

ESTIMATIVA DO *HEADWAY* DE DESCARGA EM INTERSEÇÕES SEMAFORIZADAS COM AUXÍLIO DE REDES NEURAIS ARTIFICIAIS

Tito Livio Pereira Queiroz e Silva¹

Maria Alice Prudêncio Jacques²

Mestrado em Transportes
Universidade de Brasília

Recebido: 15/06/2002 - Aprovado: 15/08/2002

RESUMO

Neste trabalho é apresentado o desenvolvimento de um modelo para estimar o *headway* de descarga dos veículos em interseções semaforizadas da cidade de Brasília. Nele foi usada uma técnica alternativa empregada na aproximação de funções: as redes neurais artificiais. De maneira a analisar as vantagens e desvantagens da modelagem com as redes neurais artificiais, os resultados obtidos e as dificuldades no seu desenvolvimento foram comparados aos associados ao desenvolvimento de um modelo analítico com a análise de regressão. Para treinar e testar as redes neurais (e calibrar e validar o modelo analítico) foram utilizados dados obtidos a partir de três fontes distintas: filmagem do processo de descarga de filas, levantamentos geométricos e observações das características gerais das vias. Os resultados indicaram que apesar das redes neurais fornecerem estimativas mais precisas do *headway* de descarga, elas impõem maiores dificuldades para o desenvolvimento do modelo do que a técnica de análise de regressão.

Palavras-chave: Interseções semaforizadas; *headway* de descarga; redes neurais

ABSTRACT

The aim of this work is to develop a model to estimate the discharging headway of vehicles at signalized intersections in Brasilia. In light of this, an alternative technique used to approximate functions was applied: artificial neural networks. In order to analyze the advantages and drawbacks of modeling with neural networks, the results obtained and the development difficulties were compared with those associated with an analytic model developed through regression analysis. In order to train and test the neural networks (and calibrate and validate the analytic model), data obtained from three different sources was used: filming of the lane discharging process, topographic surveys and observations of roads' general characteristics. The results showed that although neural networks give more accurate estimates of discharging headway, they present more difficulties in model development than the regression analysis technique.

Keywords: Signalized intersections; discharging headway; neural networks

1. INTRODUÇÃO

O aumento na utilização de automóveis particulares é uma realidade enfrentada pela maioria dos países do mundo nos últimos anos. Mesmo em países que contam com um bom sistema de transporte público, como o Reino Unido, o número de habitantes por veículo caiu de 1,9 para 1,8 no período de 1989 a 1998 (ANFAVEA, 2000). Nos países em desenvolvimento, esta redução é mais acentuada. No Brasil, por exemplo, só no período de 1996 a 2000, o número de habitantes por veículo privado baixou de 5,75 para 5,03 (GEIPOT, 2000).

A falta de recursos e a mudança de prioridades no investimento em transportes fizeram com que o aumento da frota de veículos não fosse acompanhada, na mesma proporção, pela ampliação da infra-estrutura viária. Um dos resultados desse fato foi o crescimento dos congestionamentos nas vias das cidades, aumentando os tempos de deslocamento e a poluição, com conseqüente diminuição da qualidade de vida das pessoas.

O congestionamento pode ser tratado como um problema de desequilíbrio entre a capacidade ofertada pelas vias e a quantidade de espaço viário demandada pelos veículos. Tal problema pode ser solucionado por meio de duas abordagens distintas, mas não mutuamente exclusivas: gerenciamento da oferta ou gerenciamento da demanda de tráfego. Jacques (2000) defende que, mesmo sendo necessária a adoção de medidas que visem o controle da demanda, é inegável a contribuição que o controle do tráfego pode fornecer para minimizar os problemas de circulação dos veículos.

As interseções em nível são os pontos mais críticos da malha viária com relação aos congestionamentos e, dessa forma, devem receber atenção especial. Se for justificado seu uso e dependendo da qualidade da sua programação, o semáforo pode ser um dos instrumentos mais eficazes para controlar o tráfego em uma interseção (Niittymäki, 1998). No entanto, para que seja possível programar adequadamente os semáforos, é necessário que sejam conhecidos alguns parâmetros que descrevem o comportamento dos veículos ao saírem das interseções, tais como o *headway* de descarga, fluxo de saturação etc. Em especial, as formas de controle por semáforo em tempo real necessitam de informações sobre o *headway* de descarga dos veículos. Para Briggs (1977), o conhecimento do *headway* de descarga é fundamental, também, para o desenvolvimento de modelos de simulação microscópica do tráfego.

Diante das dificuldades de obtenção destes parâmetros *in loco* para diversas situações geométricas e operacionais encontradas, eles são frequentemente estimados a partir de modelos. Queiroz (2001) mostrou que os modelos utilizados para estimativa do fluxo de saturação devem ser ajustados para refletir a realidade atual de cada local onde foram desenvolvidos. Considerando que o fluxo de saturação e o *headway* de descarga são parâmetros que representam o mesmo fenômeno, pode-se afirmar que, também, os modelos para estimativa do *headway* devem ser desenvolvidos para a realidade do local onde serão empregados. A grande maioria das pesquisas dedicadas ao estudo do *headway* de descarga apresenta modelos que permitem a sua estimativa para as condições de tráfego dos locais onde foram desenvolvidos. No entanto, não existe nenhum modelo para estimativa deste parâmetro que reflita as condições de tráfego em cidades brasileiras.

