

Sistemas Fuzzy evolucionários para controle de semáforos

Victor L. Silva * José Maria P. de Menezes Júnior **

* *Curso de Engenharia Elétrica, Universidade Federal do Piauí, UFPI,
(e-mail: victorlima.pi@gmail.com).*

** *Curso de Engenharia Elétrica, Universidade Federal do Piauí,
UFPI, (e-mail: josemenezesjr@ufpi.edu.br).*

Abstract: Heavy vehicle traffic is one of the main problems in large cities, and in Brazil, where the competent authorities have not trained road networks, overcrowding in traffic causes even more obstacles. The applications of computational intelligence techniques in traffic are very broad, with an emphasis on intelligent traffic lights. For the design of intelligent traffic lights, this work proposes the use of Fuzzy Logic, but its main objective is the automatic generation of Fuzzy systems. In order to achieve this objective, the SUMO traffic simulation software was used, which allowed the development of three intersection scenarios controlled by traffic lights. In these scenarios, the traffic performance was evaluated from different adjustments in the pertinence functions and in the set of rules of the Fuzzy system that controls the traffic lights, and these adjustments were made by the AG (Genetic Algorithm) and PSO (Particle Swarm Optimization) algorithms. When comparing traffic performance with traffic lights controlled by Fuzzy and optimized Fuzzy, there are quite significant improvements in the traffic variables analyzed, such as waiting time and the queue size of cars. Thus, this work shows the importance of using evolutionary Fuzzy models to optimize parameters.

Resumo: O tráfego intenso de veículos é um dos principais transtornos nas grandes metrópoles, e no Brasil, onde as autoridades competentes não capacitaram as redes viárias, a superlotação no trânsito causa ainda mais entraves. As aplicações das técnicas de inteligência computacional no trânsito são muito amplas, com destaque para os semáforos inteligentes. Para o projeto de semáforos inteligentes, este trabalho propõe o emprego da Lógica Fuzzy, mas tem como objetivo principal a geração automática de sistemas Fuzzy. Para a realização desse objetivo, foi empregado o software de simulação de tráfego SUMO, que permitiu a elaboração de três cenários de cruzamentos controlados por semáforos. Nesses cenários foram avaliados o desempenho dos tráfegos a partir de diferentes ajustes nas funções de pertinência e no conjunto de regras do sistema Fuzzy que controla os semáforos, sendo que esses ajustes foram efetuados pelos algoritmos AG (Algoritmo Genético) e PSO (Particle Swarm Optimization). Quando comparado o desempenho do tráfego com semáforos controlados por Fuzzy e Fuzzy otimizado, tem-se melhorias importantes nas variáveis de trânsito analisadas, como tempo de espera e tamanho da fila de carros. Assim, este trabalho evidencia a importância de se empregar modelos Fuzzy evolucionários na otimização de parâmetros.

Keywords: Traffic Light; Fuzzy; Optimization; Genetic Algorithm; PSO

Palavras-chaves: Semáforo; Fuzzy; Otimização; Algoritmo Genético; PSO

1. INTRODUÇÃO

O uso de controladores Fuzzy no cálculo das fases dos semáforos é uma estratégia de inserção da inteligência computacional no trânsito que vem sendo utilizada há décadas. Um dos primeiros projetos de semáforos com temporização em tempo real, ou dinâmica, foi abordado por Pappis and Mamdani (1977), onde um controlador em uma única interseção de duas ruas foi apresentado. Os resultados obtidos a partir da implementação do controlador semafórico de Lógica Fuzzy são tabulados contra aqueles que correspondem a um controlador convencional, onde os períodos das fases passam por ajustes fixos. Assim, é mostrado que o uso da Lógica Fuzzy nos sinais de trânsito

resulta em melhor desempenho se comparado com a lógica convencional (Pappis and Mamdani, 1977).

