

# Aplicação de uma rede neuro *Fuzzy* para a previsão do comportamento do tráfego veicular urbano na região metropolitana da cidade de São Paulo

*Application of a neuro-fuzzy network for the prediction of vehicular traffic behavior in the São Paulo metropolitan region*

Ricardo Pinto Ferreira

Programa de Mestrado em Engenharia de Produção,  
Universidade Nove de Julho – UNINOVE.  
São Paulo, SP [Brasil]  
kasparov@uninove.edu.br

Renato José Sassi

Programa de Mestrado em Engenharia de Produção,  
Universidade Nove de Julho – UNINOVE.  
São Paulo, SP [Brasil]  
sassi@uninove.br

Carlos de Oliveira Affonso

Programa de Mestrado em Engenharia de Produção,  
Universidade Nove de Julho – UNINOVE.  
São Paulo, SP [Brasil]  
carlos.affonso@uninove.edu.br

## Resumo

O aumento do consumo das famílias brasileiras, fruto da estabilidade econômica experimentada no país nos últimos anos, resultou na ampliação do volume de itens, que devem ser coletados ou distribuídos diariamente na cidade de São Paulo. Esse cenário provocou profundas mudanças no mercado de distribuição e coleta de encomendas, tornando a distribuição altamente complexa e afetando diretamente a eficiência desse serviço. Diversas técnicas e *softwares* são utilizados para prever o comportamento do tráfego veicular urbano na região metropolitana da cidade de São Paulo, inclusive, técnicas baseadas na Inteligência Artificial. Assim, neste trabalho foram aplicadas, para prever o comportamento do tráfego, duas técnicas da Inteligência Artificial: a Lógica *Fuzzy* e as redes neurais artificiais, que combinadas formam uma rede Neuro *Fuzzy*. Os resultados mostram que a aplicação da rede Neuro *Fuzzy* na previsão do comportamento do tráfego veicular urbano na cidade de São Paulo é positiva.

**Palavras-chave:** Previsão do comportamento do tráfego. Rede Neuro *Fuzzy*. Roteirização de veículos.

## Abstract

The increase in consumption by Brazilian families, a consequence of the economic stability experienced in the country in recent years, has resulted in an increase in the volume of items that need to be picked up and delivered daily in the city of São Paulo. This situation has led to profound changes in the market for the pickup and delivery of orders, making the distribution highly complex and directly affecting the efficiency of this service. Diverse techniques and software, some based on artificial intelligence, are used to predict the behavior of vehicular urban traffic in the São Paulo metropolitan region. In this paper, artificial neural networks were combined with fuzzy logic to form a neuro-fuzzy network in order to predict the behavior of traffic. The results indicate that the application of the neuro-fuzzy network for predicting the behavior of urban vehicular traffic in the city of São Paulo yields positive results.

**Key words:** Neuro-fuzzy network. Prediction of traffic behavior. Vehicle Routing.

## 1 Introdução

Os novos hábitos de consumo dos brasileiros trouxeram ao mercado produtos com ciclo de vida mais curto e, conseqüentemente, volumes crescentes de itens coletados ou distribuídos todos os dias, afetando diretamente a roteirização e a programação de veículos (TODAY LOGISTICS & SUPPLY CHAIN, 2009).

Quando a definição dos roteiros envolve aspectos espaciais ou geográficos e também temporais, como restrições de horários de atendimento aos pontos a serem visitados, consideram-se esses aspectos problemas típicos de roteirização e programação de veículos (CUNHA, 1997).

A possível solução para o problema de roteirização e programação de veículos é a roteirização dinâmica de veículos, que consiste em alterar as rotas iniciais conforme a fluidez de tráfego, oferecendo em tempo real rotas alternativas que minimizem o período improdutivo de espera em congestionamentos (FERREIRA, 2011).

O trânsito caótico, presenciado na região metropolitana da cidade de São Paulo (RMSP) é formado por diversas ocorrências notáveis (ON), que são destacadas pela central de operações da Companhia de Engenharia de Tráfego (CET), pois interferem, ou podem vir a alterar, as condições de fluidez e de segurança do tráfego na cidade (COMPANHIA DE ENGENHARIA DE TRÁFEGO, 2011), tais como caminhão quebrado, manifestações em vias, falta de energia elétrica, queda de árvore, acidentes com e sem vítimas.