O desenvolvimento de modelos por meio da análise de regressão se mostra uma tarefa complexa, principalmente quando é necessária a inclusão de muitas variáveis explicativas. Uma técnica alternativa de modelagem que vem sendo aplicada com bastante frequência na área de transportes, utiliza as redes neurais artificiais (RNAs) como ferramenta (Dougherty, 1995 e 1997). Queiroz (2001) mostrou que, além de se mostrar menos complica-

do na inclusão das variáveis explicativas, o uso de RNAs leva a resultados mais precisos.

Diante do exposto, neste trabalho objetiva-se desenvolver um modelo para estimar o *headway* de descarga de veículos em interseções controladas por semáforo na cidade de Brasília, utilizando redes neurais artificiais. De maneira a verificar a precisão obtida com o modelo desenvolvido com as RNAs, os resultados obtidos por meio desta técnica serão comparados com aqueles obtidos com um modelo analítico desenvolvido através de análise de regressão. Para observar as vantagens e desvantagens da modelagem com as RNAs de maneira qualitativa, serão analisadas as dificuldades inerentes a modelagem realizada com estas duas diferentes técnicas.

2. REFERENCIAL TEÓRICO

Este item mostrará as principais fundamentações teóricas utilizadas durante o desenvolvimento desta pesquisa e necessária à perfeita compreensão do trabalho.

2.1. *Headway* de descarga

Entende-se por *headway* de descarga o intervalo de tempo decorrido entre a passagem de dois veículos consecutivos por uma seção de referência (faixa de retenção, alinhamento do meio-fio da via perpendicular etc.), tomado com relação a um ponto em comum dos veículos (rodas traseiras, pára-choque dianteiro etc.), obtidos durante a dissipação de uma fila de veículos em uma interseção controlada por semáforo. Uma definição particular deve ser adotada para o primeiro veículo da fila, uma vez que na frente deste não existe nenhum automóvel. Neste caso, diz-se que o *headway* de descarga é o tempo decorrido desde o início da indicação do verde para fila em questão, até a passagem do ponto de referência do veículo pela referência na via. Para a realização deste estudo, adotou-se como referência a passagem das rodas traseiras dos veículos sobre a faixa de retenção. Esta escolha foi realizada em função da maior facilidade que tais pontos ofereceriam à coleta dos *headways* de descarga, considerando o método escolhido para a obtenção dos mesmos (i.e. filmagem do processo de descarga).

A importância do conhecimento do *headway* de descarga para desenvolvimento de estratégias de controle semaforico em tempo real ou de modelos microscópicos de simulação, vem levando autores de alguns países a estudar este parâmetro de comportamento veicular.

Durante a revisão da literatura, foram encontrados os seguintes trabalhos sobre o processo de dissipação de filas de veículos em interseções controladas por semáforo: Carstens, 1971; Briggs, 1977; Lu, 1984; Lee e Chen, 1986; Porto Jr. e Londero, 1990; Bonneson, 1993; Adonis *et al*, 1996; Akçelik e Besley, 1996; Bartel *et al*, 1997; Gibson *et al*, 1997; Niittymäki, 1998. Analisando estes estudos percebe-se que a posição do veículo na fila é quase sempre considerada. Variáveis como a velocidade desejada dos veículos sobre a faixa de retenção, aceleração, distância entre os veículos na fila estacionária, tempo de reação dos motoristas e tipo de veículo foram consideradas em pelo menos três destes estudos. No entanto, dos estudos que trataram do tipo de veículo, só um analisou de fato a sua influência sobre o *headway* de descarga por posição na fila; nos demais, o parâmetro que estava sendo estudado era o tempo de descarga de uma fila de veículos. Mesmo neste estudo que avaliou o impacto do tipo de veículo sobre *headway* de descarga, a análise foi feita para condições bem específicas, ou seja, para faixas de conversão à esquerda. Outras variáveis consideradas nos estudos foram: tipo de movimento realizado pelos veículos (em frente, à direita e à esquerda); período do dia no qual

os dados foram obtidos (pico da manhã ou da tarde); posição da faixa na via (central ou lateral); largura da faixa de tráfego; localização da via (em áreas comerciais centrais – CBD – ou em áreas não comerciais – NCBD); dentre outras.

Dos estudos mencionados anteriormente, os únicos que não sugeriram um modelo para a estimativa do *headway* de descarga foram o de Lee e Chen (1986) e Porto Jr. e Londero (1990). A rigor, nos trabalhos de Carstens (1971), Lu (1984) e nos estudos chilenos (Adonis *et al.*, 1996; Bartel *et al.*, 1997; Gibson *et al.*, 1997) também não foram desenvolvidos modelos para a estimativa do *headway*, mas foram propostos modelos para estimar o tempo total de descarga de uma fila de veículos.

