

Controle Inteligente de Semáforos Utilizando Redes Neurais Artificiais com Funções de Base Radial

Milton R. Heinen¹, Claudio Cesar de Sá², Felipe K. Silveira², Cristiane Cesconetto² e Gilberto Sohn Jr²

¹Curso de Engenharia de Computação – Universidade Federal do Pampa (UNIPAMPA)
Campus Bagé – CEP 96413-170 – Bagé, RS – Brasil

²Departamento de Ciência da Computação – Universidade do Estado de Santa Catarina (UDESC) – CEP 89219-710 – Joinville, SC – Brasil

milton.heinen@unipampa.edu.br, claudio@colmeia.udesc.br,
{felipekrugersilveira,cristiane.cesconetto,
gilbertosjr.jlle}@gmail.com

Resumo. *Os problemas de mobilidade têm aumentado de forma que o crescimento urbano não está conseguindo contê-los. Para amenizar esses problemas em geral são criadas novas vias e/ou vias alternativas, porém às vezes o custo dessas pode ser elevado e inviável em alguns cenários. Este trabalho apresenta uma abordagem que aproveita melhor os recursos disponíveis para melhorar o desempenho geral do trânsito. Para isso, são utilizadas estratégias inteligentes para o controle de semáforos, como aprendizagem por reforço, redes neurais artificiais e sistemas multiagente. Os resultados obtidos mostram que modelo proposto é uma alternativa viável para amenizar os problemas de congestionamento nas grandes cidades.*

1. Introdução

A demanda por mobilidade é uma das características da nossa sociedade neste século. Entretanto, mobilidade traz consigo um aumento dos problemas relacionados aos congestionamentos no trânsito. As ações até então adotadas para minimizar este problema visam ou uma melhora da malha viária com a construção de novas vias, ou a otimização do fluxo de tráfego na malha existente. Esta última é não apenas economicamente mais viável, como também a alternativa preferida por sociedades nas quais o fator meio ambiente é uma questão chave [BAZ 10a].

Uma abordagem clássica para a redução do congestionamento urbano é a sincronização dos semáforos de forma que os veículos possam atravessar uma via arterial em um sentido com uma velocidade específica, sem paradas. Esta abordagem apresenta bons resultados em ambientes cujo fluxo do tráfego varia de forma bem definida ao longo do dia, o que não é o caso na maioria das cidades brasileiras de grande porte, nas quais há diversas áreas de comércio e negócios, e não apenas uma, central. Além disto, a determinação de quais planos são mais apropriados para cada hora do dia é uma tarefa complexa que requer contagens e estudos do fluxo de tráfego em diferentes pontos da rede. Desta forma, abordagens mais flexíveis e robustas como as baseadas em sistemas multiagente são uma necessidade [BAZ 10b].

Este artigo apresenta uma nova abordagem, baseada em técnicas multiagente, aprendizado por reforço e redes neurais artificiais para o controle inteligente de sinais de trânsito. Esta abordagem é testada utilizando o simulador ITSUMO [BAZ 10a], que é

um simulador de trânsito bastante realístico desenvolvido no laboratório de sistemas multiagente (MASLab) da UFRGS. Este trabalho está estruturado da seguinte forma: a Seção 2 introduz os sistemas de controle inteligente de semáforos. As Seções 3 e 4 descrevem, respectivamente, o aprendizado por reforço e as redes neurais artificiais, que são as técnicas de aprendizado de máquina utilizadas neste trabalho. A Seção 5 apresenta o simulador ITSUMO e suas características. A Seção 6 descreve os experimentos realizados bem como os resultados obtidos. Por último, a Seção 7 apresenta algumas conclusões e perspectivas.

2. Controle inteligente de semáforos

Controladores de semáforos geralmente usam um conjunto de parâmetros que determinam o comportamento desejado para determinada intersecção. Dentre esses parâmetros, destacamos os conceitos de fase e de plano semaforico. Uma fase corresponde à especificação de um conjunto de movimentos permitidos. Um plano semaforico corresponde a um conjunto único de configurações de temporização para as fases, ou seja, um plano semaforico determina quais fases serão ativadas, em que ordem, e por quanto tempo.