Essas ocorrências são registradas durante o dia e formam os congestionamentos que impedem a eficiência do transporte urbano, além de causar prejuízos consideráveis. Existem três níveis de roteirização que devem ser analisados, a saber: Nível Operacional, Tático e Estratégico.

Neste artigo, trata-se da previsão do comportamento do tráfego veicular urbano na RMSP no

Nível Estratégico da hierarquia de roteirização. Assim, a principal contribuição está na composição do Nível Estratégico de roteirização com um sistema dinâmico de roteirização veicular urbano.

Diversas técnicas e *softwares* são utilizados para prever o comportamento do tráfego veicular urbano na cidade de São Paulo, inclusive, técnicas baseadas em Inteligência Artificial. Assim, neste trabalho foram aplicadas para a previsão do comportamento desse tráfego duas técnicas da Inteligência Artificial combinadas: a Lógica *Fuzzy* ou Lógica Difusa e as redes neurais artificiais, que unidas formam uma rede chamada de Neuro *Fuzzy*.

Segundo Santos, Felix e Vieira (2009), técnicas da Inteligência Artificial (IA) como a Lógica *Fuzzy* e as redes neurais artificiais (RNA) surgem como alternativas de apoio ou até substituição dos métodos tradicionais de processamento e tomada de decisão para roteirização e programação de veículos. Combinar uma rede neural artificial com a Lógica *Fuzzy* pode ser uma alternativa interessante para a resolução de problemas (AFFONSO, 2010; PACHECO; VELLASCO, 2007, FERREIRA, 2011; WU et al., 2011; SHABALOV; SEMENKIN; GALUSHIN, 2011).

A Lógica *Fuzzy* é uma teoria matemática, expressa por um conjunto de variáveis linguísticas, que tem como principal objetivo modelar o raciocínio humano, imitando a habilidade humana de tomar decisões em ambientes de incerteza e de imprecisão (GOLDSCHMIDT; PASSOS, 2005).

As RNAs são modelos constituídos por unidades de processamento simples, chamadas de neurônios artificiais, que calculam funções matemáticas. Esses modelos são inspirados na estrutura do cérebro e têm como objetivo simular o comportamento humano, tais como aprendizagem, associação, generalização e abstração, quando submetidas a treinamento.








Figura 2: Bolsão de distribuição (C e D)




Figura 3: Bolsão de distribuição (E)

sistema operacional, pode ser decomposto em três partes, como segue:

- Nível Operacional – nele estão os métodos de roteirização de veículos;
- Nível Tático – em que se encontra a Roteirização Dinâmica de Veículos, que oferece em tempo real, alternativas que reduzem o tempo improdutivo em trechos interrompidos ou com lentidão acentuada devido a alguma ocorrência notável;
- Nível Estratégico – no qual está a previsão do comportamento do tráfego veicular urbano no início do roteiro.

Com os três níveis hierárquicos de roteirização, é possível considerar não apenas os fatores básicos e os métodos de roteirização, como também os fatores externos, ocorrências relevantes (ocorrências notáveis de trânsito), que influenciam diretamente no nível de fluidez do tráfego nas grandes cidades. A Figura 4 ilustra a hierarquia proposta para a roteirização apoiada pelos três níveis.




Figura 4: Hierarquia de roteirização

A previsão do comportamento do tráfego ou percentual de lentidão representa o nível estratégico da roteirização. A roteirização dinâmica de veículos representa o tático, e os métodos de roteirização representam o nível operacional.

### 3 Metodologia

A metodologia adotada na estruturação deste artigo foi definida como bibliográfica e experi-

mental e a realização da pesquisa foi embasada em consultas a fontes bibliográficas e de referencial teórico, tais como artigos, livros, teses, dissertações, *websites* com conteúdos sobre Roteirização e Programação de Veículos (RPV), RNAs, Lógica *Fuzzy* e RNFs.

Utilizou-se uma RNF obtida por meio da combinação da Lógica *Fuzzy* com uma RNA do tipo MLP (*Multilayer Perceptron*), sendo a camada das variáveis de entrada da RNF MLP composta pelas ocorrências notáveis de trânsito (Tabela 1) obtidas no *website* <<http://www.cetsp.com.br>> da Companhia de Engenharia de Tráfego (CET) com as informações sobre as ocorrências notáveis de trânsito na RMSP.