Na literatura existem diversos trabalhos que utilizam a Lógica Fuzzy para gerenciar o fluxo de tráfego em cruzamentos de ruas. Geralmente, esses trabalhos usam as variáveis de tráfego para estimar o tempo da fase verde dos semáforos, visando reduzir o tempo médio de espera e o tamanho das filas de veículos, como em Abiyev et al. (2017); Zuraime et al. (2019); Vogel et al. (2018); Kulkarni and Waingankar (2007); Mahmood et al. (2019). Alguns trabalhos diversificam apresentando outras abordagens, como detecção de acidentes, onde um fluxo muito lento de veículos é o principal sinal da presença de acidentes Al-Awadhi et al. (2015), ou com a possibilidade de abrir

o fluxo de veículos em uma determinada direção quando detectada a presença de veículos de emergência, com passagem prioritária Jha and Shukla (2014), como ambulâncias, bombeiros, etc. Outros trabalhos empregam Lógica Fuzzy com outras técnicas computacionais para coletar as variáveis de trânsito, como no uso de processamento de imagem para contar o número de veículos nos cruzamentos Chabchoub et al. (2021), sendo que este dado será uma das variáveis de entrada difusas. Finalmente, o uso da Lógica Fuzzy no gerenciamento de tráfego, mais precisamente nos semáforos, é bastante comum.

Todavia, a maior parte dos trabalhos que empregam Fuzzy no controle de semáforos, o fazem sem aplicar nenhum tipo de otimização nos parâmetros. Assim, nesses trabalhos, predominam aqueles que apresentam ajustes dos parâmetros Fuzzy apenas com a intuição humana, que não detém a mesma capacidade de cálculo de uma técnica computacional. Há trabalhos que comprovam a melhoria na eficiência de controladores Fuzzy quando os parâmetros são otimizados por técnicas computacionais. Como exemplos de aplicações para o tráfego, o trabalho Shahsavari Pour et al. (2013) faz uso de AG para otimizar um controlador Fuzzy que controla volumes de tráfego flutuantes, como condições de carga supersaturadas ou incomuns. Em Zhang et al. (2014), é demonstrado um sistema Fuzzy otimizado por AG para desenvolver um sistema de previsão de congestionamento de tráfego preciso e robusto. Por fim, em Odeh (2015), AG foi usado para adaptar as regras de decisão de um controlador Fuzzy que definem um sistema inteligente de semáforos, obtendo desempenho superior ao de um controle clássico baseado em Fuzzy. Há outros trabalhos que também fazem uso de AG na otimização do controlador Fuzzy (Adriansyah and Amin (2005); Leng et al. (2007); Seng et al. (1999)).

Assim como o AG, o uso de PSO na otimização do controlador Fuzzy também é bastante empregado na literatura. Quanto às aplicações de PSO para otimização do controlador Fuzzy no gerenciamento de trânsito, o trabalho Zouari et al. (2018) otimizou um sistema de gerenciamento de tráfego controlado por Fuzzy, fazendo uso de PSO para alcançar o ponto ótimo em relação a dois critérios: número de veículos que chegam ao destino e tempo médio de viagem. O artigo Gong and Zhang (2012) propõe um controlador Fuzzy para semáforos em rotatórias, e um algoritmo PSO é desenvolvido para otimizar as funções de pertinência adotadas no controlador proposto. Além dos já citados, temos aplicações de PSO e Fuzzy em semáforos nos trabalhos Wijaya et al. (2015); Wu and Wang (2016); García-Nieto et al. (2013).

Esclarecida a vantagem da otimização do controlador Fuzzy, o objetivo principal deste trabalho é avaliar o desempenho de um sistema semaforizado controlado por Fuzzy com parâmetros otimizados por AG e PSO, para reduzir o tempo de espera e a quantidade de veículos em cruzamentos semaforizados, bem como diminuir a emissão de CO₂ e o consumo de combustível, melhorando o fluxo de tráfego. Para isso, são empregados três cenários simulados de cruzamentos semaforizados distintos, sendo o último obtido em um artigo recente (Tunc et al., 2019), que servirá de validação para a estratégia de otimização dos parâmetros Fuzzy apresentada nos dois primeiros cenários.

2. GERAÇÃO AUTOMÁTICA DE SISTEMAS FUZZY

A automatização de sistemas representa um importante avanço da inteligência computacional. Neste contexto, o uso de técnicas de aprendizado de máquinas automatizado (*Auto Machine Learning, AutoML*, em inglês) permite a análise de dados automatizada na construção de modelos analíticos para sistemas (Fernandez et al., 2019). Assim, a ideia central na automatização de sistemas é reduzir a intervenção humana, permitindo aos sistemas aprender com dados, identificar padrões e tomar decisões (Harrington, 2012).