Comparando os estudos analisados sobre o *headway* de descarga, com aqueles sobre o fluxo de saturação avaliados por Queiroz (2001), verifica-se que algumas variáveis consideradas nos últimos não são incluídas nos estudos relativos ao *headway*. No entanto, uma vez que o *headway* de descarga e o fluxo de saturação representam o mesmo fenômeno, as variáveis que afetam um dos parâmetros também devem ter sua influência investigada no processo de modelagem do outro.

2.2. Redes Neurais Artificiais (RNAs)

As redes neurais artificiais são formas de computação paralelas distribuídas formadas por unidades de processamento simples (neurônios) que computam determinadas funções matemáticas. Estas unidades são dispostas em camadas e interligadas por um grande número de conexões, as quais estão associados pesos (pesos sinápticos). Estes pesos são os responsáveis pelo armazenamento do conhecimento adquirido pela rede. (Braga *et al.*, 2000).

A capacidade que as redes neurais têm de solucionar problemas está diretamente relacionada com a sua arquitetura. Segundo Braga e outros (2000), os principais elementos que definem a arquitetura de uma RNA são o número de camadas escondidas, a forma como os neurônios estão conectados entre si, a quantidade de conexões entre os neurônios e o número de neurônios em cada camada. Normalmente, estes elementos são definidos empiricamente.

Outra característica importante a se considerar é a capacidade de aprendizado das RNAs. Com relação a esta propriedade das redes, pode-se destacar os paradigmas e algoritmos de aprendizado. Os primeiros se referem à forma como a rede se relaciona com o ambiente externo; os últimos, dizem respeito à maneira como são executadas as correções nos pesos sinápticos, com o intuito de melhorar a resposta da rede. Segundo Haykin (1999), o problema que se pretende solucionar, ou seja, a aproximação de uma função que relacione as variáveis explicativas com o *headway* de descarga, se insere nos problemas solucionáveis por meio das redes com aprendizado supervisionado (paradigma de aprendizado).

Neste trabalho foi utilizada a rede *perceptron* multicamadas (ou MLP, *MultiLayer Perceptron*), que vem sendo aplicada com sucesso em muitos trabalhos de transporte (Faghri e Hua, 1992; Dougherty, 1995 e 1997). As redes MLP são constituídas de unidades sensoras, que recebem os dados de entrada, uma ou mais camadas escondidas, responsáveis pela extração das características dos dados de entrada, e uma camada de saída, que fornece a resposta da rede. O algoritmo *backpropagation* foi utilizado para treinar as RNAs nesta pesquisa, uma vez que é o mais comumente utilizado no treinamento das redes MLP. Este algoritmo é empregado para treinar redes de maneira supervisionada, por meio da correção incremental dos pesos, a partir da comparação entre a resposta que se deseja obter e a resposta fornecida pela rede. Seu funcionamento ocorre em duas fases: a *forward*, na qual os sinais são propagados, de camada a camada, na direção da camada de saída; na fase seguinte, a *backward*, os pesos são ajustados, com base nos erros de previsão.

3. DESENVOLVIMENTO DO MODELO COM AUXÍLIO DE RNAs

Neste item serão descritos os procedimentos necessários para o desenvolvimento do modelo para a estimativa do *headway* de descarga com o auxílio de redes neurais.

3.1. Obtenção das bases de dados

A partir da revisão bibliográfica e em função dos tipos de equipamento disponíveis para a coleta dos dados, foram determinadas as variáveis consideradas neste estudo: i) posição dos veículos na fila; ii) tipo de veículo (leve ou pesado); iii) período do dia (pico da manhã/meio-dia ou pico da tarde); iv) localização da faixa na via (faixa esquerda, central ou direita); v) localização da via (em áreas comerciais centrais – CBD – ou em áreas não comerciais – NCBD); vi) largura da faixa; vii) greide da faixa; e viii) fluidez do tráfego a jusante da faixa de retenção.

3.1.1. Levantamento dos dados

Nas faixas onde os dados foram coletados era permitido exclusivamente o movimento em frente. Os dados relativos a estas variáveis foram levantados em 25 faixas de trânsito, pertencentes a 16 diferentes interseções da cidade de Brasília, sendo obtidos de três fontes distintas: filmagens do processo de descarga; levantamentos topográficos; e observações gerais.

a) Filmagens do processo de descarga: as filmagens deveriam permitir a extração dos dados relativos ao *headway* de descarga (com o uso de cronômetros), à posição do veículo na fila (da 1ª a 15ª posição) e ao tipo de veículo. Para cada posição na fila foi associado, além do tipo de veículo na posição “n”, a seqüência de tipos de veículos (LL, PL, LP, PP). Por exemplo, se na posição 2 existisse um veículo pesado e na posição 1 existisse um leve, seria associada a posição 2 uma seqüência LP. Neste estudo, veículo pesado foi definido como sendo aquele que possui mais de quatro pneus em contato com o pavimento e veículo leve o que possui quatro pneus tocando o solo.

b) Levantamentos topográficos: estes levantamentos forneceram o greide e a largura da faixa, bem como ajudaram a definir a fluidez a jusante da faixa de retenção. A largura foi medida na seção onde se encontra a faixa de retenção.