A coleta dos dados não seguiu nenhum planejamento de experimento pré-definido, os dados foram coletados de segunda a sexta-feira nos dias 14, 15, 16, 17 e 18 de dezembro de 2009. A base de dados completa da CET é composta por 340 ocorrências notáveis de trânsito.

A Figura 5 mostra a metodologia experimental do trabalho, utilizada para a previsão do comportamento do tráfego veicular urbano na RMSP pela RNF MLP, tendo como saída da RNF a entrada para o nível estratégico da roteirização representado pelo topo da pirâmide (previsão do comportamento do tráfego).




Figura 5: Metodologia experimental

## 4 Combinação de técnicas da Inteligência Artificial

Segundo Goldschmidt e Passos (2005), algumas técnicas podem ser combinadas para gerar os chamados sistemas híbridos ou arquiteturas híbridas. A grande vantagem desse tipo de sistema deve-se ao sinergismo obtido pela combinação de duas ou mais técnicas. Esse sinergismo reflete na obtenção de um sistema mais poderoso (em termos de interpretação, de aprendizado, de estimativa de parâmetros, de treinamento, dentre outros) e com menos deficiências.

Nesta seção, são apresentados os principais conceitos da Lógica *Fuzzy*, das redes neurais artificiais e também as características da rede Neuro *Fuzzy* MLP.

### 4.1 Redes neurais artificiais

As redes neurais artificiais (RNA) são modelos constituídos por unidades de processamento simples, chamadas de neurônios artificiais, que calculam funções matemáticas. Esses modelos são inspirados na estrutura do cérebro e têm como objetivo simular o comportamento humano, tais como aprendizagem, associação, generalização e abstração quando submetidas a treinamento.

As RNAs são particularmente eficientes para o mapeamento entrada/saída de sistemas não lineares e para realizar processamento paralelo, além de simular sistemas complexos (HAYKIN, 2001).

Ainda segundo Haykin (2001), as RNAs generalizam os resultados obtidos para dados previamente desconhecidos, ou seja, produzem respostas coerentes e apropriadas para padrões ou exemplos que não foram utilizados no seu treinamento.

Segundo Kovács (2006), as RNAs são consideradas um aproximador universal de funções contínuas.

Para Russel e Norvig (1995), aprender a aproximar funções é considerada uma tarefa de inferência indutiva, a RNA aprende a representar funções.

As características descritas acima das RNAs confirmam a sua aplicação em diversas áreas: previsão de risco de crédito (SELAU; RIBEIRO, 2009), medicina (BLAZADONAKIS; MICHALIS, 2008), distribuição física (SANTOS; FELIX; VIEIRA, 2009) e gestão de estoques (ARAÚJO; LIBRANTZ; ALVES, 2009). Outras aplicações também podem ser encontradas em campos diversos, por exemplo: modelagem, análise de séries temporais, reconhecimento de padrões e processamento de sinais e controle (HAYKIN, 2001).

Escolheu-se utilizar neste artigo uma RNA do tipo MLP (*Multilayer Perceptron*), treinada por meio do algoritmo de *error back-propagation*, porque ela utiliza uma função sigmoide (em forma de S) como função de ativação, que é extremamente simples, o que facilita a sua aplicação em problemas que envolvem classificação, como neste estudo.

O algoritmo de *error back-propagation* funciona por meio da correção dos pesos das saídas dos neurônios que são ajustadas camada por camada até que o erro da rede atinja um erro aceitável (HAYKIN, 2001).

Uma RNA do tipo MLP tipicamente consiste em uma especificação do número de camadas, tipo de função de ativação de cada unidade e pesos de conexões entre as diferentes unidades que devem ser definidas para a construção desse tipo de RNA (HAYKIN, 2001).

## 4.2 Lógica Fuzzy

Na teoria clássica dos conjuntos, a pertinência de um elemento a um conjunto fica bem definida. Entretanto, para uma grande variedade de fenômenos físicos fica difícil estabelecer claramente se um elemento pertence ou não a determinado conjunto.

Dessa forma, Zadeh (1965) propôs uma caracterização mais ampla, de modo que a função pertinência possa assumir valores contínuos entre 0 e 1.