Das definições supracitas, pode-se então, aduzir a abordagem da automatização de sistemas para o desenvolvimento de FIS (*Fuzzy Inference System*). Alguns trabalhos são pioneiros nesse sentido, como o de Karr (1991), onde foi apresentada a otimização de parâmetros Fuzzy, e os de Valenzuela-Rendón (1991) e Thrift (1991), onde são tratados a automatização da base de regras Fuzzy. Em Pham and Karaboga (1991) também foi proposta uma abordagem similar mas usando relações Fuzzy R (um conjunto Fuzzy do produto cartesiano), em vez da relação crisp clássica (tabela de decisão).

Na Figura 1, adaptada de Cordon et al. (2004), tem-se um esquema básico da automatização de um FIS, onde fica evidente o uso de uma meta-heurística (MH) com a incumbência de reduzir a intervenção humana. Costuma-se dividir um FIS em dois componentes que formam a Base de Conhecimento: Base de Regras (*Rule Base, RB*, em inglês), consistindo no conjunto de regras Fuzzy, e Base de Parâmetros (*Parameter Base, PB*, em inglês), que envolve os parâmetros remanescentes do FIS, como funções de pertinência, operadores de agregação e métodos de defuzzificação (Koshiyama et al., 2019).

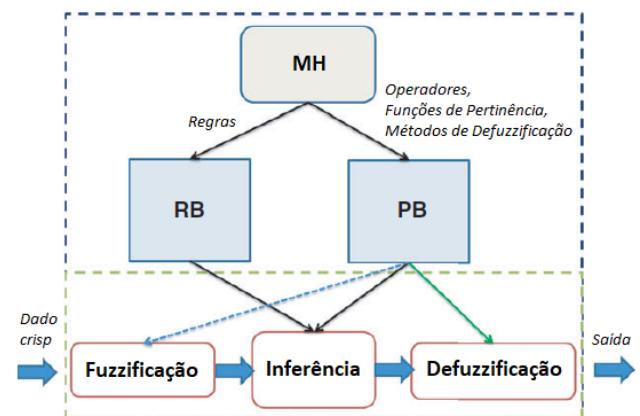


Figura 1. Componentes de um FIS com meta-heurística.

Portanto, como demonstrado na Figura 1, e que representa o núcleo deste trabalho, são empregadas MHs na otimização da Base de Regras e da Base de Parâmetros Fuzzy, os dois componentes que formam a Base de Conhecimento.

Assim, neste trabalho, as funções de pertinência e o conjunto de regras Fuzzy foram ajustados com uso de técnicas computacionais, enquanto os parâmetros restantes foram ajustados apenas com intervenção humana. As MHs empregadas para o ajuste dos dois parâmetros foram AG e

PSO. Essas duas técnicas estão entre as mais empregadas nas tarefas de otimização (Simon, 2013), e por apresentarem boa interpretabilidade, foram escolhidas para a tarefa de realizar o ajuste dos parâmetros citados, na construção do FIS evolucionário para o controle de semáforos.

2.1 Funções de Pertinência

Os ajustes das funções de pertinência podem ser feitos alterando a posição e o formato das funções, a partir da escolha de seus atributos. Há diversas maneiras de efetuar esses ajustes, como demonstrado em Cordón (2011). Neste trabalho, algumas restrições são impostas com o intuito de garantir a interpretabilidade na composição das funções (de Oliveira, 1999), como uma função com termo linguístico “alto” estar ocupando o espaço de uma função com termo “baixo” (Runkler, 2016), por exemplo. Assim, para impedir o surgimento dessas incoerências, cada função só pode ser ajustada dentro de um determinado trecho, uma área de abrangência da função (Pedrycz, 2008). Dessa forma, cria-se uma faixa de ajuste para as funções, que permite aos algoritmos de otimização realizarem a busca das melhores posições de cada função, mantendo a interpretabilidade entre os termos linguísticos. A Figura 2 ilustra o modelo, bem como as restrições na composição das funções de pertinência propostas neste trabalho.




Figura 2. Restrições das funções de pertinência.

2.2 Regras

Há duas abordagens básicas na construção da Base de Regras (Koshiyama et al., 2019), a saber: Classificador Michigan e Classificador Pittsburgh. Na abordagem Michigan cada regra do FIS é considerada um cromossomo, ou indivíduo. Na abordagem Pittsburgh cada indivíduo é considerado um conjunto de regras. Ambas as abordagens são bastante empregadas, assim como suas versões híbridas (Ishibuchi et al., 2013; Lahsasna and Seng, 2017). Apesar de demandar mais custo computacional, a abordagem Pittsburgh é menos complexa, por isso optou-se por aplicar essa abordagem neste trabalho.