Usualmente a escolha de planos semaforicos visa minimizar o atraso total em determinado cruzamento. A fim de lidar com mudanças nas condições de tráfego, vários planos semaforicos são definidos, um para cada padrão de fluxo. Planos bem projetados podem atingir resultados aceitáveis caso sejam sincronizados. De maneira geral, quanto maior o número de intersecções adjacentes sincronizadas, menores são as filas. Infelizmente, no caso geral é impossível se obter sincronização simultânea em todas as direções e sentidos. Por esta razão os planos precisam ser selecionados de forma a priorizar apenas alguns sentidos.

Caso não se disponha de dados de situações passadas para uso por parte de abordagens pré-programadas, é possível se aplicar sistemas sensíveis ao tráfego. O uso desses sistemas teve início na década de 80 e alcançou razoável sucesso na Europa. Entretanto, eles ainda apresentam altos custos de comunicação e hardware, além de desvantagens técnicas, como o fato de exigirem a definição a priori de planos semaforicos para cobrir todas as situações relevantes ao controlador [CAM 03].

Em [PAP 03] é apresentada uma revisão de métodos clássicos oriundos da engenharia de tráfego. Como foi dito, existe uma demanda por soluções mais flexíveis e robustas para o controle de semáforos. Em [BAZ 05] uma abordagem baseada em SMA é descrita, onde cada semáforo é modelado como um agente. Cada agente possui planos pré-definidos para coordenação com agentes adjacentes. Planos diferentes podem ser escolhidos para haver coordenação em diferentes direções de acordo com a hora do dia. Essa abordagem utiliza técnicas de teoria dos jogos evolucionária. Os principais benefícios dessa abordagem são: os agentes podem criar subgrupos de sincronização para melhor atender às necessidades do fluxo em alguma direção, não há necessidade de um controle central e não há comunicação nem negociação direta entre os agentes. No entanto, são necessárias matrizes de pagamento (“*pay-off matrices*”) e essas matrizes devem ser formalizadas explicitamente pelo projetista do sistema. Isto faz com que a abordagem consuma tempo quando diferentes opções de coordenação são possíveis e/ou a rede de tráfego é muito complexa (não há somente uma via principal a ser considerada).

3. Aprendizado por reforço

A área de Aprendizado por Reforço (AR) é comumente utilizada para determinar ações ótimas em problemas de decisão sequenciais. Em geral, problemas de AR são modelados como Processos de Decisão de Markov (*Markov decision processes* ou MDP). Métodos de AR podem ser independentes de modelo ou baseados em modelos. Estes últimos assumem que a função de transição T e a função de recompensa R são disponíveis. Métodos independentes de modelo, por outro lado, isentam o agente de conhecer quaisquer informações a respeito da dinâmica do ambiente. O *Q-Learning* é o algoritmo de AR independente de modelo mais simples atualmente em uso. Ele opera através da constante melhoria de estimativas de valores estado-ação, ou *valores Q*, ou seja uma estimativa numérica da qualidade de um par de estado-ação [NAI 05].

O problema associado às técnicas de aprendizado por reforço tradicionais é a necessidade de que as ações e estados sejam discretos, o que limita seu uso em muitas aplicações reais e/ou exige uma discretização prévia das informações sensoriais. Além disso, para que haja convergência todos os pares de ações-estados precisam ser experimentados, o que prejudica o aprendizado quando o número de ações e estados é muito grande. Uma forma de se resolver estes problemas é através do uso de aproximadores de funções. Em [WAS 10] uma técnica chamada *Tile Coding* foi utilizada para permitir estados contínuos no controle inteligente de sinais de trânsito via aprendizado por reforço. Neste projeto serão utilizadas redes neurais artificiais como aproximadores de funções, que permitem o uso de ações e estados contínuos em aplicações de aprendizado por reforço.

4. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são sistemas de processamento paralelo e distribuído compostos por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas dispostas em uma ou mais camadas interligadas por um grande número de conexões geralmente unidirecionais [HAY 99]. As Redes Neurais Artificiais podem ser implementadas em computadores através de um simulador, que irá simular um modelo abstrato e simplificado dos neurônios humanos [HEI 06].

As RNAs são compostas por um conjunto de neurônios interconectados, como mostra a Figura 1. Dentre as principais características das Redes Neurais, uma das importantes é a sua capacidade de aprender por meio de exemplos, onde é bastante comum o uso de técnicas de aprendizado de máquina supervisionado, mas existindo também algoritmos de aprendizado semi-supervisionado ou não supervisionado [REZ 03]. Um dos modelos de aprendizado neural mais utilizados atualmente é o modelo denominado *Back-propagation* [RUM 86]. Neste modelo, é utilizado um conjunto de dados de exemplos padrões com as respectivas respostas esperadas (aprendizado supervisionado). Uma parte desses dados é utilizada como base de aprendizado, e outra parte é usada como base de validação (avaliação da generalização). Este tipo de aprendizado é conhecido como aprendizado supervisionado com validação cruzada [HAY 99]. Esta técnica permite avaliar se a RNA aprendeu os dados apenas 'decorando' ou se realmente aprendeu bem criando um modelo genérico (generalização) dos dados aprendidos.




