

## SELEÇÃO DE MODELOS NEURAIS DE INTERAÇÃO ESPACIAL ATRAVÉS DE ALGORITMOS GENÉTICOS

**Alexandra Akamine**  
**Antônio Néelson Rodrigues da Silva**  
Universidade de São Paulo  
Escola de Engenharia de São Carlos  
Departamento de Transportes  
**Renato da Silva Lima**  
Universidade Federal de Itajubá  
Departamento de Engenharia de Produção

### RESUMO

O objetivo deste trabalho é avaliar o uso da técnica de otimização de Algoritmos Genéticos (AGs) como ferramenta auxiliar para a seleção de Redes Neurais Artificiais (RNAs) destinadas à construção de Modelos de Interação Espacial. Os dados empregados para o experimento aqui proposto refletem a evolução espacial da demanda por serviços municipais de educação numa cidade média brasileira, para os anos de 2000 e 2001. Os dados de demanda foram agregados em zonas e os fluxos dos centróides destas zonas para os pontos de oferta foram divididos aleatoriamente em três subconjuntos: treinamento, validação e teste. As arquiteturas de rede utilizadas foram definidas a partir do emprego de AGs, através da comparação dos fluxos reais do ano de 2001 e dos fluxos estimados com base nos dados de 2000. Os resultados obtidos através dos modelos neurais selecionados pelos AGs mostraram-se superiores aos do modelo gravitacional tradicional após algumas iterações (gerações).

### ABSTRACT

The objective of this work is to evaluate the use of the Genetic Algorithms (GAs) optimization technique as a supporting tool to select Artificial Neural Networks (ANNs) configurations applied to Spatial Interaction Models. The data used for this application reflect the changes in the spatial distribution of the demand for education services in a Brazilian medium-sized city, in the period 2000-2001. Demand data were aggregated to fit within the limits of the census tracts (CT), and the number of trips from the centroids of those CT to each facility were randomly split in three data subsets: training, validation, and query. The ANN configurations used were defined with the application of GAs, which were used to minimize the differences between 2001 actual values and the values estimated with the models trained with the 2000 dataset. The results showed that the neural spatial interaction models selected by the AGs outperformed the traditional gravity models after a few iterations (generations).

### 1. INTRODUÇÃO

O rápido crescimento das cidades brasileiras, não acompanhado de um planejamento prévio de sua expansão (incluindo o uso e a ocupação do solo), vem acarretando transtornos à comunidade no que se refere aos deslocamentos, visto que estes se tornam cada vez maiores (Dutra, 1998). Devido a isso, torna-se necessário um conhecimento das subdivisões internas das cidades, dos tipos de serviços atualmente prestados à comunidade em cada uma destas subdivisões e dos usuários destes serviços, não só em termos quantitativos, mas principalmente no que diz respeito à sua distribuição no espaço. Mais ainda, o conhecimento da evolução da demanda no tempo e a sua localização espacial permitem a avaliação de inúmeros cenários de gestão da demanda e da oferta, possibilitando, por exemplo, prever em qual região haverá um crescimento maior da primeira no curto, médio e longo prazos. Outros aspectos que devem ser avaliados são a origem, o destino e o volume de deslocamentos que ocorrem em um determinado conjunto de zonas, o que pode ser estimado através de modelos de interação espacial.

Além de sua aplicação direta na fase de Distribuição de Viagens dos modelos sequenciais de previsão de demanda por transportes, os modelos de interação espacial são importantes para

a avaliação de impactos decorrentes de alterações na oferta de diversas infra-estruturas urbanas, tais como a ampliação dos equipamentos de educação e saúde. Neste sentido, Akamine e Silva (2004) realizaram um estudo com o intuito de contribuir para um projeto de pesquisa mais amplo (Lima e Silva, 2000), que visava a estruturação de um Sistema de Apoio à Decisão Espacial (SADE) para gestão integrada dos sistemas de Educação e Saúde de responsabilidade dos municípios. A pesquisa de Akamine e Silva (2004), que tinha por objetivo avaliar o desempenho de modelos de interação espacial construídos com Redes Neurais Artificiais (RNA), foi desenvolvida a partir de dados da Secretaria Municipal de Educação da cidade de São Carlos, referentes aos alunos matriculados em 2000 e 2001 nas Creches (para crianças de 0 a 6 anos) e EMEIs (Escolas Municipais de Educação Infantil, para crianças de 3 a 6 anos).

