

Ajuste Dinâmico de Tempos Semafóricos usando Previsão de Tráfego e Controle Fuzzy Sequencial

Erick Lucas M. F. Da Silva¹, Manoel Henrique De Oliveira Camargo¹,
Maria José Pereira Dantas¹

¹Pontifícia Universidade Católica de Goiás (PUCGO)
Caixa Postal 86 – CEP 74605-020 – Goiânia – GO – Brasil

{erick.lucas0973, manelhro}@gmail.com, mjdantas@pucgoias.edu.br

Abstract. A hybrid method for adaptive traffic-light control is investigated by combining an LSTM predictor and a Mamdani fuzzy controller. Using 5-min data, smoothed traffic states (60-min trailing moving average) are forecast for speed and road occupancy, and sequential green-time adjustments are computed with bounded per-cycle variation. Hyperparameter Optimization is performed via a Genetic Algorithm to improve the predictive model. On the test set, $R^2 = 0.7908$ is achieved for speed and $R^2 = 0.8559$ for occupancy. In the control stage, the predicted-state strategy approximates the oracle fuzzy control with green-time MAE=3.582 s and RMSE=5.050 s.

Resumo. Investiga-se um método híbrido para controle adaptativo de semáforos combinando um preditor LSTM e um controlador fuzzy Mamdani. Com dados a cada 5 minutos, estados suavizados do tráfego (média móvel retroativa de 60 min) são previstos para velocidade e ocupação, e ajustes sequenciais do tempo de verde são calculados com limitação de variação por ciclo. A otimização de hiperparâmetros é realizada via Algoritmo Genético para melhorar o modelo preditivo. No teste, obtém-se $R^2 = 0,7908$ (velocidade) e $R^2 = 0,8559$ (ocupação). Na etapa de controle, o tempo de verde baseado nas previsões aproxima o oracle (MAE=3,582 s; RMSE=5,050 s).

1. Introdução

As áreas urbanas têm registrado um crescimento significativo dos congestionamentos de tráfego. Por outro lado, a evolução tecnológica tem impulsionado o desenvolvimento dos Sistemas de Transporte Inteligente (ITS), cujo objetivo é aprimorar a gestão do tráfego por meio de abordagens fundamentadas em sistemas inteligentes [Akopov and Beklaryan 2024, Cruz-Piris et al. 2018]. Em geral, esses sistemas articulam elementos como infraestrutura, veículos e usuários, buscando promover melhorias integradas em toda a rede viária.

Entre as abordagens mais recorrentes nesse contexto, destacam-se os Semáforos Inteligentes (STLs), que possibilitam o controle adaptativo dos fluxos de veículos e pedestres [Akopov and Beklaryan 2024]. De modo geral, esses sistemas buscam reduzir os congestionamentos, tratando o ajuste dos tempos semafóricos como um problema de otimização.

O artigo [Yu et al. 2022] trata de previsão de fluxo de tráfego em toda a cidade com o uso de fuzzy + ConvLSTM, mostrando que o problema de prever fluxo de tráfego

“na cidade toda” é difícil porque o tráfego depende de vários fatores ao mesmo tempo (dependências espaciais, temporais, clima, feriados etc.) e, quando há muito dado, a incerteza/ruído não pode ser ignorada.

Neste trabalho, além de propor uma abordagem híbrida baseada em *Long Short-Term Memory* (LSTM) [Hochreiter and Schmidhuber 1997] que é uma rede neural e lógica fuzzy [Marro et al. 2010] para controle adaptativo de semáforos, também investigamos a otimização automática do preditor por meio de *Hyperparameter Optimization* (HPO) [Yokoyama et al. 2022]. Para isso, empregamos um Algoritmo Genético (AG) [Goldberg 1989] para selecionar hiperparâmetros do modelo e do treinamento (p.ex., tamanho de janela, taxa de aprendizado, arquitetura e regularização) a partir do desempenho no conjunto de validação. Este artigo apresenta na sequência, a metodologia aplicada; depois, os resultados obtidos. Por fim, a conclusão e trabalhos futuros.

2. Metodologia

A base de dados usada foi *dataset “Smart Mobility Traffic Dataset”*, disponibilizado publicamente no *Kaggle*¹. Embora a página do repositório descreva variáveis típicas de mobilidade urbana, o *dataset* não apresenta documentação detalhada sobre local, período e procedimento de coleta. Além disso, a análise exploratória revelou características compatíveis com dados sintetizados ou fortemente curados (p.ex., amostragem temporal regular a cada 5 minutos, ausência de valores faltantes e variáveis categóricas com distribuição aproximadamente balanceada). Assim, o *dataset* é tratado neste estudo como um conjunto de dados de caráter experimental, adequado para avaliação metodológica, mas com limitações quanto à generalização para cenários reais.

