



<b>Evento</b>	Salão UFRGS 2020: SIC - XXXII SALÃO DE INICIAÇÃO CIENTÍFICA DA UFRGS
<b>Ano</b>	2020
<b>Local</b>	Virtual
<b>Título</b>	PREVISÃO DE VELOCIDADES DE TRÁFEGO COM REDE NEURAL LSTM ENCODER-DECODER
<b>Autor</b>	MATHEUS BASSO DO AMARAL
<b>Orientador</b>	HELENA BEATRIZ BETTELLA CYBIS

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO E TRANSPORTES  
LABORATÓRIO DE SISTEMAS DE TRANSPORTES

PREVISÃO DE VELOCIDADES DE TRÁFEGO COM REDE NEURAL LSTM  
ENCODER-DECODER

MATHEUS BASSO DO AMARAL

ORIENTADORA: PROFESSORA PhD HELENA BEATRIZ BATTELLA CYBIS

## RESUMO

A área de engenharia de tráfego tem recebido contribuições importantes dos recentes avanços tecnológicos de outras áreas, como IoT (internet das coisas) e inteligência artificial. A interseção entre essas áreas tem levado ao surgimento de campos de estudo inovadores como *Smart Cities* e veículos autônomos, além de contribuir para áreas tradicionais, como o gerenciamento ativo de tráfego (ATM), no qual se enquadra este estudo.

O ATM existe desde a primeira metade do século passado e, tradicionalmente, propõe o uso de algoritmos simples e detectores de tráfego e velocidade para gerenciar operações de tráfego em rodovias. Embora muitas agências de tráfego ainda usem estes métodos, o ATM tem recebido muitas contribuições de abordagens *data-driven* e parece estar cada vez mais se fundindo com o conceito de *Smart Cities* (Y. Ma *et al.*, 2020). Uma característica importante possibilitada pela utilização de métodos mais robustos é a capacidade realizar melhores previsões de tráfego e antecipar cenários indesejados, como congestionamentos, acidentes e aumento do tempo de viagem.

Neste trabalho, foi proposto o uso de redes neurais *long short-term memory* (LSTM) para realizar previsões de velocidade nas proximidades de um gargalo de rodovia localizado na região metropolitana de Porto Alegre, Brasil. A metodologia proposta tem, contudo, o objetivo de priorizar previsões feitas próximo da capacidade da via, que é o momento mais crítico para a gestão do tráfego. As previsões realizadas são da velocidade média esperada para 5 intervalos de 5 minutos no futuro feitas a partir de dados de tráfego, precipitação e outras informações possivelmente relevantes como dia da semana e mau funcionamento dos detectores. Essa abordagem foi escolhida porque LSTMs têm a capacidade de reter informações criando dependências de longo prazo, o que geralmente resulta em um desempenho melhor do que o de métodos paramétricos e o de redes neurais normais na previsão de séries temporais.

A arquitetura LSTM foi proposta por Hochreiter (1997) e seu objetivo principal é modelar as longas dependências, o que não é possível com o uso de RNRs comuns. Previsões de tráfego a curto prazo podem ser definidas como um processo de estimar antecipadamente o estado do tráfego para um tempo futuro (Gu *et al.*, 2019). Por esta razão, acurácia e precisão são aspectos muito importantes que devem ser levados em consideração, sendo a LSTM uma grande candidata, pois ela captura a não linearidade da dinâmica de tráfego de uma maneira efetiva através de blocos de memória e, assim, exhibe capacidade superior

para predição de séries temporais com longas dependências temporais (X. Ma *et al.*, 2015).

A previsão de velocidades pode levar a bons resultados em termos de erro médio, uma vez que a velocidade do tráfego é estável na maior parte do tempo por conta dos limites de velocidade. Contudo, um erro médio baixo pode ocultar erros grandes de previsão em momentos críticos, como durante a ocorrência de *breakdowns*, onde as características do tráfego se alteram em um curto espaço de tempo. Este problema raramente é abordado por outros autores, portanto foi proposto segregar os dados em cinco conjuntos com característica de tráfego equivalentes e analisar o erro do modelo para cada um deles individualmente e para cada horizonte de previsão.

Até a conclusão deste trabalho, a avaliação da qualidade de metodologias de previsão de tráfego a partir da comparação de curvas de probabilidade de *breakdowns* feitas com as previsões e com dados de campo não havia sido usada em outras pesquisas. No entanto, entendemos que isto produz uma comparação sólida, uma vez que esses métodos já estão bem estabelecidos entre a comunidade de engenheiros de tráfego e permitem o cálculo da capacidade da via.

Com um MAE (erro médio absoluto) de 5,40km/h, os erros das previsões obtidas nas regiões de maior interesse mostraram resultados satisfatórios para todos os intervalos previstos, porém nota-se que o erro aumenta com o horizonte de previsão. A utilização dos volumes como peso amostral permitiu a redução dos erros das predições em situações onde o tráfego se encontra próximo da capacidade. Por conta disso observou-se convergência entre as curvas de probabilidade calculadas com dados de campo e com dados previstos, indicando que o modelo também é capaz de fazer boas previsões em momentos críticos para o tráfego.

## BIBLIOGRAFIA

- Gu, Y., Lu, W., Qin, L., Li, M., e Shao, Z. (2019) Short-term prediction of lane-level traffic speeds: A fusion deep learning model. *Transportation Research Part C: Emerging Technologies*, 106(July), 1–16.
- Hochreiter, S. (1997) Long Short-Term Memory., *1780*, 1735–1780.
- Ma, X., Tao, Z., Wang, Y., Yu, H., e Wang, Y. (2015) Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research Part C: Emerging Technologies*, 54, 187–197.
- Ma, Y., Zhang, Z., e Ihler, A. (2020) Multi-Lane Short-Term Traffic Forecasting with Convolutional LSTM Network. *IEEE Access*, 8, 34629–34643.