

Comparação de Métodos para Previsão de Tráfego em Tempo-Real

Jorge Lopes¹, João Bento²

¹Brisa Operação e Manutenção

CESUR - Centro de Sistemas Urbanos e Regionais, Instituto Superior Técnico, Portugal

jlopes@brisa.pt

² Instituto Superior Técnico, Portugal

joao@civil.ist.utl.pt

Sumário

Este estudo apresenta uma comparação experimental com três métodos matemáticos para, em tempo-real, efectuar previsões de curto prazo do tráfego em auto-estradas. Esta comparação inclui um método baseado em simulação mesoscópica, que reproduz o fenómeno tráfego, e dois métodos de inferência, baseados em séries de previsão temporais e redes neuronais respectivamente. O cenário de estudo inclui situações de fluxo de tráfego livre e situações de congestionamento recorrente em ciclo diário e semanal. Os resultados obtidos revelam o desempenho dos diferentes métodos, bem como a sua complexidade em termos computacionais e preparação. Por fim analisa-se a importância dos resultados e o seu potencial contributo para otimizar os serviços de gestão e informação de tráfego rodoviário.

Palavras-chave: previsões de tráfego; auto-estrada; simulação de redes; séries de previsão temporais; redes neuronais

1. Introdução

A produção e disseminação efectiva de previsões de tráfego e condições de circulação é uma das principais ambições e motivações quando se aborda o tema do desenvolvimento de sistemas inteligentes de transporte (ITS – *Intelligent Transport Systems*). Esta informação, principalmente a que diz respeito ao congestionamento de tráfego, seria muito importante para os gestores de infra-estruturas, com vista à gestão pró-activa das operações; para os condutores em rota ou em preparação, com vista à optimização dos tempos de viagem e a decidir sobre percursos alternativos; mas também para agentes terceiros, envolvidos ou não na gestão e planeamento de sistemas de transporte. Esta informação seria importante para cenários regulares, recorrentes de padrões de tráfego, como sejam os dias de trabalho, fins de semana ou ciclos mais alargados como as vésperas de Natal e Páscoa ou início e fim do mês de Agosto – tradicionalmente associado a movimentações anormais devido às férias anuais. Mas seria também importante para

situações inesperadas, provocadas por acidentes, obstruções nas vias, condições meteorológicas adversas ou trabalhos na estrada.

Este assunto tem sido objecto de inúmeros estudos e desenvolvimentos nas últimas duas décadas, com contribuições das áreas científicas da matemática, estatística, física e computação, entre outras. Diversos resultados têm sido apresentados como efectivos ou promissores, embora o número de aplicações a sistemas de tempo-real continue a ser escasso e, quando acontece, se aplique fundamentalmente a áreas e sistemas muito limitados.

O principal objectivo de um sistema de previsão de tráfego é a produção e disponibilização contínua de informação antecipada sobre os fluxos de tráfego e tempos de percurso próximo do tempo real, usando informação de monitorização activa do sistema em conjugação com dados históricos do sistema. Apesar da existência de algumas abordagens científicas ao fenómeno até aos anos 90, apenas em 1992, Ben-Akiva *et al.* [1] apresentaram uma solução integrada para a previsão dinâmica de condições de tráfego para a rede de auto-estradas da Holanda com um sistema de previsão baseado em modelos de simulação e estatística. Os dados históricos e observados em tempo-real eram usados como dados de entrada num modelo estatístico para previsões de muito-curto prazo: até 15 minutos, enquanto o modelo de simulação era utilizado para horizontes de previsão mais alargados. Apesar dos resultados satisfatórios apresentados, o sistema foi descontinuado devido aos custos operacionais dos requisitos computacionais e do processo de recolha de informação em tempo-real.