Seguindo a metodologia apresentada no trabalho de Lima *et al.* (2001), cerca de 16000 endereços foram localizados espacialmente com o auxílio de um SIG (Sistema de Informações Geográficas), caracterizando a distribuição espacial dos alunos de cada escola e creche ao longo do período analisado. Uma vez localizados espacialmente, os dados de demanda foram agregados em zonas, o que permitiu determinar, então, os fluxos entre estas e os pontos de oferta. A partir destas informações, Akamine e Silva (2004) realizaram as etapas de construção e avaliação do desempenho dos modelos de interação espacial usando RNAs, para a estimativa de fluxos futuros. Como observado por Dougherty (1995) e posteriormente por Rodrigue (1997) e Raia Jr. e Silva (2001), a aplicação de modelos de Redes Neurais Artificiais na área de transportes não se limita a esta aplicação, mas esta é, sem dúvida, uma vertente bastante promissora.

O que ficou evidente no trabalho de Akamine e Silva (2004), no entanto, foi a dificuldade para seleção da rede neural a ser utilizada na modelagem, ou seja, aquela que teria melhor desempenho e poder de predição. Tal como muitos outros trabalhos que utilizam Redes Neurais Artificiais para este tipo de modelagem (como os de Brondino, 1999; Raia Jr., 2000; Costa, 2001; e Bocanegra, 2002, todos na área de transportes), os parâmetros de rede são escolhidos pelo usuário e, ainda que se consiga resultados satisfatórios variando-se tais parâmetros, a rede selecionada por ter melhor desempenho não necessariamente representa a melhor solução para o problema que está sendo analisado.

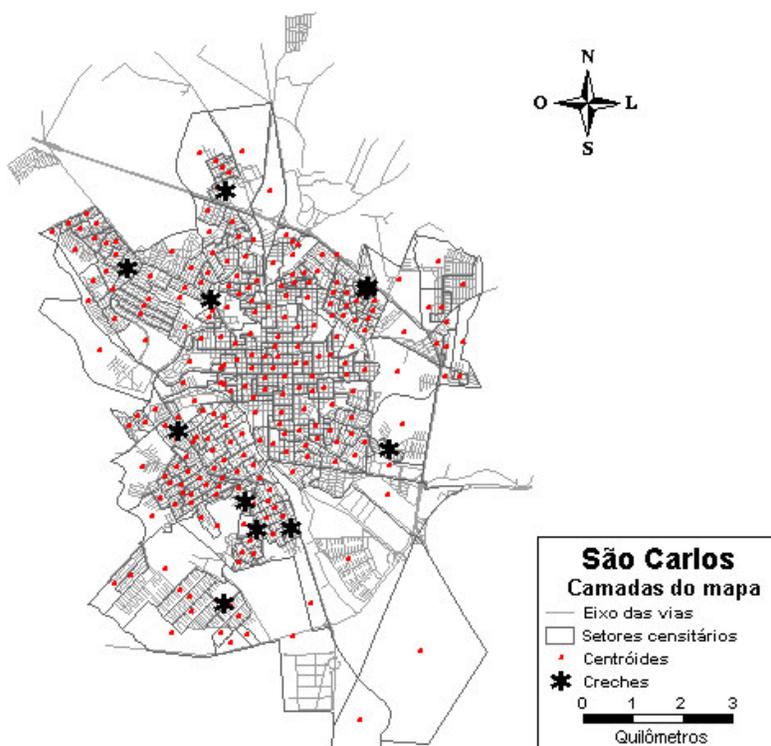
Para superar este problema, Fischer e Reismann (2002) sugerem o uso de procedimentos de busca global na seleção de melhores arquiteturas de rede. Nesta linha, o trabalho aqui apresentado tem por objetivo testar o emprego da técnica de otimização de Algoritmos Genéticos como alternativa para melhoria do desempenho dos modelos neurais de interação espacial. Assim, após esta breve introdução, na seção 2 seguem alguns aspectos relativos aos dados utilizados no presente estudo e à construção dos modelos neurais de interação espacial. O uso de Algoritmos Genéticos como ferramenta de otimização é discutido na seção 3, enquanto que a seção 4 trata da avaliação do desempenho dos modelos propostos. Finalmente, na seção 5, são apresentadas as conclusões do presente estudo, seguindo-se, na seção 6, a bibliografia consultada.