No AG, a disposição dos antecedentes e consequentes das regras se dá de forma binária no cromossomo (Smith, 1980; Carse et al., 1996). Cada gene, ou bit, nesse cromossomo representa uma regra criada arbitrariamente. Dependendo do valor do bit associado a essa regra, ela pode estar ativa ou não.

No PSO, as regras são adequadas de forma distinta. Assim como no AG, diversas regras são criadas arbitrariamente, porém, em vez de códigos binários, pesos são armazenados como posição do enxame no PSO. Da mesma forma que

o AG, com essas restrições o PSO é capaz de ajustar a combinação entre antecedentes e consequentes, bem como otimizar o número de regras necessárias.

3. METODOLOGIA

O desenvolvimento deste trabalho é dividido em duas etapas: construção de ambientes simulados, para emulação de cruzamentos semaforicos, e elaboração de um sistema com controle Fuzzy que atue no controle semaforico das redes viarias desses cenários. Como software de simulação de tráfego, foi utilizado o SUMO (*Simulation of Urban Mobility*, em inglês), um dos mais empregados para a referida finalidade. Com auxílio desse software, serão avaliados os desempenhos de três configurações semaforicas: tempo fixo (os períodos das fases não mudam); controle Fuzzy sem otimização; controle Fuzzy com parâmetros otimizados. Para isso, são empregados três cenários de cruzamentos que utilizam semáforos de 2 tempos, onde as três configurações semaforicas propostas serão avaliadas em cada cenário.

Sobre os cenários propostos para a avaliação do desempenho dos semáforos, no primeiro tem-se um cenário fictício, porém bastante comum, onde uma demanda de veículos arbitrária é inserida na rede viária do cenário. No segundo cenário a demanda é coletada a partir de um cruzamento semaforico real, e o terceiro cenário foi obtido em um artigo recente Tunc et al. (2019), que servirá de validação para a estratégia de otimização dos parâmetros Fuzzy apresentada nos dois primeiros cenários. A Figura 3 apresenta os cenários. Por fim, efetuam-se testes comparativos entre as três configurações semaforicas propostas. Análises, tabelas e gráficos são elaborados com o intuito de esclarecer o desempenho de cada configuração.




Figura 3. Aspectos do cenários simulados: a) Cenário I; b) Cenário II; c) Cenário III.

3.1 Características do AG e PSO

É importante esclarecer que o objetivo deste trabalho não é comparar algoritmos, e sim otimizar parâmetros Fuzzy. Portanto, a comparação apresentada neste trabalho sobre o AG e PSO é apenas oportuna, diante do objetivo principal de otimizar o FIS para o controle de semáforos.

Para o emprego dos algoritmos AG e PSO na tarefa de otimizar os parâmetros Fuzzy, é necessário realizar o ajuste dos atributos que direcionam esses dois algoritmos. Há diversos trabalhos (alguns resumidos em Fernández-Martínez (2012); Katoch et al. (2021)) que estudam as diferentes configurações desses atributos. Como dito, o foco não é a comparação de algoritmos, portanto o ajuste sobre os atributos desses algoritmos se dá apenas no tamanho da população de cada algoritmo. Assim, são realizados testes com quantidades distintas de indivíduos que compõem as

populações, com o intuito de encontrar um valor ótimo de configuração dos algoritmos que possibilitará a otimização do FIS. Os outros atributos desses algoritmos foram escolhidos dentre os valores mais usuais. Sendo assim, a probabilidade de reprodução e mutação são 90% e 10%, respectivamente, para o AG. No PSO, o coeficiente de inércia é 0.9, e 2.0 para os coeficientes de cognição e social. O número de gerações para ambos os algoritmos é fixado em 40, enquanto a população é avaliada para as quantidades 20, 40, 60 e 80, com critério de parada sendo o número máximo de gerações. Como esses algoritmos não são determinísticos, 30 simulações foram realizadas para cada população.