Figura 2 – Exemplo de uma Rede Neural Artificial

Na área de controle inteligente de sinais de trânsito as redes neurais são ferramentas bastante adequadas, porque permitem a utilização de ações e estados contínuos em conjunto com as técnicas de aprendizado por reforço multiagente. Além disso, alguns modelos de redes neurais permitem a formação incremental de agrupamentos, possibilitando assim a criação de grupos de sinais de trânsito que possam atuar em conjunto de forma a maximizar o desempenho do sistema de trânsito.

5. Simulador Itsumo

A fim de testar as abordagens propostas o simulador ITSUMO (do inglês *Intelligent Transportation System for Urban Mobility*) [SIL 06b] foi utilizado. Este simulador é baseado em um modelo microscópico de movimentação física, o modelo baseado no autômato de Nagel-Schreckenberg, pois este tipo de modelo leva em consideração veículos individualmente e é relativamente mais complexo que um modelo macroscópico.

No cenário de tráfego urbano mais elementos foram adicionados, como semáforos e tipos mais complexos de intersecções. ITSUMO contém elementos diversos como: pistas, veículos, injetores de veículos (*sources*), coletores de veículos (*sinks*), detectores e semáforos. A configuração topológica da rede e os parâmetros da simulação pode ser armazenados em um banco de dados ou em arquivos do tipo XML. A Figura 2 mostra os principais módulos do simulador: aquisição de dados, simulação microscópica e visualização. O simulador inicializa a rede (lendo o arquivo XML) e o cenário e atualiza os detectores a cada intervalo de tempo pré-definido. O comportamento dos agentes que controlam os semáforos é um módulo a parte do simulador.

O módulo de aquisição e manutenção de dados se baseia em uma interface gráfica. O banco de dados em XML armazena informações relativas à topologia das malhas viárias, dados dos semáforos e informações dinâmicas, como contagens de fluxo de veículos. Adicionalmente às funcionalidades básicas da interface e do banco de dados, existem ferramentas para geração de estatísticas e geração automatizada de dados para os demais módulos, assim como algoritmos de sumarização de dados. O módulo de simulação propriamente dito é implementado em C++.

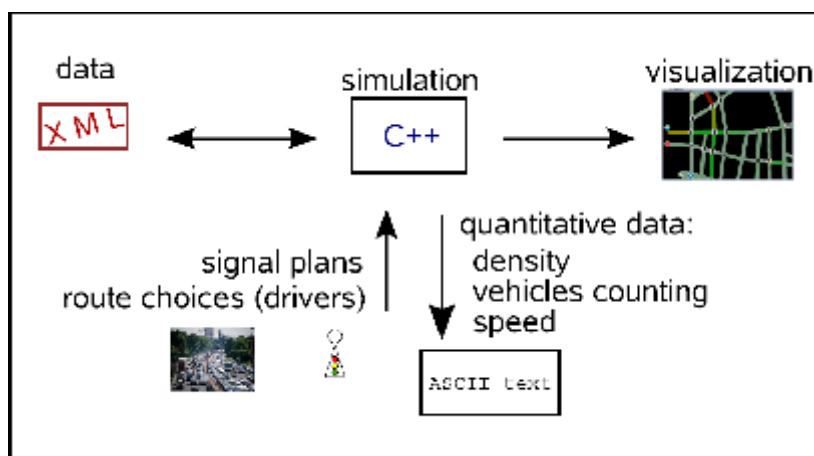


Figura 3 – Módulos da Ferramenta de Simulação

6. Modelo proposto

Esta seção descreve os detalhes do modelo proposto neste trabalho, bem como seu respectivo protótipo. Este modelo consiste na criação de um agente capaz de criar estratégias de controle através de seu conhecimento para um melhor desempenho no trânsito. Estas estratégias são implementadas usando técnicas de inteligência artificial a fim de diminuir o número de veículos nas filas de cada via, assim melhorando a fluidez como um todo.