Os dados são amostrados a cada 5 minutos. Para reduzir ruído e aumentar a previsibilidade do estado de tráfego, os alvos de previsão foram definidos como médias móveis retroativas (*trailing*) de 60 minutos para velocidade e ocupação. Seja y_t uma das variáveis (velocidade ou ocupação) no instante t . O alvo suavizado é definido por: $\bar{y}_t^{(W)} = \frac{1}{W} \sum_{i=0}^{W-1} y_{t-i}$, com $W = 12$ amostras ($12 \times 5 \text{ min} = 60 \text{ min}$). Assim, o modelo aprende a prever o nível médio de tráfego no horizonte de 5 minutos à frente, evitando oscilações de curto prazo que prejudicam a previsão direta do valor instantâneo.

A LSTM recebe uma janela temporal de $L = 72$ amostras (6 horas) e produz duas saídas regressivas: velocidade e ocupação suavizadas ($\bar{v}_t + 1$, $\bar{o}_t + 1$). As variáveis numéricas foram padronizadas (*z-score*) usando apenas o conjunto de treino. A divisão foi temporal (70% treino, 15% validação, 15% teste). O treinamento utilizou erro quadrático médio e otimizador Adam. O desempenho foi medido por MAE (erro absoluto médio), RMSE (raiz do erro quadrático médio) e R^2 (coeficiente de determinação).

A saída prevista pela LSTM (velocidade e ocupação) alimenta um Sistema de Inferência Fuzzy Mamdani [Mamdani and Assilian 1975] cuja base de regras está na Tabela 1. O controlador retorna um tempo de verde desejado $G_{fuzzy}(t)$. Para representar um controle mais realista e evitar mudanças abruptas, aplica-se uma atualização sequencial baseada no valor aplicado no ciclo anterior $G_{prev}(t-1)$: $\Delta G(t) = \text{clip}(G_{fuzzy}(t) - G_{prev}(t-1), -\Delta G_{max}, \Delta G_{max})$, $G_{prev}(t) = \text{clip}(G_{prev}(t-1) + \Delta G(t), G_{min}, G_{max})$, onde G_{min} e G_{max} são limites operacionais e ΔG_{max} limita a variação por ciclo.

¹Disponível em: <https://www.kaggle.com/datasets/ziya07/smart-mobility-traffic-dataset>

Por fim, o valor *crisp* (numérico) da duração do verde G é obtido por defuzzificação usando o método do centróide (centro de gravidade), dado por: $G = \frac{\int g \mu_G(g) dg}{\int \mu_G(g) dg}$. Esse valor G^* é então aplicado como o tempo de verde no controlador semafórico, respeitando os limites operacionais definidos.

Tabela 1. Base de regras fuzzy para definição da duração do sinal verde.

Ocupação	Velocidade média		
	Baixa (sL)	Média (sM)	Alta (sH)
Baixa (oL)	r6: Verde Médio	r7: Verde Pouco	r8: Verde Pouco
Média (oM)	r3: Verde Muito	r4: Verde Médio	r5: Verde Pouco
Alta (oH)	r1: Verde Máximo	r2: Verde Muito	r9: Verde Muito

Para melhorar o desempenho do preditor LSTM, foi empregada otimização de hiperparâmetros via Algoritmo Genético (HPO-AG). Cada indivíduo codifica um conjunto de hiperparâmetros (p.ex., L (lookback), W (suavização), taxa de aprendizado, tamanho das camadas e dropout). A seleção foi realizada por torneio, com cruzamento de 1 ponto, mutação por gene e elitismo.

A função objetivo foi a minimização do erro quadrático médio no conjunto de validação (val_scaled_mse), usando divisão temporal (70% treino, 15% validação, 15% teste). Para viabilizar a busca, cada candidato foi treinado por um número reduzido de épocas com *early stopping*. No total, foram avaliadas 275 configurações (25 indivíduos por população, ao longo de 11 avaliações de população incluindo a inicial).

3. Resultados

Esta seção apresenta os resultados preditivos da LSTM antes e depois da HPO-GA, bem como o impacto no controle fuzzy sequencial. Em todos os cenários, o *baseline* de persistência assume $\hat{y}(t) = y(t-1)$ e serve como referência simples para séries temporais.

A Tabela 2 resume o desempenho da configuração inicial (sem HPO-AG) no conjunto de teste. Observa-se que a LSTM apresenta baixo erro (MAE/RMSE) e R^2 elevado para os alvos suavizados, enquanto a persistência apresenta desempenho significativamente inferior, com erros muito maiores e R^2 negativo, indicando que repetir o último valor bruto observado não é adequado para aproximar os alvos utilizados.

Tabela 2. Desempenho no conjunto de teste sem HPO-AG (alvos suavizados).