Utiliza-se o conceito de Lógica *Fuzzy* como sendo o ferramental matemático necessário para o tratamento das operações lógicas e algébricas realizadas no universo dos conjuntos *Fuzzy* (PASSINO; YURKOVICH, 1998).

Os conceitos de intersecção, união, complementaridade, convexidade, etc., são extensivos para tais conjuntos e várias propriedades dessas noções no contexto dos conjuntos *Fuzzy* estão estabelecidas no trabalho de Zadeh (1965).

Um elemento importante na Lógica *Fuzzy* é a Função de Pertinência. Deve-se considerar que a escolha da Função de Pertinência depende do contexto. Por exemplo, o conceito de temperatura alta é claramente diferente para a temperatura de um forno de indução e para a de um corpo humano febril. Ainda que seja considerado um mesmo conceito, a escolha depende do contexto em que o observador está inserido. A Função de Pertinência estabelece o grau de certeza que determinada variável de entrada representa para uma variável linguística. Um exemplo de Função de Pertinência pode ser observado na Figura 6.

A questão central para a consistência em modelar-se um sistema pela Lógica *Fuzzy* é a determinação de uma base de regras que represente de forma satisfatória a sua dinâmica, ou seja, como as variáveis de entrada relacionam-se entre si, quais são as suas saídas e, a partir disso, os seus correspondentes erros associados são determinados. Portanto, a exatidão do modelo é diretamente proporcional à aderência entre a dinâmica real do sistema e a base de regras proposta para representá-la.

Suponha que um especialista humano descreva, por meio de uma linguagem verbal, de que forma uma ocorrência notável (Tabela 1) influencia no percentual de lentidão, como demonstrado a seguir: Ocorrência Notável (ON) baixo, médio e alto.

Deve-se utilizar essa descrição linguística e transformá-la num conjunto de regras que possam ser processadas em um programa de computa-

dor, isso é chamado de regras de inferência *Fuzzy* (PASSINO; YURKOVICH, 1998).

A aplicação da Lógica *Fuzzy* para previsão ou monitoramento, em um determinado sistema, é caracterizada pela utilização de um mecanismo de inferência baseado em regras pré-estabelecidas. Essa característica gera a necessidade de que os eventos apresentados na entrada devam necessariamente classificar-se em uma das regras pré-estabelecidas.

McNeill e Thro (1994) relacionaram algumas características de sistemas em que a aplicação da Lógica *Fuzzy* é necessária ou benéfica. Esses sistemas complexos são difíceis de modelar, como exemplo: sistemas controlados por especialistas humanos, sistemas com entradas e saídas complexas e contínuas, sistemas que se utilizam da observação humana como entradas ou como base para regras, sistemas que são naturalmente imprecisos, como sistemas cuja descrição é extremamente complexa.

Nesse contexto, a previsão do comportamento do tráfego urbano na RMSP foi inserida por apresentar extrema complexidade.

### 4.3 Rede NeuroFuzzy

As redes Neuro *Fuzzy* (RNF) têm surgido como uma ferramenta promissora, pois reúnem os benefícios das RNAs, em que a aprendizagem e o poder computacional das RNAs são combinados à capacidade de representação, ao raciocínio da Lógica *Fuzzy* (GOMIDE; FIGUEIREDO; PEDRYCZ, 1998).

A combinação dos atributos positivos das duas técnicas gera sistemas com a capacidade de aprender e de adaptar-se às necessidades para a resolução de problemas do mundo real, mostrando-se ideais para aplicações, tais como identificação, predição, classificação e controle (REZENDE, 2005; RUTKOWSKI, 2008).

Segundo Nauck, Klawonn e Kruse (1996), o termo RNF é usado para abordagens que apresentam as seguintes propriedades:

- São baseadas em Lógica *Fuzzy* e treinadas por um algoritmo de aprendizado derivado de uma das RNAs. O procedimento de aprendizado (heurística) opera em informações locais, e causa apenas modificações locais no fundamento da RNF.
- Possuem três camadas em que a primeira camada representa as variáveis de entrada, a do meio (escondida) representa as regras de inferência, e a terceira, as variáveis de saída;
- Podem ser sempre interpretadas como um mecanismo de inferência; nem todos os modelos especificam procedimentos de aprendizagem para criação de regras *Fuzzy*.
- O procedimento de aprendizagem de uma RNF transforma as propriedades semânticas de um sistema *Fuzzy* em um conjunto de descrições. Isso resulta em restrições que podem tornar-se modificações aplicáveis aos parâmetros do sistema; entretanto, nem todas as abordagens em uma RNF possuem essa propriedade.
- Aproximam uma função n-dimensional que é parcialmente definida pelo treinamento dos dados.