Por outro lado, as redes neuronais artificiais (ANN – *Artificial Neural Network*) têm ganho popularidade na investigação aplicada ao sector dos transportes, e em particular em sistemas de previsão. Em 1996 [2] usaram métodos baseados em ANN para modelar e controlar o fluxo de tráfego em ramos de acesso a auto-estradas a partir de modelos de previsão. Em 2004, Van Lint [3] apresentou um modelo ANN para prever tráfego em tempo-real em estradas urbanas de utilização intensa na Holanda. Apesar desta solução manter o foco da década anterior, quer ao nível dos dados de entrada, quer nos resultados que apresenta, a principal vantagem é a menor complexidade computacional e a flexibilidade estender para novas áreas geográficas.

A aplicação de métodos estatísticos, nomeadamente sobre a forma de séries temporais, remonta aos anos 70 com Ahmed e Cook [4]. Em 1990 Davis *et al.* [5] propôs uma aproximação de previsão baseada na análise linear de séries temporais com algoritmo de reconhecimento de padrões. O método consistia em reconhecer padrões de tráfego em janelas temporais deslizantes para depois constituir uma função de resposta sobre a forma de previsão.

Outros métodos tem sido aplicados a funções de previsão de tráfego como sejam as árvores de classificação e decisão – Graves *et al.* [6], modelos baseados em ondas de choque de tráfego – Lu e skabardonis [7], modelos baseados em filas – Urbanek e Rogers [8] e Wang *et al.* [9].

2. Métodos de Previsão de Tráfego

Em geral os métodos de previsão de tráfego são encaixados em duas categorias principais: os baseados na simulação e modelação de tráfego, e os que são baseados em métodos de inferência ou de análise de dados[10]. Os primeiros – de simulação e modelação procuram reproduzir o fenómeno tráfego para depois extrair a situação futura. Por outro lado, os métodos de inferência ignoram o fenómeno e focam-se na relação causa-efeito.

Para este estudo utiliza-se um método baseado em simulação, um baseado em redes neurais e um terceiro baseado em séries estatísticas temporais.

2.1. Modelo Baseado em Simulação (DynaMIT)

A simulação de cenários de tráfego assenta na modelação do sistema de transporte e do processo tráfego em si, de forma a ajustar, adaptar e reproduzir em cenários ou combinações hipotéticas, como sejam acidentes, alterações anormais de procura, trabalhos nas vias, etc..

Após um processo exaustivo de calibração em que se reproduz o fenómeno com dados conhecidos, o simulador é aplicado em cenários novos, normalmente de tempo-real. DynaMIT – *Dynamic Network Assignment dor Management of Information for Travelers* é o simulador utilizado neste estudo e assenta no modelos desenvolvido por Ben-Akiva *et al.* [11]. A função objectivo do simulador pode ser formulada como uma função que minimiza a discrepância entre os resultados da simulação e as observações que se observam à posteriori :

$$\min_{\beta, \gamma, \chi_p} \|M_{sim} - M_{obs}\|$$

em que β representa os parâmetros das escolhas individuais, γ representa os parâmetros d e calibração do simulador, χ_p são os fluxos Origem-Destino (OD) para um intervalo de tempo p , M_{sim} são os resultados da previsão e M_{obs} são as correspondentes valores observados.

2.2. Modelo Baseado em Redes Neurais Artificiais (ANN)

Este estudo usa um modelo baseado em FF – *feed forward* ANN, seguindo os princípios gerais de funcionamento destes algoritmos.




Figura 1. Arquitectura da Rede Neuronal Artificial

Para definir a arquitectura topológica óptima em termos de desempenho e qualidade, foram testadas algumas variantes, incluindo algoritmos *backpropagation* (PROP), *resilient backpropagation* (RPROP) e *radial basis function* (RBF). A topologia final é aqui representada na forma $L_i - L_h - L_o$ para uma ANN com L_i nós de entrada, L_h nós intermédios ou escondidos e L_o nós de saída. Os pesos iniciais foram gerados de forma aleatória e foram testadas três funções de activação: (i) tangente hiperbólica $\tanh(v)$ no domínio $[-1,1]$; sigmóide

$\frac{1}{(1 + \exp(-v))}$ no domínio $[0,1]$ e uma variante sigmóide $\frac{2}{(1 + \exp(-v))} - 1$ também no domínio $[0,1]$.