c) Observações gerais: o tráfego lento após a retenção (registrado durante as filmagens) ou faixas com características geométricas e operacionais ruins a jusante da retenção (i.e. com mudanças bruscas de traçado, pontos de ônibus, entrada e saída de estacionamentos ou de retornos) caracterizavam uma fluidez ruim. Todos os demais casos caracterizavam uma fluidez boa. A classificação das vias com relação à sua localização na cidade foi realizada observando-se as características do entorno da interseção onde as mesmas se localizavam: CBD, se possuíam características de vias urbanas e movimento intenso de veículos e pedestres; e NCBD, se possuíam características rodoviárias e apresentavam baixa movimentação de automóveis e pedestres. A localização da faixa na via foi dividida em três categorias: faixas esquerdas, se possuíam meio-fio do seu lado esquerdo; faixas centrais, se não possuíam meio-fio como limite; e faixas direitas, se possuíam meio-fio do lado direito. Por sua vez, o período em que foi realizada a filmagem foi separado em duas classes: pico da manhã (incluindo o pico do meio-dia) e pico da tarde.

3.1.2. Montagem das bases de dados

Foram selecionadas 20% das faixas para o teste (i.e. 5 faixas de tráfego), enquanto as demais (i.e. 20 faixas) foram utilizadas para o treinamento. Esta divisão da base de dados resul-

tou em 2.363 observações utilizadas para no teste e 7.088 observações usadas no treinamento.

A base de dados original de teste (dados desagregados por ciclo) apresentava várias observações “contraditórias”, ou seja, várias situações onde as variáveis explicativas são todas iguais, diferenciando-se apenas no valor do *headway* de descarga. Uma vez que as arquiteturas a serem testadas estimam um único valor para cada grupo de variáveis independentes, foi necessária a agregação dos dados a serem utilizados no processo de teste.

Os dados foram agregados por posição na fila, tipo de veículos na posição “n” e “n-1” (LL, PL, LP ou PP) e faixa (características locais). Por exemplo, os dados relativos aos veículos leves seguidos de veículos leves (seqüência LL), na posição 5, medidos na faixa 10, foram agrupados para formar um único caso. O valor utilizado para representar o *headway* de descarga de cada caso foi a média aritmética dos *headways* incluídos nos respectivos casos. Objetivando analisar a resposta dos modelos quando calibrados com os dados agrupados e desagregados, foram agregados da mesma maneira os dados da base de treinamento.

3.2. Desenvolvimento de um modelo analítico

A análise do impacto das variáveis de entrada sobre a variável de saída é difícil de ser realizada na modelagem com as redes neurais. Desta maneira, além de servir de base para comparação com o modelo conseguido por meio das redes neurais artificiais, o desenvolvimento de um modelo analítico foi fundamental para determinar quais variáveis explicativas têm influência na estimativa do *headway*.

Neste sentido foram testados sete modelos, dentre eles um modelo baseado naquele desenvolvido por Akçelik e Besley (1996). Os modelos testados foram calibrados com as mesmas bases de dados utilizadas para o treinamento das redes neurais (base de treinamento agregada e desagregada).

A um nível de 5%, verificou-se que os únicos parâmetros que não apresentavam significância na estimativa do *headway* de descarga foram aqueles relacionados ao período do dia em que foram realizadas as filmagens e à largura da faixa. Os melhores resultados foram obtidos quando o modelo foi calibrado com a base de dados desagregada. O formato final deste modelo é mostrado na Equação 1. Maiores detalhes a respeito do desenvolvimento do modelo analítico podem ser conseguidos em Silva (2002).

$$h_n = [3,24 + (0,02 \times G) + (0,09 \times Local) - (0,22 \times F) - (0,06 \times Faixa)] \times e^{-\{(0,02 \times n) - (0,36 \times TV_{n-1}) + [N_{n-1} \times ((0,29 \times LL) + (0,06 \times PL) - (0,32 \times LP) - (0,50 \times PP))]\}} \quad (1)$$

onde:

h_n = *headway* de descarga do veículo na posição n (s);

G = greide da faixa (%);

Local = variável dummy que indica a área onde está localizada a via. Local = 1 se a faixa estiver em uma área comercial central (CBD) e Local = 0 caso contrário;

F = variável dummy que indica a fluidez do tráfego a jusante da linha de retenção. F = 1 se a fluidez for boa e F = 0 se for ruim;

Faixa = variável dummy que indica a localização da faixa na aproximação. Faixa = 1 se for uma faixa esquerda, Faixa = 0 se for uma faixa central e Faixa = -1 se for uma faixa direita;

n = posição do veículo na fila;

TV_{n-1} = tipo do primeiro veículo da fila. $TV_{n-1} = 1$ se for pesado e $TV_{n-1} = 0$ se for leve;

N_{n-1} = variável dummy que indica se o veículo não é o primeiro da fila. $N_{n-1} = 1$ se não for o primeiro da fila e $N_{n-1} = 0$ caso contrário;

LL = variável dummy que indica se o veículo na posição “n” é leve e na posição “n-1” também é leve. LL = 1 se ocorrer esta situação e LL = 0 caso contrário;

PL = variável dummy que indica se o veículo na posição “n” é leve e na posição “n-1” é pesado. PL = 1 se ocorrer esta situação e PL = 0 caso contrário;

LP = variável dummy que indica se o veículo na posição “n” é pesado e na posição “n-1” é leve. LP = 1 se ocorrer esta situação e LP = 0 caso contrário; e

PP = variável dummy que indica se o veículo na posição “n” é pesado e na posição “n-1” é pesado. PP = 1 se ocorrer esta situação e PP = 0 caso contrário.