Métrica	MAE	RMSE	R^2
<i>Velocidade (Traffic_Speed_kmh_target)</i>			
LSTM (sem HPO)	2,123	2,613	0,7488
Persistência (raw $y(t) = y(t-1)$)	18,102	21,021	-15,2572
<i>Ocupação (Road_Occupancy%_target)</i>			
LSTM (sem HPO)	2,514	3,107	0,8217
Persistência (raw $y(t) = y(t-1)$)	21,340	25,068	-10,6027

Após o HPO-AG, o desempenho no teste melhorou de forma consistente (Tabela 3). Em velocidade, o MAE reduziu de 2,123 para 1,951 (aprox. 8,1%) e o R^2 aumentou de 0,7488 para 0,7908 (+0,0420). Em ocupação, o MAE reduziu de 2,514 para 2,263 (aprox. 10,0%) e o R^2

aumentou de 0,8217 para 0,8559 (+0,0342), sugerindo que a busca evolutiva identificou uma configuração mais adequada para capturar o estado médio do tráfego.

Tabela 3. Desempenho no conjunto de teste com HPO-AG (alvos suavizados).

Métrica	MAE	RMSE	R^2
<i>Velocidade (Traffic_Speed_kmh_target)</i>			
LSTM (com HPO)	1,951	2,384	0,7908
Persistência (raw $y(t) = y(t-1)$)	18,102	21,021	-15,2572
<i>Ocupação (Road_Occupancy%_target)</i>			
LSTM (com HPO)	2,263	2,794	0,8559
Persistência (raw $y(t) = y(t-1)$)	21,340	25,068	-10,6027

Para avaliar o impacto do erro de previsão no controle adaptativo, comparou-se o tempo de verde calculado pelo controlador fuzzy alimentado pelas previsões (controle preditivo) com o tempo de verde calculado a partir dos valores reais (controle *oracle*). No modo sequencial, o controle preditivo apresentou MAE=3,582 s e RMSE=5,050 s para o tempo de verde, com saturação do limitador $\Delta G_{\max}$ abaixo de 0,1% (para cima e para baixo), indicando estabilidade da atualização incremental e boa aproximação do comportamento *oracle*. Em relação aos resultados anteriores, observou-se redução do erro no tempo de verde (MAE de 3,915 s para 3,582 s; RMSE de 5,542 s para 5,050 s), sugerindo que a melhora preditiva obtida com HPO-AG se reflete diretamente na qualidade do ajuste semafórico.

4. Conclusão

Este trabalho propôs uma abordagem híbrida para o controle adaptativo de semáforos, integrando redes LSTM para previsão de tráfego a um controlador fuzzy Mamdani. A otimização via AG potencializou o desempenho preditivo, atingindo R^2 de 0,7908 (velocidade) e 0,8559 (ocupação). No controle, o ajuste do tempo de verde baseado nessas previsões convergiu para o comportamento *oracle* (MAE=3,582 s; RMSE=5,050 s), com baixa saturação e alta estabilidade operacional. O código-fonte, modelos e dados estão disponíveis publicamente no repositório do projeto².

As principais limitações deste estudo residem no caráter experimental do *dataset*, cuja ausência de metadados geográficos e temporais restringe a generalização para cenários reais. Adicionalmente, a avaliação baseou-se em uma comparação indireta com um controle *oracle*, carecendo de uma simulação microscópica de tráfego que mensure métricas operacionais críticas, como atraso médio, formação de filas e frequência de paradas.

Pesquisas futuras devem focar na validação via simulação microscópica (SUMO) para mensurar impactos operacionais e na expansão do controle para cenários multifases coordenados. É desejável também explorar otimização multiobjetivo (atraso, emissões) e a integração de variáveis exógenas. Adicionalmente, o teste de arquiteturas como GRU e *Transformers* e novas estratégias de HPO podem ampliar a capacidade de transferência do modelo para ambientes reais.

²Disponível em: https://github.com/ManelHRO/Semafaro_LSTM_Fuzzy

Referências

- Akopov, A. S. and Beklaryan, L. A. (2024). Traffic improvement in manhattan road networks with the use of parallel hybrid biobjective genetic algorithm. *IEEE Access*, 12:19532–19552.
- Cruz-Piris, L., Rivera, D., Fernández, S., and Marsá-Maestre, I. (2018). Optimized sensor network and multi-agent decision support for smart traffic light management. *Sensors*, 18(2):435.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8):1735–1780.
- Mamdani, E. H. and Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7(1):1–13.
- Marro, A. A., Souza, A. M. C. S., Cavalcante, E. R. S., Bezerra, G. S., and Nunes, R. O. (2010). Lógica fuzzy: conceitos e aplicações. Notas de aula/monografia, Universidade Federal do Rio Grande do Norte (UFRN), Natal, RN.
- Yokoyama, A. M., Ferro, M., and Schulze, B. (2022). A multi-objective hyperparameter optimization for machine learning using genetic algorithms: A green ai centric approach. In Bicharra Garcia, A. C., Ferro, M., and Rodríguez Ribón, J. C., editors, *Advances in Artificial Intelligence – IBERAMIA 2022*, pages 133–144, Cham. Springer International Publishing.
- Yu, H., Zheng, Q., Qian, S., and Zhang, Y. (2022). A fuzzy-based convolutional lstm network approach for citywide traffic flow prediction. In *2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)*, pages 3360–3367.