2.3. Modelo Baseado em Séries Estatísticas Temporais (TSF)

O processo baseado em séries temporais também foi desenvolvido especificamente para este estudo e assenta em três algoritmos principais, que são executados nas diferentes fases do processo: algoritmo de treino, algoritmo de teste e algoritmo de previsão. O algoritmo de treino e aprendizagem é executado para identificar padrões de tráfego na dimensão p que são modelados numa função matemática quadrática:

$$f(\{v_0, v_1, v_2, \dots, v_{p-1}\}) = ax^2 + bx + c$$

3. Resultados experimentais

Os algoritmos apresentados foram implementados e testados na A5 – Auto-estrada da Costa do Estoril, com um conjunto de dados entre Setembro de 2009 e Fevereiro de 2011. Os primeiros 6 meses (Set.09-Fev.10) foram utilizados para treinar e calibrar os diferentes modelos, enquanto os dados do restante período foram utilizados para testar o desempenho e a qualidade dos resultados. Nesta secção apresentam-se alguns resultados gráficos e numéricos desta análise de qualidade.

A FIGURA 2 sumariza a comparação do desempenho dos métodos na previsão da velocidade.

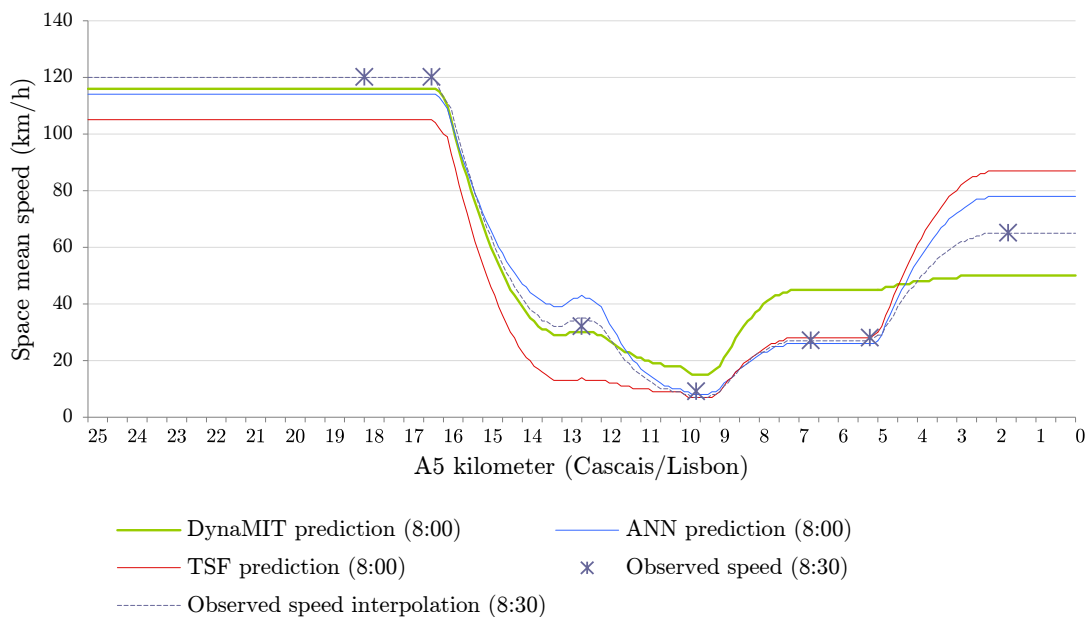


Figura 2. Gráfico comparativo das previsões para 30 minutos

A **Figura 3** apresenta uma análise comparativa do desempenho dos métodos para o intervalo 10 minutos (1-step), 20 minutos (2-step) até 60 minutos (6-step), considerando os valores previstos e os valores observados. Conforme se pode verificar, com o alargamento do horizonte de previsão o método ANN tende a sub-estimar os valores enquanto os restantes métodos mantêm alguma sobre-estimação dos mesmos.