3.3. Modelagem com as RNAs

A escolha dos muitos fatores envolvidos no desenvolvimento de um modelo com as redes neurais (arquitetura, taxa de aprendizado, limites de normalização etc.), depende em grande parte da experiência pessoal do pesquisador e do problema em questão. No entanto, é possível encontrar algumas informações úteis em trabalhos que utilizam as RNAs como técnica de modelagem de funções.

Inicialmente, foi realizado um pré-processamento dos dados de forma a facilitar o aprendizado da rede. Este pré-processamento consiste em comprimir os valores dos dados de entrada e saída em um intervalo determinado (normalização dos dados). Para tanto foi utilizada a Equação 2.

$$x_{norm} = \min_{norm} + \frac{(\max_{norm} - \min_{norm}) \times (x - x_{min})}{(x_{max} - x_{min})} \quad (2)$$

onde: x = valor do dado a ser normalizado;

x_{norm} = valor normalizado da dado x;

\min_{norm} = menor valor permitido após a normalização;

\max_{norm} = maior valor permitido após a normalização;

x_{max} = maior valor encontrado na base de dados; e

x_{min} = menor valor encontrado na base de dados.

Não há uma regra que defina quais são os melhores valores de “ \min_{norm} ” e “ \max_{norm} ” que devem ser utilizados. Os valores adotados neste trabalho foram os mesmos utilizados por Queiroz (2001), ou seja, os dados foram comprimidos entre 0,05 e 0,95. A exemplo de Queiroz, a escolha destes limites ocorreu a partir da realização de vários testes. Vale destacar, ainda, que os dados das bases de treinamento e teste foram normalizados considerando o valor máximo e mínimo das duas bases como um todo (i.e., $x_{max} = 15$ e $x_{min} = -4,14$). Outras possibilidades de realização do processo de normalização são discutidas por Queiroz que, após vários testes, verificou que a normalização conjunta dos dados das duas bases era a melhor solução para o seu estudo.

O desempenho de uma RNA está intimamente relacionado com a escolha de alguns fatores referentes ao treinamento da rede, sendo o principal a arquitetura. No entanto, não há nenhuma forma bem definida para escolha da arquitetura mais adequada para solução de determinado problema, principalmente no que se refere à quantidade de camadas escondidas e de neurônios nestas camadas. Assim, a seleção da quantidade de camadas escondidas e de neurônios nas mesmas é definida, normalmente, por procedimentos de tentativa-e-erro. Já na camada de saída têm-se um neurônio para cada resposta fornecida pela rede (nesta pesquisa, foi utilizado um neurônio, correspondente ao *headway* de descarga). O número de unidades sensoras na camada de entrada é igual a quantidade de variáveis explicativas (Tabela 1).

Tabela 1: Variáveis utilizadas para treinamento da rede

Número da unidade sensora	Variável de entrada correspondente	Número da unidade sensora	Variável de entrada correspondente
1	Greide	6	Tipo de veículo na posição n=1
2	Localização da faixa na via	7	Sequência LL
3	Localização da via	8	Sequência PL
4	Fluidez a jusante da faixa de retenção	9	Sequência LP
5	Posição na fila	10	Sequência PP

Há ainda outros fatores a determinar para o treinamento das redes: função de ativação das camadas escondidas e da camada de saída; taxa de aprendizado; e número máximo de passos de treinamento (i.e. quantidade de vezes em que todos os vetores de treinamento são apresentados a rede). As funções de ativação utilizadas foram a sigmoideal logística, para os neurônios das camadas escondidas, e a linear, para o neurônio da camada de saída. A taxa de aprendizado adotada foi de 0,05, enquanto o número de passos, para cada ciclo de treinamento, foi de 3.000.

3.4. Teste das redes analisadas

Depois de treinadas várias arquiteturas de redes, partiu-se para a verificação da capacidade de generalização das mesmas, ou seja, a capacidade que as mesmas têm de conseguir dar respostas coerentes para situações não apresentadas na etapa de treinamento.

Para cada caso da base de teste (base agregada) foi calculado o erro de estimativa das RNAs, utilizando a Equação 3.

$$\text{Erro} = \frac{h_n^{\text{estimado}} - h_n^{\text{real}}}{h_n^{\text{real}}} \times 100 \quad (3)$$

onde: Erro = erro obtido ao comparar o *headway* estimado e o observado em campo (%);

h_n^{estimado} = *headway* de descarga na posição “n” estimado pelas RNAs; e

h_n^{real} = *headway* de descarga na posição “n” obtido em campo.

Os erros encontrados para os casos da base de teste das redes apresentaram grande variação (de 0% até mais de 100%). Diante deste fato, surgiu a dúvida de qual valor do erro considerar aceitável.