É importante notar que a recomendação é restringir a população do PSO a 20-50 partículas (Kennedy and Eberhart, 1995), mas há diversos trabalhos onde fica demonstrado que, apesar da quantidade 20-50 ser bastante usual e responsiva, o tamanho da população depende da tarefa a ser realizada (Piszcz and Soule, 2006; Pelikan et al., 2000; Nadi and Khader, 2011). Portanto, não é surpresa encontrar trabalhos onde a otimização se deu a partir de valores maiores do que 20-50 partículas (Piotrowski et al., 2020; Dhal et al., 2019), e o mesmo pode ser afirmado para o AG (Roeva et al., 2013).

4. RESULTADOS

Para cada cenário um conjunto de resultados distintos é apresentado. Assim, certas variáveis de trânsito das simulações são avaliadas após a otimização das funções de pertinência e do conjunto de regras Fuzzy, por meio dos algoritmos de otimização AG e PSO. Para os Cenários I e II, o produto das variáveis de trânsito “tamanho da fila”(queue length) e “tempo de espera”(waiting time) foi escolhido como função objetivo (fitness) dos algoritmos de otimização.

Nesses cenários, o objetivo dos algoritmos é prover uma composição de funções de pertinência e um conjunto de regras Fuzzy otimizados que melhore (reduza, neste caso) os valores dessas variáveis de trânsito na simulação. Assim, os resultados dos Cenários I e II focam na comparação das variáveis queue length e waiting time para as três configurações semafóricas. Além disso, como o Cenário II é baseado em uma demanda de tráfego real, é oportuno apresentar outras variáveis de trânsito além das já citadas. Assim, com o intuito de apresentar a importância, para além da fluidez do tráfego, de os semáforos estarem bem ajustados aos cruzamentos, a emissão de CO₂ e o consumo de combustível também são apresentados.

Já no Cenário III, os autores do trabalho comparado (Tunc et al., 2019) apresentaram como resultados a velocidade média e a emissão acumulada de CO₂, para diferentes densidades de veículos, e em duas estratégias (Estratégia 1 e 2) que empregam planos de operação semafóricos distintos. Assim, as simulações do Cenário III neste trabalho visam a melhoria desses resultados, no caso o aumento da velocidade média e a redução da emissão acumulada de CO₂. Para isso, os algoritmos de otimização usam a velocidade média como função objetivo, com a tarefa de aumentar a velocidade. Além disso, diferentemente dos Cenários I e II, no Cenário III foi utilizada apenas a otimização do conjunto de regras Fuzzy. Isso se dá porque, como

apresentado nos resultados para os Cenários I e II, otimizar o conjunto de regras Fuzzy mostrou-se mais eficiente do que otimizar a composição das funções de pertinência.

4.1 Cenários I e II

Os resultados nas Tabelas 1 e 2 deixam evidente que um FIS para semáforos com parâmetros bem ajustados consegue prover grandes melhorias no trânsito. O FIS sem otimização dos parâmetros por si só já fornece melhorias significativas nas variáveis de trânsito queue length e waiting time, se comparado com o semáforo de tempo fixo. Essas variáveis tiveram os resultados melhorados quando as técnicas computacionais de otimização foram aplicadas ao FIS que realiza o ajuste das fases dos semáforos. Assim, o semáforo controlado por Fuzzy com parâmetros otimizados, não só reduziu o tempo de espera e o número de carros enfileirados, mas também reduziu o número de regras do FIS. Também é importante notar que, para ambos os cenários, otimizar o conjunto de regras foi mais eficiente do que otimizar as funções de pertinência. Por fim, é notável que não houve diferença significativa nos resultados da otimização dos parâmetros do FIS por AG ou PSO.

Tabela 1. Resultados para as otimizações do Cenário I.

	Tempo		Função de Pertinência		Regras	
	Fixo	Fuzzy	AG Fuzzy	PSO Fuzzy	AG Fuzzy	PSO Fuzzy
queue_length	23.22	17.71	13.46	13.63	11.59	11.59
waiting_time	18.07	10.55	8.12	8.12	4.85	4.85
Regras	-	25	25	25	10	10

Tabela 2. Resultados para as otimizações do Cenário II.