## **2. MODELOS NEURAI DE INTERAÇÃO ESPACIAL**

Para a realização deste estudo foram empregados dados que refletem a evolução espacial da demanda por serviços municipais de educação numa cidade média brasileira (São Carlos, SP) ao longo de dois anos. Foram utilizados o endereço da residência e da unidade escolar

em que estuda cada um dos alunos das Creches municipais nos anos de 2000 e 2001. Os dados das EMEIs não foram aqui considerados por apresentarem um padrão de distribuição espacial mais consistente, como observado por Akamine e Silva (2004) e, portanto, Modelos de Interação Espacial com melhor desempenho de predição (mesmo o tradicional modelo gravitacional).

Como apresentado em Akamine e Silva (2004), tais dados foram localizados espacialmente com o auxílio de um SIG (Sistema de Informações Geográficas) e agregados em zonas, utilizando-se a divisão da área da cidade de São Carlos em 245 setores censitários adotada pelo IBGE no ano 2000. Em seguida, foram calculados os valores de atração dos pontos de oferta (dados pelo número de vagas existentes por unidade escolar), o total de viagens produzidas em cada zona e as distâncias entre as Creches e os centróides dos setores. A Tabela 1 apresenta um resumo destes dados, enquanto a Figura 1 representa a localização dos pontos de demanda e oferta.



**Figura 1:** Pontos de demanda (centróides) e oferta (Creches municipais)

**Tabela 1:** Resumo quantitativo dos dados utilizados nos modelos de interação espacial

<i>Unidades</i>	<i>Ano</i>	<i>Pontos de oferta</i>	<i>Pontos de demanda</i>	<i>Pares O/D</i>
Creches	2000	10	245	2450
	2001	11	245	2695

Em seguida, para a construção dos modelos de redes neurais, com três nós de entrada (total de viagens produzidas, total de viagens atraídas e distâncias) e um de saída (fluxos), os conjuntos de dados do ano 2000 foram divididos de forma aleatória em três subconjuntos: o primeiro para treinamento da rede (50% do total de dados), o segundo para validação (25% do total de dados) e o terceiro para teste (25% do total de dados). Posteriormente, todos os dados foram utilizados para estimar os fluxos futuros a partir de pontos conhecidos de origem e destino. Estes foram, então, comparados aos fluxos reais observados no ano de 2001, testando a capacidade de generalização dos modelos. Tal procedimento foi repetido 3 vezes, com os dados em diferentes ordens aleatórias e, portanto, com diferentes subconjuntos de treinamento, validação e teste.