Como visto anteriormente, vários sistemas de controle inteligente têm sua estrutura baseada em um sistema multiagente e, com base nisso, toda a implementação deste trabalho é baseada nos conceitos base de SMA (Sistemas multiagente). Neste sistema multiagente, cada agente será responsável por um nodo (cruzamento) da malha, tendo como responsabilidade obter as informações, perceber o ambiente, aprender com base nos *feedbacks* e atuar na melhor ação possível com base no seu conhecimento.

A atuação no ambiente do agente será basicamente escolher os planos de trânsito do seu nodo de responsabilidade, ou seja, no cruzamento existem semáforos nos quais o agente deverá estabelecer a temporização de cada um, tanto de turnos vermelhos quanto de turnos verdes. Essa decisão será baseada em experiências que o agente já teve, podendo ser positivas, negativas ou neutras. Essas experiências geram o conhecimento do agente, que tomará as decisões fundamentadas no aprendizado que teve a partir destas.

Dentre as técnicas abordadas de aprendizagem, neste projeto decidiu-se utilizar aprendizado por reforço, porém diferentemente de como seria tradicionalmente com *Q-Learning*, este trabalho utiliza redes neurais artificiais para que possam utilizar ações e estados contínuos, pois o *Q-Learning* necessita de ações e estados discretos, o que se torna inviável quando o número de ações e estados é muito grande. Assim, o modelo proposto se baseia na construção de um agente que tenha autonomia suficiente para poder manipular todos esses aspectos e que tenha a capacidade de aprender através de ações que terão *feedbacks* que definirão as decisões futuras.

Ao desenvolver este agente, foi utilizado o simulador ITSUMO descrito anteriormente. O ITSUMO é bastante funcional e permite a modelagem do problema com bastante versatilidade, permitindo inserção de informações como os cruzamentos e suas possíveis conversões, taxa de entrada e saída de carros da malha, taxa de probabilidade de conversão em cada cruzamento, etc.

7. Experimentos e resultados

Para validar o modelo proposto foram realizados experimentos utilizando duas malhas (mapas): um cruzamento simples e o um mapa modelado com nove cruzamentos. Primeiramente, foram rodados testes na malha de um cruzamento simples (Figura 3) onde os pontos azuis representam os *sources* e os pontos vermelhos os *sinks*. Nesta malha, a simulação durou 12000 unidades de tempo do simulador, e são necessárias aproximadamente 50 unidades de tempo para a simulação entrar em regime. Para se verificar a eficácia do modelo proposto os experimentos utilizando o agente foram comparados com os resultados obtidos utilizando semáforos tradicionais de tempo fixo.




Figura 4 – Malha utilizada para primeiro experimento

Os experimentos foram repetidos 10 vezes utilizando números aleatórios distintos, e para ao final foi calculado o número médio de carros parados em toda a malha. A Figura 4 mostra os resultados obtidos neste experimento, onde o eixo y do gráfico representa o número médio de carros parados durante a simulação. Percebe-se que o modelo proposto representa uma alternativa eficiente em comparação aos tempos fixos, pois além da diferença ser relativamente expressiva (o número médio de carros parados é aproximadamente 40% menor) os intervalos de confiança não se sobrepõem.




Figura 5 – Comparação do cruzamento simples

O próximo experimento utilizou um mapa mais elaborado, onde existem 9 cruzamentos (Figura 5), e pode se ver o comportamento do trânsito em uma área maior e possivelmente aplicável em uma situação real. As taxas de todos os *sources* neste mapa ficam intercalando entre 0.04 e 0.14, e mudam a cada 12000 unidades de tempo do simulador. É válido salientar que neste segundo caso, por ter mais ruas disponíveis, os carros parados em um semáforo sofrem a influência de uma probabilidade de qual será a sua rua de destino, levando em consideração em quais ruas ele pode acessar.




Figura 6 – Mapa de nove cruzamentos utilizado para validação

Para análise de resultados, foram realizados 10 experimentos com números aleatórios distintos, e ao final foi verificada a média de carros parados em cada experimento. Porém, diferentemente do primeiro experimento, aqui foram utilizados 72.000 unidades de tempo do simulador. Esse número maior que o do teste anterior justifica-se pelo tamanho maior do mapa, considerando que este começa vazio aos poucos se torna populoso. Um tempo maior é necessário para que este comece a demonstrar um comportamento padrão da situação.