	Tempo		Função de Pertinência		Regras	
	Fixo	Fuzzy	AG Fuzzy	PSO Fuzzy	AG Fuzzy	PSO Fuzzy
queue_length	30.46	26.24	18.21	18.46	14.69	14.69
waiting_time	18.98	15.34	9.56	9.39	4.92	4.92
Regras	-	25	25	25	15	15

Como o Cenário II é baseado em uma demanda de tráfego real, resultados acerca da emissão de CO₂ e consumo de combustível são apresentados na Tabela 3. Assim, um semáforo controlado por FIS com parâmetros otimizados provê redução da emissão de CO₂, além de reduzir o consumo de combustível.

Tabela 3. Resultado para as emissões do Cenário II.

	Tempo		Função de Pertinência		Regras	
	Fixo	Fuzzy	AG Fuzzy	PSO Fuzzy	AG Fuzzy	PSO Fuzzy
CO ₂ (Kg/s)	163.70	152.10	143.50	143.80	139.20	139.20
Combustível (L/s)	70.40	65.40	61.70	61.80	56.30	56.30

4.2 Cenário III

As Figuras 4 e 5 apresentam o resultado final da simulação do Cenário III para as duas variáveis de trânsito propostas por Tunc et al. (2019): velocidade média e emissão acumulada de CO₂. Neste cenário, apenas o conjunto de regras do FIS foi otimizado, pois como apresentado nos cenários anteriores, otimizar o conjunto de regras Fuzzy foi mais eficiente do que otimizar as funções de pertinência. Além

disso, apenas a otimização com AG é apresentada, já que como mostrado nos cenários anteriores, há pouca diferença entre os resultados otimizados obtidos com AG ou PSO.




Figura 4. Resultado da otimização da velocidade média.

Na Figura 4, a velocidade média dos veículos sujeitos aos semáforos controlados por FIS com parâmetros otimizados (Fuzzy/AG, linhas tracejadas), de ambas as estratégias, foi maior do que os resultados apresentados pelos autores no artigo original (linhas contínuas e linhas pontilhadas). Já na emissão acumulada de CO₂ na Figura 5 (Fuzzy/AG, linhas tracejadas), houve uma redução significativa, mais evidente nas maiores densidades de veículos. Quanto às regras iniciais, os autores em Tunc et al. (2019) empregaram 49 para ambas as estratégias. A otimização do conjunto de regras forneceu uma grande redução no número dessas. Para a Estratégia 1, 16 regras foram suficientes, e na Estratégia 2, apenas 10 regras foram suficientes.

5. CONCLUSÕES

Neste trabalho foi proposta a comparação entre diferentes configurações de controle de semáforos. Para isso, foram empregados três cenários de cruzamentos semaforicos distintos. Os resultados deixam claro a superioridade do semáforo controlado por FIS com parâmetros otimizados para todas as variáveis de tráfego analisadas.

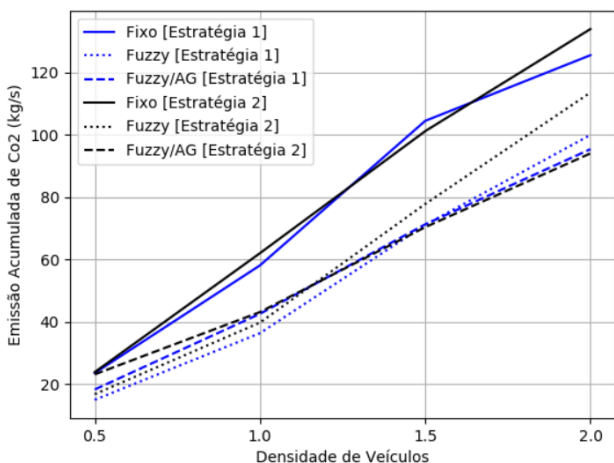


Figura 5. Resultado da otimização da emissão.

Quanto aos parâmetros, notou-se que otimizar o conjunto de regras Fuzzy apresentou resultados melhores do que a otimização das funções de pertinência. Além disso, não houve diferença significativa nos resultados apresentados pelos algoritmos de otimização AG e PSO, confirmando que algoritmos comuns como os empregados são suficientes para alcançar melhorias do FIS. Os resultados obtidos no Cenário III foram importantes porque validaram todas as técnicas de otimização propostas nos dois primeiros cenários, e com melhoria dos resultados apresentados pelos autores originais do artigo que serviu de comparação.

Por fim, apesar deste trabalho empregar otimização dos parâmetros Fuzzy com aplicações em semáforos, é válido afirmar que a otimização dos parâmetros apresentará bons resultados para ambientes de trabalho que apliquem FIS para diferentes aplicações.