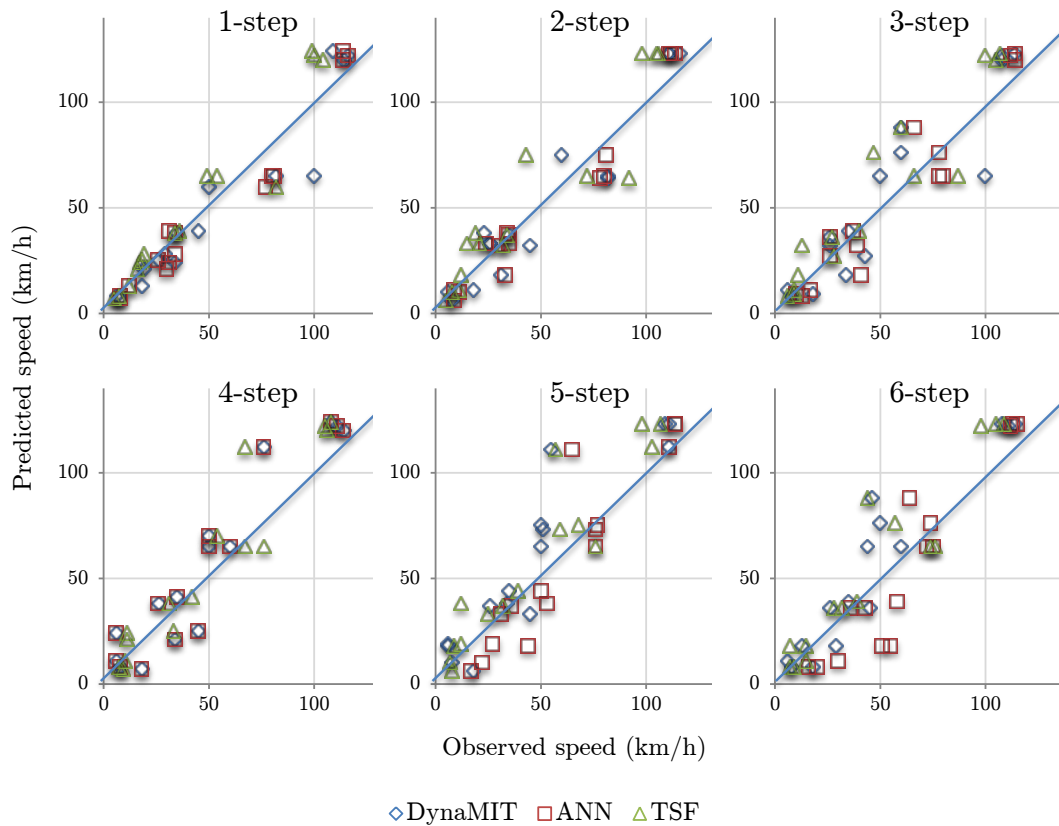


Figura 3. Comparação do desempenho para o intervalo 10-60 minutos

A análise numérica dos resultados é baseada na utilização da medida de desempenho NRMSE - *Normalized Root Mean Square Error*:

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (Y_n^{Pred} - Y_n^{Obs})^2}$$

$$NRMSE = \frac{RMSE}{Y_{max}^{Obs} - Y_{min}^{Obs}}$$

em que N é o número de observações; Y_n^{Obs} é o n ésimo valor observado e Y_n^{Pred} é o correspondente valor previsto. Y_{max}^{Obs} e Y_{min}^{Obs} são os valores máximos e mínimos observados.

A **Tabela 1** apresenta os resultados da análise numérica da qualidade das previsões efectuadas com os diferentes métodos, enquanto a **Tabela 2** sumariza a mesma análise num resultado final absoluto.