Na Figura 6 mostra graficamente os resultados, onde novamente se verifica a superioridade do modelo proposto em relação aos semáforos de tempo fixo. Neste experimento a simulação leva em média 200 unidades de tempo para entrar em regime.




Figura 7 – Comparação da malha de nove cruzamentos

Com esta análise fica claro que os resultados obtidos pelo agente RBF são superiores à tradicional abordagem de tempos fixos. A diferença foi bem maior no primeiro caso pelo fato de que se congestionou o semáforo mais facilmente, uma vez que a taxa de chegada de carros na malha era maior que na segunda abordagem.

8. Conclusões

Este trabalho apresentou uma nova abordagem de controle inteligente de sinais de trânsito baseada em sistemas multiagente, redes neurais artificiais e aprendizado por reforço. Os experimentos realizados utilizando o simulador demonstram que o modelo proposto consegue obter melhores resultados em relação aos semáforos de tempos fixos nas simulações. Esta alternativa se mostra viável, uma vez que se sua implantação não gera tantos transtornos à sociedade quanto à criação de novas vias para solucionar um problema que às vezes pode estar atrelado a problemas de organização e não estruturais.

Como perspectivas futuras destaca-se o uso de mapas mais realísticos nos experimentos bem como a utilização do modelo proposto para o controle de semáforos reais em nossas cidades, bastando somente dotar os mesmos de sensores para que os mesmos possam perceber o número de carros parados em cada via.

Referências

- [BAZ 05] A. L. C. Bazzan. A distributed approach for coordination of traffic signal agents. *Autonomous Agents and Multiagent Systems*, 10(1):131–164, March 2005.
- [BAZ 10a] A. L. C. Bazzan, M. de Brito do Amarante, T. Sommer, and A. J. Benavides. ITSUMO: an agent-based simulator for ITS applications. In R. Rossetti, H. Liu, and S. Tang, editors, *Proc. of the 4th Workshop on Artificial Transportation Systems and Simulation*. IEEE, September 2010.

- [BAZ 10b] A. L. C. Bazzan, D. de Oliveira, and B. C. da Silva. Learning in groups of traffic signals. *Eng. Applications of Art. Intelligence*, 23:560–568, 2010.
- [CAM 03] E. Camponogara and W. K. Jr. Distributed learning agents in urban traffic control. In F. Moura-Pires and S. Abreu, editors, *EPIA*, pages 324–335, 2003.
- [HAY 99] S. HAYKIN. *Neural Networks – A Comprehensive Foundation*. Segunda Edição.: Pearson, 1999. 823p.
- [HEI 06] M. R. Heinen, F. S. Osório, F. Heinen e C. Kelber. SEVA3D: Using Artificial Neural Networks to Autonomous Vehicle Parking Control. In: *IJCNN - IEEE International Joint Conference on Neural Networks*, 2006, Vancouver. Vancouver, Canadá: IEEE Press, 2006. v.1. p.9454 -9461.
- [NAI 05] R. Nair, P. Varakantham, M. Tambe, and M. Yokoo. Networked distributed POMDPs: A synthesis of distributed constraint optimization and POMDPs. In *Proceedings, The Twentieth National Conference on Artificial Intelligence and the Seventeenth Innovative Applications of Artificial Intelligence Conference (AAAI)*, pages 133– 139. AAAI Press AAAI Press / The MIT Press, 2005.
- [PAP 03] M. Papageorgiou, C. Diakaki, V. Dinopoulou, A. Kotsialos, and Y. Wang. Review of road traffic control strategies. *Proceedings of the IEEE*, 91(12):2043–2067, December 2003.
- [REZ 03] S. Rezende (Ed.). *Sistemas Inteligentes : Fundamentos e Aplicações*. Barueri: Editora Manole, 2003. 525 p. ISBN 85-204-1683-7.
- [RUM 86] D. Rumelhart, G. Hinton, and R. Williams. *Learning Internal Representations by Error Propagation*. MIT Press, Cambridge, MA. 1986.
- [SIL 06b] B. C. d. Silva, D. d. Oliveira, A. L. C. Bazzan, and E. W. Basso. Adaptive traffic control with reinforcement learning. In *Proceedings of the 4th Workshop on Agents in Traffic and Transportation (AAMAS 2006)*, 2006.
- [WAS 10] S. J. Waskow, A. L. C. Bazzan. Improving Space Representation in Multiagent Learning via Tile Coding. *Proc. Brazilian Artificial Intelligence Symposium (SBIA)*, São Bernardo do Campo, SP, Oct. 2010.