REFERÊNCIAS

- Abiyev, R., Ma'aitah, M., and Sonyel, B. (2017). Fuzzy logic traffic lights control (ftlc). 233–238.
- Adriansyah, A. and Amin, S.H.M. (2005). Knowledge base tuning using genetic algorithm for fuzzy behavior-based autonomous mobile robot. 20–125.
- Al-Awadhi, F., Yousef, M., and Alkandari, A. (2015). Dynamic fuzzy logic traffic light integrated system with accident detection system using itraffic simulation. 140–145.
- Carse, B., Fogarty, T.C., and Munro, A. (1996). Evolving fuzzy rule based controllers using genetic algorithms. *Fuzzy Sets and Systems*, 80(3), 273–293.
- Chabchoub, A., Hamouda, A., Al-Ahmadi, S., and Adnen, C. (2021). Intelligent traffic light controller using fuzzy logic and image processing. *International Journal of Advanced Computer Science and Applications*, Volume 12, 2021.
- Cordón, O. (2011). A historical review of evolutionary learning methods for mamdani-type fuzzy rule-based systems: Designing interpretable genetic fuzzy systems. *International Journal of Approximate Reasoning*, 52(6), 894–913.
- Cordon, O., Gomide, F., Herrera, F., Hoffmann, F., and Magdalena, L. (2004). Ten years of genetic fuzzy systems: Current framework and new trends. *Fuzzy Sets and Systems*, 141, 5–31.
- de Oliveira, J. (1999). Semantic constraints for membership function optimization. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 29(1), 128–138.
- Dhal, K.G., Das, A., Sahoo, S., Das, R., and Das, S. (2019). Measuring the curse of population size over swarm intelligence based algorithms. *Evolving Systems*.
- Fernandez, A., Herrera, F., Cordon, O., Jose del Jesus, M., and Marcelloni, F. (2019). Evolutionary fuzzy systems for explainable artificial intelligence: Why, when, what for, and where to? *IEEE Computational Intelligence Magazine*, 14(1), 69–81.
- Fernández-Martínez, J.L. (2012). A brief historical review of particle swarm optimization (psa). *Journal of Bioinformatics and Intelligent Control*, 1, 3–16.
- García-Nieto, J., Olivera, A., and Alba, E. (2013). Optimal cycle program of traffic lights with particle swarm