Conforme mencionado no subitem 3.1.2, o valor adotado para representar o *headway* de descarga de cada caso da base de teste foi a média aritmética dos *headways* que se enquadravam nos respectivos casos. No entanto, verificou-se que os *headways* observados em campo possuem uma variação normal em torno desta média. Desta maneira, apesar do valor estimado poder não estar próximo da média, pode estar dentro do intervalo de confiança que reflete a variação natural dos dados. Diante do exposto, calculou-se, para cada caso de teste, o intervalo de confiança (IC), a um nível de 95%. A Figura 1 mostra o percentual de casos nos quais os *headways* estimados ficaram dentro dos intervalos de confiança, para todas as arquiteturas consideradas na etapa de treinamento. As redes testadas são representadas pelo número de neurônios (e unidades de entrada) em cada camada. Desta maneira, a rede 10-2-1 representa uma rede com 10 unidades de entrada, 2 neurônios na primeira (e única) camada escondida e 1 neurônio na camada de saída. Analogamente, a rede 10-2-1-1 indica que existem 10 unidades de entrada, 2 neurônios na primeira camada escondida, 1 neurônio na segunda camada escondida e 1 neurônio na camada de saída.

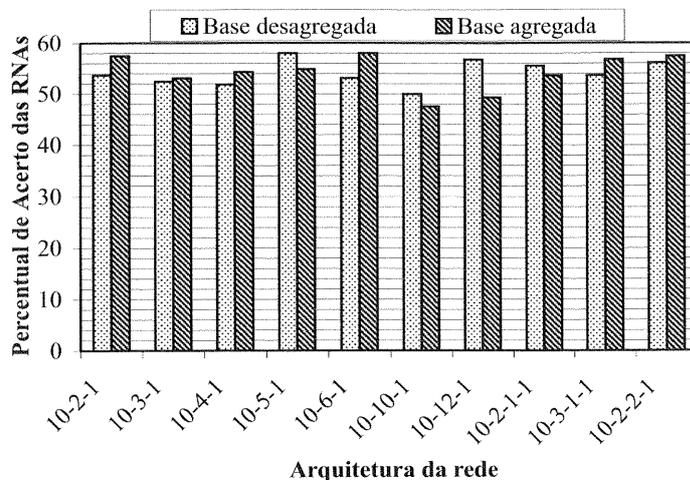


Figura 1: Índice de acerto na estimativa dos *headways* utilizando as RNAs

Observando os resultados mostrados na Figura 1, verifica-se que as redes 10-5-1, treinada com a base desagregada, e 10-6-1, treinada com a base agregada, apresentaram os maiores índices de acerto (58,02 %). No entanto, os *headways* estimados acima do limite superior do intervalo de confiança foram bem maiores ao usar a rede 10-6-1. Já o erro com relação ao limite inferior do intervalo de confiança foi um pouco menor para a rede com mais neurônios (ver Figura 2).

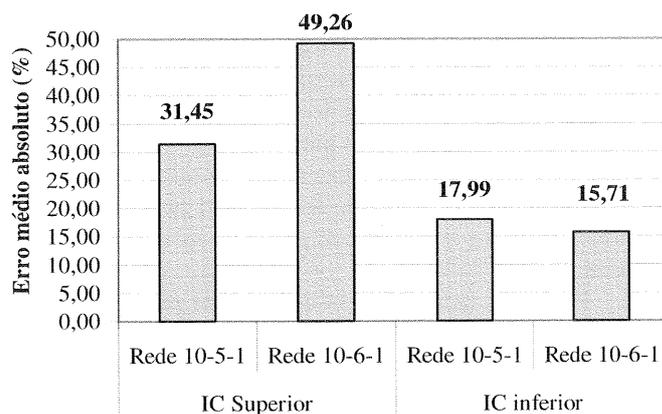


Figura 2: Erros de estimativa com relação aos intervalos de confiança (IC)

Em resumo, a comparação entre a rede 10-5-1, treinada com a base desagregada, e a rede 10-6-1, treinada com a base agregada, mostra que a última, apesar de ter precisão semelhante a da primeira, realiza as estimativas fora do intervalo de confiança de maneira mais grosseira.

4. Comparação entre os modelos

Neste item serão comparadas, quantitativamente e qualitativamente, as duas técnicas de modelagem utilizadas nesta pesquisa: as redes neurais artificiais e a análise de regressão.

4.1. Comparação quantitativa

Uma vez que os critérios tradicionalmente adotados para a análise dos modelos analíticos (coeficiente de determinação e significância dos parâmetros) não são aplicáveis para as redes neurais, optou-se por avaliar o erro médio absoluto e o índice de acerto na previsão do *headway*. Utilizando a mesma base de dados utilizada para teste das diferentes arquiteturas de RNAs, calculou-se o erro médio de estimativa (obtido a partir dos erros absolutos calculados com a Equação 3) e o índice de acerto obtidos com o modelo analítico.

Nas duas modelagens foi utilizada a mesma base de da-

dos para o treinamento (ou calibração no caso no modelo analítico), o que permite comparar os resultados com eles obtidos de maneira direta. A Figura 3 mostra o erro e o índice de acerto obtidos com o modelo analítico e com as RNAs. Nesta Figura, pode-se perceber que os resultados obtidos com as redes neurais são mais satisfatórios que aqueles obtidos com o modelo analítico, embora a diferença seja pequena.