Os principais modelos de inferência encontrados na literatura aplicados as RNFs são os do tipo Mamdani (MAMDANI; ASSILIAN, 1975) e os do tipo Takagi-Sugeno (RUTKOWSKI, 2008). A inferência do tipo Mamdani consiste em conectar os antecedentes e o conseqüente das regras usando normas-T (geralmente do tipo mínimo ou produto). Para este estudo, foi utilizado o sistema do tipo Mamdani, uma vez que com tal modelo não há necessidade de realizar a defuzzyficação da saída.

Neste artigo, uma RNA do tipo MLP foi combinada à Lógica *Fuzzy*, formando uma rede Neuro *Fuzzy* MLP (RNF MLP).

## 5 Experimentos com a Rede Neuro *Fuzzy*

A Tabela 1 apresenta os códigos e os tipos de ocorrências notáveis registradas que foram utilizadas como variáveis de entradas da rede Neuro *Fuzzy* (Xn).

**Tabela 1: Ocorrências notáveis**

Código	Ocorrências Notáveis	Xn
206	Ônibus imobilizado na via	x1
207	Caminhão quebrado	x2
208	Veículo com excesso	x3
302	Acidente com vítima	x4
304	Atropelamento	x5
310	Incêndio em veículos	x6
311	Ocorrência envolvendo carga	x7
312	Ocorrência envolvendo carga perigosa	x8
315	Falta de energia elétrica	x9
316	Incêndio	x10
317	Alagamento	x11
321	Manifestações	x12
334	Defeito na rede de trólebus	x13
331	Queda de árvore	x14
561	Semáforo apagado	x15
562	Semáforo embandeirado	x16

Fonte: Adaptado da Companhia de Engenharia de Tráfego (2009).

Para modelar as funções de pertinência correspondentes às ocorrências notáveis, foram utilizadas funções Gaussianas, conforme mostrado na Equação 1:


$$\mu^\alpha(x) = e^{-\frac{1}{\sigma}(x-c_\alpha)^2} \tag{1}$$

em que:

- $c_\alpha$ : centro da função Gaussiana;
- $\sigma_\alpha$ : dispersões da função;
- $\alpha$ : rótulo linguístico (alto, médio, baixo).

A Figura 6 mostra uma das dezesseis funções de pertinência (uma para cada ocorrência notável) calculadas pela Equação (1).

O algoritmo de treinamento usado na MLP (*Multilayer perceptrons*) foi o *error backpropagation* que funciona da seguinte maneira: apresenta-se um padrão à camada de entrada da rede, esse padrão é processado, camada por camada, até que a saída forneça a resposta processada,  $f_{MLP}$ , calculada como mostrado a seguir, na Equação 2. Em que  $v_1$  e  $w_{ij}$  são pesos sinápticos;  $b_{10}$  e  $b_0$  são os *biases*; e  $\varphi$  a função de ativação.



**Figura 6: Função de Pertinência (Ônibus imobilizado na via - x1)**



$$f_{MLP}(x) = \varphi \left( \sum_1^{Non} v_i \cdot \varphi \left( \sum w_{ij} x_i + b_{i_0} \right) + b_0 \right) \quad (2)$$

As redes MLP são caracterizadas por possuírem mais de uma camada oculta, para esse trabalho a rede MLP com três camadas ocultas apresentou melhor desempenho.

Os parâmetros utilizados para construção da MLP, que faz parte da RNF MLP são os seguintes: número de neurônios de entrada igual a 16, número de camadas igual a 3, número de neurônios nas camadas ocultas igual a 10 e número máximo de iterações igual a 150.

Foram realizados dois experimentos. O primeiro experimento utilizou a RNF MLP para prever o comportamento do tráfego, durante o dia 15 de dezembro de 2009, em comparação com os dados informados pela CET, considerando como variável de saída o percentual de lentidão. A Figura 7 mostra a resposta da RNF MLP (curva Yrede) na previsão do comportamento do tráfego durante o dia 15 de dezembro de 2009.