- optimization. *IEEE Transactions on Evolutionary Computation*, 17, 823–839.
- Gong, Y.J. and Zhang, J. (2012). Real-time traffic signal control for roundabouts by using a pso-based fuzzy controller. 1–8.
- Harrington, P. (2012). *Machine Learning in Action*. Manning Publications, USA.
- Ishibuchi, H., Yamane, M., and Nojima, Y. (2013). Rule weight update in parallel distributed fuzzy genetics-based machine learning with data rotation. In *2013 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 1–8.
- Jha, M. and Shukla, S. (2014). Design of fuzzy logic traffic controller for isolated intersections with emergency vehicle priority system using matlab simulation. *International Journal of Engineering Research and Applications*, 4.
- Karr, C. (1991). Genetic algorithms for fuzzy controllers. *AI Expert*, 6(2), 26–33.
- Katoch, S., Chauhan, S.S., and Kumar, V. (2021). A review on genetic algorithm: past, present, and future. *Multimedia Tools and Applications*, 80(5), 8091–8126.
- Kennedy, J. and Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95 - International Conference on Neural Networks*, volume 4, 1942–1948 vol.4.
- Koshiyama, A.S., Tanscheit, R., and Vellasco, M.M.B.R. (2019). Automatic synthesis of fuzzy systems: An evolutionary overview with a genetic programming perspective. *WIREs Data Mining and Knowledge Discovery*, 9(2), e1251.
- Kulkarni, G. and Waingankar, P. (2007). Fuzzy logic based traffic light controller. 107 – 110.
- Lahsasna, A. and Seng, W. (2017). An improved genetic-fuzzy system for classification and data analysis. *Expert Systems with Applications*, 83.
- Leng, G., McGinnity, T., and Prasad, G. (2007). Design for self-organizing fuzzy neural networks based on genetic algorithms. *Fuzzy Systems, IEEE Transactions on*, 14, 755 – 766.
- Mahmood, T., Durdu, A., and Ali, M.E.M. (2019). A two stage fuzzy logic adaptive traffic signal control for an isolated intersection based on real data using sumo simulator. Volume-3, 656–659.
- Nadi, F. and Khader, A.T. (2011). A parameter-less genetic algorithm with customized crossover and mutation operators. GECCO '11, 901–908. Association for Computing Machinery, New York, NY, USA.
- Odeh, S.M. (2015). Hybrid algorithm: Fuzzy logic-genetic algorithm on traffic light intelligent system. In *2015 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 1–7.
- Pappis, C.P. and Mamdani, M. (1977). A fuzzy logic controller for a traffic junction. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-7(10), 707–717.
- Pedrycz, W. (2008). *Semantics and Perception of Fuzzy Sets and Fuzzy Mappings*, 597–639. Springer Berlin Heidelberg, Berlin, Heidelberg.
- Pelikan, M., Goldberg, D., and Cantu-Paz, E. (2000). Bayesian optimization algorithm, population sizing, and time to convergence. 275–282.
- Pham, D. and Karaboga, D. (1991). Optimum design of fuzzy logic controllers using genetic algorithms. *Journal of Systems Engineering*, 1(2), 114–118.
- Piotrowski, A.P., Napiorkowski, J.J., and Piotrowska, A.E. (2020). Population size in particle swarm optimization. *Swarm and Evolutionary Computation*, 58, 100718.
- Piszcz, A. and Soule, T. (2006). Genetic programming: Optimal population sizes for varying complexity problems. GECCO '06, 953–954. Association for Computing Machinery, New York, NY, USA.
- Roeva, O., Fidanova, S., and Paprzycki, M. (2013). Influence of the population size on the genetic algorithm performance in case of cultivation process modelling. In *2013 Federated Conference on Computer Science and Information Systems*, 371–376.
- Runkler, T.A. (2016). Generation of linguistic membership functions from word vectors. In *2016 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 993–999.
- Seng, T.L., Khalid, M., and Yusof, R. (1999). Tuning of a neuro-fuzzy controller by genetic algorithm. *IEEE transactions on systems, man, and cybernetics. Part B, Cybernetics : a publication of the IEEE Systems, Man, and Cybernetics Society*, 29-2, 226–36.
- Shahsavari Pour, N., Asadi, H., and Pour Kheradmand, M. (2013). Fuzzy multiobjective traffic light signal optimization. *Journal of Applied Mathematics*, 2013, 249726.
- Simon, D. (2013). John Wiley & Sons, Inc., USA.
- Smith, S.F. (1980). *A learning system based on genetic adaptive algorithms*. Ph.D. thesis, Department of Computer Science, University of Pittsburgh, PA.
- Thrift, P. (1991). Fuzzy logic synthesis with genetic algorithms. In *ICGA*.
- Tunc, I., Yesilyurt, A.Y., and Soylemez, M.T. (2019). Intelligent traffic light control system simulation for different strategies with fuzzy logic controller. In *2019 11th International Conference on Electrical and Electronics Engineering (ELECO)*, 830–834.
- Valenzuela-Rendón, M. (1991). The fuzzy classifier system: A classifier system for continuously varying variables.
- Vogel, A., Oremović, I., Simic, R., and Ivanjko, E. (2018). Improving traffic light control by means of fuzzy logic. 51–56.
- Wijaya, I.G.P.S., Uchimura, K., and Koutaki, G. (2015). Traffic light signal parameters optimization using particle swarm optimization. 11–16.
- Wu, B. and Wang, D. (2016). Traffic signal networks control optimize with pso algorithm. *2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, 230–234.
- Zhang, X., Onieva, E., Perallos, A., Osaba, E., and Lee, V. (2014). Hierarchical fuzzy rule-based system optimized with genetic algorithms for short term traffic congestion prediction. *Transportation Research Part C-emerging Technologies*, 43, 127–142.
- Zouari, M., Baklouti, N., Medina, J.S., Ayed, M.B., and Alimi, A. (2018). An evolutionary hierarchical interval type-2 fuzzy knowledge representation system (ehit2fkr) for travel route assignment. *ArXiv*, abs/1812.01893.
- Zuraime, F., Rahman, S., Yaakob, A.M., and Abdul Rahman, N. (2019). Traffic waiting time management using fuzzy logic approach. volume 2138, 030042.