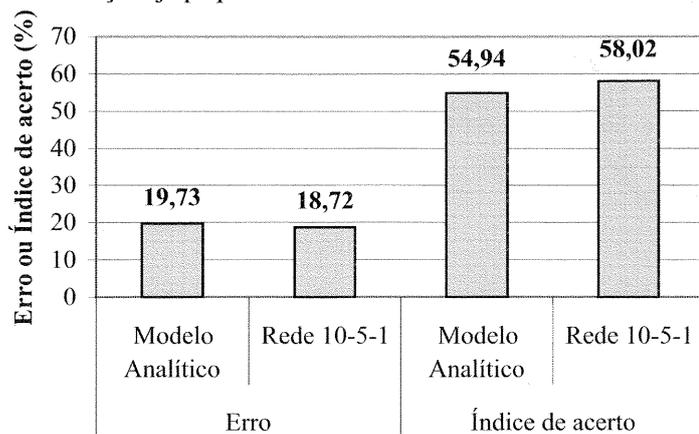


Figura 3: Comparação entre o erro de estimativa e o índice de acerto obtido com as duas técnicas de modelagem

4.2. Comparação qualitativa

Uma das principais críticas realizadas às técnicas tradicionais de análise de regressão é a necessidade da idealização de relações entre as variáveis explicativas e a variável estudada. No presente trabalho, tal problema ficou bastante evidente, uma vez que foram testados 07 modelos para se poder conseguir um modelo satisfatório. A utilização das redes neurais artificiais, realmente, elimina esta dificuldade apresentada pela análise de regressão, uma vez que estabelece por si só as relações entre as variáveis.

Por outro lado, há certa dificuldade em estabelecer os melhores fatores de treinamento das redes neurais. A falta de experiência do pesquisador torna muito demorada a busca pela melhor taxa de aprendizado e pela quantidade ideal de passos de treinamentos necessários. Além da dificuldade de determinar estes dois fatores, a procura pela melhor arquitetura requer um tempo bastante longo. Vem surgindo, no entanto, em várias áreas de pesquisa, a idéia de integrar outras formas de inteligência artificial, como o algoritmo genético, para otimizar a procura da melhor arquitetura da rede (e.g. Arifovic e Gençay, 2001).

Comparando o tempo necessário para treinar uma arquitetura de RNA utilizando o algoritmo *backpropagation* com o tempo requerido para calibrar um modelo analítico, verifica-se que o primeiro é maior. Isto ocorre, principalmente, porque não se sabe ao certo se o processo de treinamento atingiu um mínimo global ou se o mesmo se encontra em estado de saturação prematura. No entanto, técnicas alternativas, utilizando algoritmos genéticos para o treinamento das RNAs, vêm sendo recomendadas na literatura internacional para fugir do problema de aprendizado lento obtido com o *backpropagation* (e.g. Sexton e Gupta, 2000).

Por fim, vale destacar que, de fato, os resultados obtidos com as redes neurais são de difícil interpretação. Enquanto a calibração dos modelos analíticos permitiu verificar a influência das variáveis explicativas sobre o *headway* de descarga, as redes neurais não consentiram tal análise. No entanto, há alguns estudos, ainda pouco comentados na literatura referente as RNAs, que fazem tentativas de analisar o peso de cada uma das variáveis de entrada sobre a variável de saída (Intrator e Intrator, 2001).

5. CONCLUSÕES

Pode-se dizer que os objetivos desta pesquisa foram realizados com êxito. Em primeiro lugar, foi desenvolvido um modelo com auxílio das redes neurais artificiais capaz de estimar com precisão satisfatória o *headway* de descarga em interseções controladas por semáforo da cidade de Brasília. Em particular, uma rede com 5 neurônios na camada escondida conseguiu estimar corretamente 58% dos casos utilizados para teste. No entanto, foi verificada maior dificuldade de modelagem com as redes neurais, em função da grande quantidade de fatores de treinamento a escolher, principalmente no que se refere a determinação da quantidade ideal de neurônios nas camadas escondidas. Da mesma maneira, as RNAs apresentam a desvantagem de necessitar de mais tempo para treinamento, que os modelos analíticos para a calibração. Por fim, observou-se que as redes neurais não possibilitam uma análise simples da influência de cada uma das variáveis explicativas sobre a variável estudada. No entanto, vêm aparecendo na literatura alguns estudos que tentam acabar com estas desvantagens das redes neurais. Dessa maneira, para estudos análogos ao aqui realizado, considera-se recomendável que no momento as redes neurais sejam usadas de forma complementar às técnicas tradicionais de modelagem.

Como vantagem, as redes neurais não necessitam de suposições a respeito das relações existentes entre as variáveis independentes e a variável dependente, sendo também mais flexíveis com relação a dados incompletos ou com ruídos.

Apesar das dificuldades encontradas durante o desenvolvimento do modelo com as redes neurais, é válido mencionar que a rede com 5 neurônios na camada escondida se mostrou satisfatória na estimativa dos *headways* de descarga nas interseções controladas por semáforo da cidade de Brasília. Sugere-se, no entanto, que sua aplicabilidade em outras cidades brasileiras seja testada e, se necessário, seja realizado um novo treinamento com os dados dos locais onde a rede será aplicada.