Na etapa de construção e teste das redes neurais artificiais foi utilizado o *software EasyNN-plus v.1.0*. A estrutura de rede empregada pelo *EasyNN-plus* é a *Multilayer Perceptron*, o algoritmo utilizado no seu aprendizado, o *backpropagation*, e a função para se construir os modelos analisados é a sigmóide logística. Para este estudo, foram consideradas apenas redes com uma camada intermediária, variando-se os valores de taxa de aprendizagem (L), *momentum* (M) e número de nós da camada intermediária. Posteriormente, conhecidos os dados observados e estimados, pôde-se calcular os valores de erro relativo médio por conjunto, segundo a Equação 1:

$$ERM = \frac{1}{n} \sum_{i=1}^n \frac{abs(observado_i - estimado_i)}{observado_i} \quad (1)$$

### 3. ALGORITMOS GENÉTICOS

Os algoritmos genéticos, AGs, são algoritmos de busca estocástica e otimização global que seguem o princípio da seleção natural e sobrevivência do mais apto (Gen *et al.*, 1999), declarado, em 1859, pelo naturalista e fisiologista inglês Charles Darwin em seu livro *A Origem das Espécies*. De acordo com Charles Darwin, “quanto melhor um indivíduo se adaptar ao seu meio ambiente, maior será sua chance de sobreviver e gerar descendentes” (Torres, 2003).

Assim, os AGs fazem parte de um grupo de sistemas que se baseiam nos princípios da evolução e da hereditariedade. A *população inicial* representa as possíveis soluções do problema e cada componente ou *indivíduo* dessa população é chamado de *cromossomo*. Cada *cromossomo* é composto por *cadeias de genes* e cada *gene* é composto por um ou mais *alelos*, que dão valor aos genes (Bielli *et al.*, 2002). O valor do alelo pode variar, sendo geralmente utilizada a representação binária e, nesse caso, a variação é 0 ou 1. Cada indivíduo humano carrega consigo um certo número de cromossomos, no entanto o funcionamento dos AGs considera apenas um cromossomo por indivíduo, ou seja, *cromossomos haplóides* (Michalewicz, 1995).

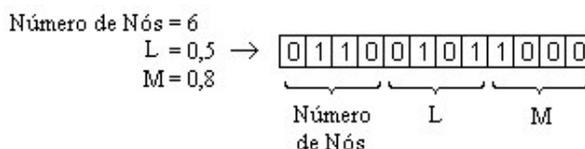
Segundo Torres (2003), o método de trabalho do algoritmo genético é considerado muito simples por envolver nada mais do que um processo de cópias de cadeias (*string*) ou permuta de parte dessas cadeias (cromossomos) que formam a população. A cada cromossomo é atribuída uma *aptidão*, que é uma nota que mede quão boa é a solução codificada para um determinado cromossomo (Lacerda e Carvalho, 1999). A aptidão de cada

cromossomo contribui na geração de novas populações que, após sofrer ação dos operadores genéticos de *seleção*, *cruzamento* e *mutação*, respectivamente, levarão à melhor população.

Ainda segundo Torres (2003), os algoritmos genéticos empregam uma estratégia de busca paralela e estruturada, mas aleatória, que é voltada em direção ao reforço da busca de pontos de alta aptidão, ou seja, pontos nos quais a função a ser minimizada (ou maximizada, dependendo do caso) tem valores relativamente baixos (ou altos). Apesar de aleatórias, as buscas não são caminhadas não direcionadas, pois exploram informações históricas para encontrar novos pontos de busca onde são esperados melhores desempenhos. Isto é feito através de processos iterativos, em que cada iteração é chamada de *geração*.

### 3.1. Desenvolvimento do algoritmo para seleção de redes neurais

No estudo aqui apresentado, o primeiro passo para o desenvolvimento do algoritmo genético foi a geração da população de cromossomos. Neste caso, cada cromossomo representa uma rede neural testada, ou seja, cada cromossomo contém, em notação binária, os possíveis valores de taxa de aprendizado (L), *momentum* (M) e número de nós na camada intermediária, como ilustrado na Figura 2. A Tabela 2 mostra, como exemplo, os valores desta etapa do estudo.