A (curva Yreal) apresenta o comportamento do tráfego registrado a cada 30 minutos, no horário das 7h às 20h, bem como as curvas que indi-

cam a média inferior e superior, obtidas por meio de cálculos estatísticos.

Esses cálculos são feitos levando-se em conta os dados históricos do comportamento do tráfego no mesmo dia da semana dos doze meses imediatamente anteriores a data atual (COMPANHIA DE ENGENHARIA DE TRÁFEGO, 2011).

Observa-se que o resultado obtido no experimento 1 representa de forma adequada o percentual de lentidão no dia 15 de dezembro de 2009, o que permite iniciar uma programação de roteiros selecionando as melhores e piores janelas de atendimento.

O segundo experimento utilizou a RNF MLP para prever o comportamento do tráfego durante a semana de 14 a 18 de dezembro de 2009, em comparação com os dados informados pela CET, considerando como variável de saída o percentual de lentidão.

A Figura 8 mostra a resposta da RNF MLP (curva Yrede) na previsão do comportamento do tráfego durante semana de 14 a 18 de dezembro de 2009.

Verifica-se que o resultado obtido no experimento 2 representa de forma adequada o percentual de lentidão durante a semana de segunda a sexta-feira.





Figura 7: Resposta da RNF MLP na previsão do comportamento do tráfego durante o dia 15 de dezembro de 2009



**Figura 8: Resposta da RNF MLP na previsão do comportamento do tráfego durante os dias 14 a 18 de dezembro de 2009**

A análise do percentual de lentidão permite a roteirização em três níveis: estratégico, tático e operacional. Dessa forma, tem-se a previsão do comportamento do tráfego (percentual de lentidão), no nível estratégico da roteirização; a roteirização dinâmica, no nível tático; e os métodos de roteirização, no operacional.

Como se observa nas Figuras 7 e 8, houve uma boa aderência entre os resultados da RNF MLP e os dados experimentais.

Essa aderência possibilitou que a RNF MLP fizesse uma boa previsão do comportamento do tráfego veicular urbano na região metropolitana da cidade de São Paulo; portanto, ela pode apoiar a tomada de decisão quanto às janelas de atendimento que devem ser evitadas, e as que apresentem comportamento que comprometa a distribuição física. A previsão do comportamento do tráfego (percentual de lentidão) calculado pela rede Neuro Fuzzy representa o nível estratégico da roteirização.

## 6 Conclusão

Neste artigo, o problema de roteirização de veículos urbanos foi abordado por nível de hierar-

quia, tendo como dados principais as ocorrências notáveis de trânsito que servem para o nível estratégico e tático da roteirização, conforme propõe o estudo.

Os desvios inteligentes no nível tático visam à redução do tempo em trânsito, mesmo quando a distância percorrida for um pouco maior, existindo ainda a economia de tempo e combustível, conclui-se que as novas técnicas são decisivas para a criação de alternativas inovadoras de roteirização.

A combinação da Lógica Fuzzy e das RNAs, conforme proposto neste artigo, mostrou-se bastante interessante para resolução desse tipo de problema, pois a Lógica Fuzzy fornece ferramentas matemáticas capazes de capturar ambiguidades associadas ao processo cognitivo humano, e, por outro lado, as RNAs mostraram-se adequadas para identificação de padrões.

A previsão do comportamento do tráfego permite escolher as melhores janelas de atendimento de maneira a evitar horários em que a previsão do tráfego aponte para níveis de lentidão que comprometam o atendimento.

Concluiu-se que a aplicação da rede Neuro Fuzzy MLP no nível estratégico apresentou um bom resultado, que motiva novos estudos. A ro-

teirização proposta no nível estratégico e tático pode ser uma excelente alternativa para auxiliar a distribuição física, favorecendo a efetividade e produtividade na distribuição e coleta em regiões urbanas como São Paulo.

Sugere-se a aplicação da RNF MLP desenvolvida neste trabalho em áreas de extrema importância para a vida humana, tais como a área de Logística da Captação de Múltiplos Órgãos para transplantes, a de Logística de Distribuição dos Órgãos para transplantes e a de Logística de Material e Medicamento Cirúrgico de Urgência ou Emergência. Pretende-se também usar outra RNA do tipo *Radial Basis Function* (RBF) na associação com a Lógica Fuzzy, contrastando resultados com a RNF MLP aqui apresentada.