Tabela 1. Análise numérica das previsões (NRMSE)

	10 min	20 min	30 min	40 min	50 min	60 min
DynaMIT	0.10	0.11	0.14	0.13	0.17	0.17
ANN	0.08	0.08	0.10	0.10	0.13	0.15
TSF	0.11	0.14	0.13	0.13	0.16	0.21

Tabela 2. Análise sumária da qualidade da previsão

	DynaMIT	ANN	TSF
NRMSE	0.134	0.107	0.147

Os resultados apresentados nas análises anteriores – gráfica e numérica, mostram o bom desempenho dos diferentes métodos na previsão de informação de tráfego. No entanto, verifica-se um ligeiro ascendente do método baseado em redes neuronais (ANN) com um desvio – erro-médio absoluto inferior em 5% aproximadamente.

4. Conclusões

A geração e disponibilização de previsões de tráfego em tempo-real é uma das principais ambições dos investigadores e desenvolvedores de sistemas inteligentes de transporte, para aplicação no mundo real.

Para este estudo foram desenhados, implementados e testados três métodos alternativos com dados reais de tráfego da A5 durante 12 meses. Os resultados apresentados mostram um desempenho satisfatório de todos os métodos em situações de tráfego recorrente, isto é, não

sujeito a situações completamente inesperadas como acidentes, trabalhos nas vias ou condições meteorológicas adversas. Ainda assim, a solução baseada em redes neuronais (ANN) apresentou vantagens ligeiras na qualidade dos resultados a que, se se acrescentarem as vantagens associadas à menor complexidade computacional e capacidade para escalonamento para redes mais alargadas, torna esta solução ainda mais competitiva.

Referências

- [1] M. Ben-Akiva, G. Cantarella, E. Cascetta, J. Ruiter, J. Whittaker, and E. Kroes, “Real-time prediction of traffic congestion,” in *Third International Conference on Vehicle Navigation and Information Systems*, 1992, pp. 557–562.
- [2] F.-S. Ho and P. Ioannou, “Traffic flow modeling and control using artificial neural networks,” *IEEE Control Systems Magazine*, vol. 16, no. 5, pp. 16–26, 1996.
- [3] J. W. C. van Lint, “Reliable Travel Time Prediction for Freeways,” Doctoral thesis, Technical University of Delft, Delft, Holland, 2004.
- [4] M. Ahmed and A. R. Cook, “Analysis of freeway traffic time-series data by using Box-Jenkins Techniques,” *Transportation Research Record*, no. 722, pp. 1–9, 1979.
- [5] G. A. Davis, N. L. Nihan, M. M. Hamed, and L. N. Jacobson, “Adaptive forecasting of freeway traffic congestion,” *Transportation Research Record*, no. 1287, pp. 29–33, 1990.
- [6] T. Graves, A. Karr, N. Roupail, and P. Takuriah, “Real-Time Prediction of Incipient Congestion on Freeways from Detector Data,” National Institute of Statistical Sciences, Research Triangle Park, NC, 1998.
- [7] X.-Y. Lu and A. Skabardonis, “Freeway Traffic Shockwave Analysis: Exploring the NGSIM Trajectory Data,” in *86th Annual Meeting Transportation Research Board*, Washington, D.C., 2006.
- [8] G. L. Urbanek and R. W. Rogers, “Alternative Surveillance Concepts and Methods for Freeway Incident Management,” US Federal Highway Administration, Springfield, VA, 1977.
- [9] Y. Wang, M. Papageorgiou, and A. Messmer, “Real-time freeway traffic state estimation based on extended Kalman filter: Adaptive capabilities and real data testing,” *Transportation Research Part A: Policy and Practice*, vol. 42, no. 10, pp. 1340–1358, 2008.
- [10] J. Lopes, “Traffic Prediction for Unplanned Events on Motorways,” Doctoral thesis, Technical University of Lisbon, Lisbon, Portugal, 2012.
- [11] M. Ben-Akiva, M. Bierlaire, J. Bottom, H. Koutsopoulos, and R. Mishalani, “Development Of A Route Guidance Generation System For Real-Time Application,” *Proceedings of the IFAC Transportation Systems 97 Conference, Chania, Greece*, pp. 405–410, 1997.