Referências bibliográficas

- Adonis, C., G. Bartel, J.E. Coeymans e J. Gibson (1996) La Influencia del Transporte Publico en Parametros de Trafico. *Anais do IX Congreso Panamericano de Ingeniería de Tránsito y Transporte*. Dec., Havana, Cuba, p. 5-16.
- Akçelik, R. e M. Besley (1996) *Fundamental Traffic Flow Relationships at Signalized Intersection Stop-Line*. Working Paper N° WD R 96/043, ARRB Transport Research Ltd., Vermont South, Australia.
- ANFAVEA - Associação Nacional dos Fabricantes de Veículos Automotores (2000). *Anuário Estatístico da Indústria Automobilística Brasileira*. (disponível em formato PDF para download em www.anfavea.com.br).
- Arifovic, J. e R. Gençay (2001) Using Genetic Algorithms to Select Architecture of a Feedforward Artificial Neural Network. *Physica A*, N° 289, p. 574-594.
- Bartel, G., J.E. Coeymans, e J. Gibson (1997) Reformulacion del Metodo de Regresion Sincronico para la Estimacion de Parametros de Capacidad de una Interseccion

- Semaforizada Bajo Condiciones de Trafico Mixto. *Anais do VIII Congreso Chileno de Ingeniería de Transporte*. Santiago, Chile, p. 371-382.
- Bonneson, J.A. (1993) Modeling Queued Driver Behavior at Signalized Junctions. *Transportation Research Record*, N° 1365, p. 99-107.
- Braga, A.P., T.B. Ludermir, A.C.P.L.F. Carvalho (2000) *Redes Neurais Artificiais: Teoria e Aplicações*. Editora LTC, Rio de Janeiro.
- Briggs, T. (1977) Time Headways on Crossing the Stop-Line after Queuing at Traffic Lights. *Traffic Engineering and Control*, p. 264-265.
- Carstens, R.L. (1971) Some Traffic Parameters at Signalized Intersections. *Traffic Engineering*, vol 41, August, N° 11, p. 33-36.
- Dougherty, M.S. (1995) A Review of Neural Networks Applied to Transport. *Transportation Research C*, vol. 3, N° 4, p. 247-260.
- Dougherty, M.S. (1997) Applications of Neural Networks in Transportation. *Transportation Research C*, vol. 5, N° 5, p. 255-257.
- Faghri, A. e J. Hua (1992) Evaluation of Artificial Neural Networks Applications in Transportation Engineering. *Transportation Research Record*, N° 1358, p. 71-80.
- GEIPOT (2000) *Anuário Estatístico*. (disponível para download em www.geipot.gov.br).
- Gibson, J., G. Bartel e J.E Coeymans (1997) Redefinición de los Parametros de Capacidad de una Intersección Semaforizada Bajo Condiciones de Trafico Mixto. *Anais do VIII Congreso Chileno de Ingeniería de Transporte*. Santiago, Chile, p. 383-395.
- Haykin, S. (1999) *Neural Networks – A Comprehensive Foudation*. Prentice-Hall, Inc., New Jersey, Estados Unidos da América.
- Intrator, O. e N. Intrator (2001) Interpreting Neural Network Results: a Simulation Study. *Computational Statistics and Data Analysis*, N° 37, p. 373-393.
- Jacques, M.A.P. (2000) *Desenvolvimento de Modelos para Representação do comportamento dos Veículos em Redes Controladas por Semáforos*. Universidade de Brasília. Brasília, DF.
- Lee, J. e R.L. Chen (1986) Entering Headway at Signalized Intersections in a Small Metropolitan Area. *Transportation Research Record*, N° 1091, p. 117-126.
- Lu, Y. –J. (1984). A Study of Left-Turn Maneuver Time for Signalized Intersections. *ITE Journal*. October, p. 42 – 47.
- Niittymäki, J. (1998). *Isolated Traffic Signals – Vehicle Dynamics and Fuzzy Control*. Licentiate Thesis, Publication 94, Transportation Engineering, Helsinki, University of Technology, Finland.
- Porto Jr, W. e L. C. Londero (1990) Levantamento dos Headways de uma Corrente de Tráfego em um Cruzamento Semaforizado. *Revista da ANPET*, Ano 3, Julho/90, p. 33-47.
- Queiroz, I.N.F de (2001) *Estimativa do Fluxo de Saturação com o Auxílio de Redes Neurais*. Dissertação de Mestrado em Transportes. Universidade de Brasília, Brasília.
- Sexton, R.S. e J.N.D Gupta (2000) Comparative Evaluation of Genetic Algorithm and Backpropagation for Training Neural Networks. *Information Sciences*. N° 129, p. 45-59.
- Silva, T.L.P.Q e (2002) *Estudo do Headway de Descarga de Veículos em Interseções Controladas por Semáforos*. Dissertação de Mestrado em Transportes. Universidade de Brasília, Brasília.

CONTATOS

¹ **Tito Livio Pereira Queiroz e Silva**

E-mail: titolpqs@unb.br

Fones: (61) 307-2058 (Ramal 210)

² **Maria Alice Prudêncio Jacques**

E-mail: mapj@unb.br

Fones: (61) 307-2714 (Ramal 32)