## Agradecimentos

Os autores agradecem à Universidade Nove de Julho (UNINOVE) pelo apoio financeiro.

## Referências

- AFFONSO, C. *Aplicação de Redes Neuro Fuzzy ao Processamento de Polímeros na Indústria Automotiva*. 2010. 111 p. Dissertação (Mestrado)– Universidade Nove de Julho, Engenharia de Produção, São Paulo, 2010.
- ARAÚJO, S. A.; LIBRANTZ, A. F. H.; ALVES, W. A. L. Algoritmos genéticos na estimação de parâmetros em gestão de estoque. *Exacta*, São Paulo, v. 7, n. 1, p. 21-29, 2009.
- BLAZADONAKIS, E.; MICHALIS, Z. *Support vector machines and neural networks as marker selectors in cancer gene analysis. Intelligent techniques and tools for novel system architectures*. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg, p. 237-258, 2008.
- COMPANHIA DE ENGENHARIA DE TRÁFEGO (CET). Disponível em: <<http://www.cetsp.com.br>>. Acesso em: 21 abr. 2011.
- COMPANHIA DE ENGENHARIA DE TRÁFEGO (CET). Disponível em: <<http://www.cetsp.com.br>>. Acesso em: 14 a 18 dez. 2009.

CORDEAU, J. F. Et al. A Guide to Vehicle Routing Heuristics. *Journal of the Operational Research Society*, v. 53, p. 512-522, 2002.

CUNHA, C. B. *Uma contribuição para o problema de roteirização de veículos com restrições operacionais*. 1997. Tese (Doutorado)– Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia de Transportes, São Paulo. 222 p.

CUNHA, C. B.; BONASSER, U. O.; ABRAHÃO, F. T. M. Experimentos Computacionais com Heurísticas de Melhorias para o Problema do Caixeiro Viajante. Associação Nacional de Pesquisa e Ensino em Transportes. In: XVI CONGRESSO DA ANPET, *Anais...* Natal/RN: ANPET, 2002.

FERREIRA, R. P. *Combinação de técnicas da inteligência artificial para previsão do comportamento do tráfego veicular urbano na cidade de São Paulo*. 2011. 107 p. Dissertação (Mestrado)– Universidade Nove de Julho, Engenharia de Produção, São Paulo, 2011.

FERREIRA, R. P.; AFFONSO, C. O.; SASSI, R. J. Dynamic routing combined to forecast the behavior of traffic in the city of São Paulo using neuro Fuzzy network. *Journal of Computer Technology and Application* (JCTA), v. 2, n.1. p. 36-41, 2011.

FERREIRA, R. P.; SASSI, R. J. A proposal for dynamic routing of vehicles in the city of Sao Paulo using intelligent routing. In: 3<sup>rd</sup> INTERNATIONAL CONFERENCE ON INFORMATION SYSTEMS, LOGISTICS AND SUPPLY CHAIN. ILS 2010 – Casablanca (Morocco), v. 3, p. 1-13, 2010.

GOLDBARG, M. C.; LUNA, H. P. L. *Otimização combinatória e programação linear: modelos e algoritmos*. 3. ed. Rio de Janeiro: Campus, 2000.

GOLDSCHMIDT, R.; PASSOS, E. *Data mining: um guia prático*, Elsevier, 2005.

GOMIDE, F.; FIGUEIREDO, M. PEDRYCZ, W. *A neural Fuzzy network: Structure and learning*, Fuzzy Logic and its applications, information sciences and intelligent systems, Bien, Z. and Min, K., Kluwer. Netherlands: Academic Publishers, p. 177-186, 1998.

HAYKIN, S. *Redes neurais – princípios e práticas*. 2. ed. Porto Alegre: Bookman, 2001.

KERNER, B. S. *Introduction to modern traffic flow theory and control*, DOI 10.1007/978-3-642-02605-8 11, Berlin Heidelberg: Springer-Verlag, p. 221-243, 2009.

KOVÁCS, Z. L. *Redes neurais artificiais – fundamentos e aplicações*. 4. ed. São Paulo: Editora Livraria da Física, 2006.