**Figura 2:** Representação binária dos parâmetros de uma rede neural

**Tabela 2:** População inicial de cromossomos para seleção de modelos neurais de interação espacial

Posição	Rede Neural			Cromossomo			Função Objetivo	Aptidão	Aptidão Acumulada
	Nós	L	M	Nós	L	M	ERM	$f_i$	
1	6	0,5	0,8	0110	0101	1000	0,1378	2,0000	2,0000
2	13	0,5	0,8	1101	0101	1000	0,1409	1,8571	3,8571
3	5	0,5	0,8	0101	0101	1000	0,1425	1,7143	5,5714
4	4	0,5	0,8	0100	0101	1000	0,1425	1,5714	7,1429
5	13	0,6	0,6	1101	0110	0110	0,1426	1,4286	8,5714
6	5	0,6	0,6	0101	0110	0110	0,1462	1,2857	9,8571
7	3	0,5	0,8	0011	0101	1000	0,1467	1,1429	11,0000
8	13	0,3	0,4	1101	0011	0100	0,1490	1,0000	12,0000
9	5	0,3	0,4	0101	0011	0100	0,1537	0,8571	12,8571
10	6	0,6	0,6	0110	0110	0110	0,1541	0,7143	13,5714
11	4	0,6	0,6	0100	0110	0110	0,1578	0,5714	14,1429
12	6	0,3	0,4	0110	0011	0100	0,1645	0,4286	14,5714
13	3	0,6	0,6	0011	0110	0110	0,1645	0,2857	14,8571
14	3	0,3	0,4	0011	0011	0100	0,1653	0,1429	15,0000
15	4	0,3	0,4	0100	0011	0100	0,1689	0,0000	15,0000

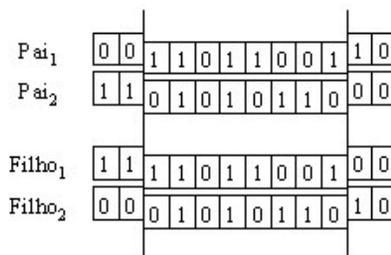
Adotando-se o erro relativo médio de cada modelo neural como sendo a função a ser minimizada, ordenou-se a população de cromossomos segundo os valores de ERM, de forma decrescente. Em seguida, construiu-se uma coluna de aptidão normalizando os valores da função objetivo no intervalo de 0 a 2, de forma que ao maior valor foi atribuída aptidão igual a 2 e, ao menor valor, aptidão igual a 0.

Uma vez determinado o valor da aptidão de cada cromossomo, determinou-se uma coluna de aptidão acumulada para iniciar o procedimento de seleção. Nesta fase, gerou-se um número aleatório  $r$  no intervalo  $[0, \text{somatotal}]$ , em que **somatotal** é a soma de todas as aptidões. Por fim, o cromossomo selecionado foi o primeiro (segundo a tabela de cima para baixo) com aptidão acumulada maior que  $r$  e sua cópia foi alocada na população intermediária. Os mesmos passos foram então repetidos até o preenchimento da população intermediária com  $N$  cromossomos. Observa-se neste processo de seleção, conhecido como Roda da Roleta, que quanto maior a aptidão de um cromossomo, maior o intervalo de aptidão acumulada entre ele e o próximo cromossomo e, portanto, maior a probabilidade de passar para as etapas seguintes.

Como é interessante que o melhor indivíduo passe de uma geração a outra sem alterações, fez-se uso de uma estratégia bastante utilizada nos AGs tradicionais, conhecida por elitismo. Seguindo esta estratégia, o cromossomo de maior aptidão foi imediatamente alocado na população seguinte, sem sofrer nenhum tipo de alteração.

Após a conclusão da etapa de seleção, aplicou-se os operadores de cruzamento e mutação. Tais operadores são utilizados para assegurar a diversidade da população, ou seja, a geração é nova, mas mantém características de adaptação adquiridas pelas gerações anteriores. As etapas de cruzamento e mutação são os principais mecanismos de busca dos AGs para explorar regiões desconhecidas do espaço de busca.

O operador de cruzamento foi aplicado aos cromossomos da população intermediária, separados aleatoriamente aos pares, gerando os cromossomos filhos. Neste trabalho, optou-se pelo cruzamento de 2 pontos, por ser o mais utilizado na literatura, segundo Lacerda e Carvalho (1999). Como ilustrado na Figura 3, cada um dos cromossomos pais foi partido em 2 pontos aleatórios, chamados pontos de corte, permutando-se as partes limitadas pelos cortes.



