!

Aluno: Nelson Murcia García

Orientador: Prof. Dr. André Riyuiti Hirakawa

Dissertação de Mestrado