LARSEN, A.; MADSEN, O.; SOLOMON, M. *Classification of Dynamic Vehicle Routing Systems*. In: Zaimpekis, V., Tarantilis, C.D., Giaglis, e G., Minis, I. (eds.) *Dynamic Fleet Management*. Springer, New York, 2007.

- LARSEN, A.; MADSEN, O.; SOLOMON, M. Partially dynamic vehicle routing-models and algorithms. *Journal of the Operational Research Society*, v. 53, p. 637-646, 2002.
- LARSEN, A. *The dynamic vehicle routing problem*. Tese (Doutorado) – Technical University of Denmark, Lyngby, 2001.
- McNEILL, F. M.; THRO, E. *Fuzzy Logic: a practical approach*. AP Professional/Academic Press, 1994.
- MAMDANI, E. H.; ASSILIAN, S. An experiment in linguistic synthesis with a fuzzy logic controller. *Int. J. Man Mach. Studies*, v. 7, p. 1-13, 1975.
- NAUCK, D.; KLAWONN, F.; KRUSE, R. *Foundations of Neuro Fuzzy Systems*. Willey & Sons, 1996.
- NOVAES, A. G.; BURIN, P. J. Um Problema de Roteirização Dinâmica de Veículos. *Revista Transportes*, 2010.
- NOVAES, A. G.; FRAZZON, E. M.; BURIN, P. J. Dynamic vehicle routing in over congested urban areas. In: LDIC 2009 – INTERNATIONAL CONFERENCE ON DYNAMICS IN LOGISTICS, Bremen, 2009.
- PACHECO, M. A. C.; VELLASCO, M. M. B. R. (Org.). *Sistemas inteligentes de apoio à decisão: análise econômica de projetos de desenvolvimento de campos de petróleo sob incerteza*. Rio de Janeiro: Ed. PUC-Rio: Ed. Interciência, 2007.
- PASSINO, K. M.; YURKOVICH, S. *Fuzzy Control*. CA, USA: Addison Wesley Longman, Inc., 1998.
- RADUAN, A. C. *Roteirização parcialmente dinâmica aplicada a serviços de campo*. 2009. 121 p. Dissertação (Mestrado)– Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia de Transportes, São Paulo, 2009.
- REZENDE, S. O. *Sistemas inteligentes: fundamentos e aplicações*. Barueri: Manole, 2005.
- RUSSEL, S.; NORVIG, P. *Artificial intelligence – a modern approach*. New Jersey: Pearson Education, 1995.
- RUTKOWSKI, L. *Computational intelligence – methods and techniques*. Berlin, Heidelberg: Springer, 2008.
- SANTOS, A. V. N.; FELIX, L. B.; VIEIRA, J. G. V. Estudo da logística de distribuição física de um laticínio utilizando lógica *fuzzy*. In: V ENCONTRO MINEIRO DE ENGENHARIA DE PRODUÇÃO (EMEPRO). *Anais...* Viçosa: EMEPRO, 2009.
- SELAU, L. P. R.; RIBEIRO, J. L. D. Uma sistemática para construção e escolha de modelos de previsão de risco de crédito. *Gestão Produção*, São Carlos. v. 16, n. 3, p. 398-413, jul.- set. 2009.
- SHABALOV, A.; SEMENKIN, E.; GALUSHIN, P. Automatized design application of intelligent information technologies for data mining problems. In: EIGHTH INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS AND KNOWLEDGE DISCOVERY (FSKD), Shanghai, v. 4, p. 2596-2599, 2011.
- TODAY LOGISTICS & SUPPLY CHAIN. São Paulo: Cecilia Borges, Ano III, n. 38, 2009.
- WU, C. F. et al. Applying a functional neurofuzzy network to real-time lane detection and front-vehicle distance measurement. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*. Issue 99, p. 1-13, 2011.
- ZADEH, L. A. Fuzzy sets. *Information and control*, v. 8. p. 338-353, 1965.

Recebido em 21 jul. 2011 / aprovado em 21 nov. 2011

**Para referenciar este texto**

FERREIRA, R. P.; SASSI, R. J.; AFFONSO, C. O. Aplicação de uma rede neuro *Fuzzy* para a previsão do comportamento do tráfego veicular urbano na região metropolitana da cidade de São Paulo. *Exacta*, São Paulo, v. 9, n. 3, p. 363-375, 2011.