**Figura 3:** Cruzamento de 2 pontos

Após a operação de cruzamento entre os cromossomos, iniciou-se o processo de mutação, que consistiu na inversão dos valores de alguns bits (0,1 a 5%) do número total de bits da

população. O operador de mutação é praticamente uma caminhada direta randômica pelos componentes de uma estrutura escolhida entre os descendentes que, dessa forma, garante a possibilidade de exploração de todo o espaço de busca independentemente da população inicial (Bielli *et al.*, 2002). Segundo Lacerda e Carvalho (1999), utiliza-se uma taxa de mutação pequena para evitar a destruição das informações contidas no cromossomo, porém suficiente para assegurar a diversidade.

#### 4. AVALIAÇÃO DO DESEMPENHO DOS MODELOS

Nesta seção é avaliado o desempenho dos modelos neurais de interação espacial selecionados através de algoritmos genéticos. Para a montagem das redes da população inicial, optou-se por utilizar diversas redes com uma camada escondida, partindo-se dos parâmetros iniciais (L, M e número de nós na camada intermediária) usados pelo *software EasyNN-plus*, tendo como base os dados do ano 2000. Estes foram também utilizados para a estimativa dos fluxos do ano 2001 pelo método gravitacional duplamente restringido. O diagrama da Figura 4 apresenta os valores de erro relativo médio (E) e desvio padrão (DP) das redes testadas na população inicial, bem como o resultado obtido através do método gravitacional. Pela análise do diagrama pode-se perceber que a melhor estimativa foi obtida pelo Método Gravitacional.

Topologia 3-6-1	L = 0,6	M = 0,6	E = 0,1541	DP = 0,0191
	L = 0,3	M = 0,4	E = 0,1645	DP = 0,0186
	L = 0,5	M = 0,8	E = 0,1378	DP = 0,0085
Topologia 3-3-1	L = 0,6	M = 0,6	E = 0,1645	DP = 0,0091
	L = 0,3	M = 0,4	E = 0,1653	DP = 0,0175
	L = 0,5	M = 0,8	E = 0,1467	DP = 0,0126
Topologia 3-4-1	L = 0,6	M = 0,6	E = 0,1578	DP = 0,0136
	L = 0,3	M = 0,4	E = 0,1689	DP = 0,0155
	L = 0,5	M = 0,8	E = 0,1425	DP = 0,0119
Topologia 3-5-1	L = 0,6	M = 0,6	E = 0,1462	DP = 0,0052
	L = 0,3	M = 0,4	E = 0,1537	DP = 0,0099
	L = 0,5	M = 0,8	E = 0,1425	DP = 0,0101
Topologia 3-13-1	L = 0,6	M = 0,6	E = 0,1426	DP = 0,0098
	L = 0,3	M = 0,4	E = 0,1490	DP = 0,0063
	L = 0,5	M = 0,8	E = 0,1409	DP = 0,0044
Método Gravitacional			E = 0,1353	

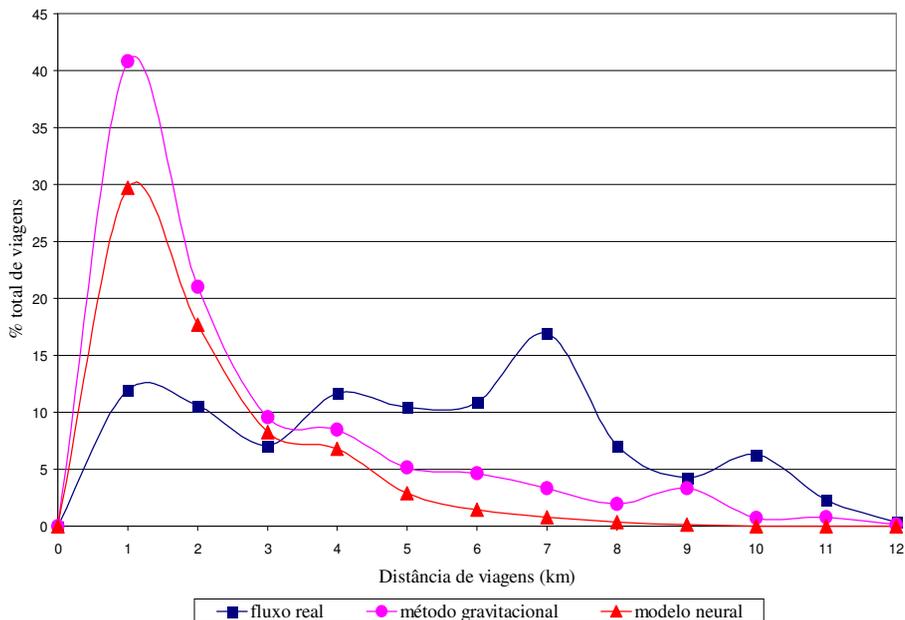
**Figura 4:** Desempenho das RNAs testadas com dados das Creches

A técnica de otimização de Algoritmos Genéticos foi aplicada nas redes testadas nesta primeira geração de modelos, tendo como resultados, os valores apresentados na Tabela 3. Como exposto na tabela, os modelos neurais mostraram melhores desempenhos a cada iteração, superando o modelo gravitacional, em termos de ERM, a partir da segunda geração.

Neste estudo, o melhor resultado (ERM = 0,1333 e DP = 0,0084) foi obtido a partir da rede com 4 nós na camada intermediária, L = 0,7 e M = 0,9, gerada na quarta iteração.

**Tabela 3:** ERM dos modelos neurais de interação espacial selecionados através de AGs

Posição	1ª geração	2ª geração	3ª geração	4ª geração	5ª geração
1	0,1378	0,1341	0,1341	0,1333	0,1333
2	0,1409	0,1378	0,1360	0,1341	0,1341
3	0,1425	0,1410	0,1368	0,1341	0,1341
4	0,1425	0,1425	0,1378	0,1360	0,1341
5	0,1426	0,1425	0,1389	0,1378	0,1360
6	0,1462	0,1425	0,1410	0,1389	0,1368
7	0,1467	0,1425	0,1424	0,1391	0,1371
8	0,1490	0,1425	0,1425	0,1396	0,1378
9	0,1537	0,1425	0,1425	0,1396	0,1389
10	0,1541	0,1425	0,1425	0,1396	0,1392
11	0,1578	0,1468	0,1468	0,1421	0,1396
12	0,1645	0,1494	0,1468	0,1421	0,1407
13	0,1645	0,1530	0,1474	0,1421	0,1407
14	0,1653	0,1541	0,1474	0,1427	0,1425
15	0,1689	0,1645	0,1539	0,1474	0,1532



**Figura 5:** Frequência de distribuição de distâncias de viagens

Para comparação dos resultados, além da análise dos valores constantes no diagrama da Figura 4, foi traçado o gráfico da Figura 5 para mostrar a frequência de distribuição de distâncias de viagens. O eixo das ordenadas representa a porcentagem do total de viagens em estudo e o eixo das abscissas representa os intervalos de distância. Pela análise do gráfico – e como observado por Akamine e Silva (2004) – fica evidente que no caso dos dados das Creches, a localização da residência dos alunos pode não estar interferindo na escolha da instituição de ensino, pois o maior número de viagens não ocorre para distâncias curtas. Tal fato pode tornar os modelos deficientes, uma vez que, além do total de viagens produzidas e atraídas, apenas as distâncias entre os pontos de demanda e oferta estão sendo utilizadas como parâmetros. Em ambos os modelos, a maior porcentagem de viagens foi estimada para distâncias de 0 a 2 quilômetros.

## 5. CONCLUSÕES

Como observado por Akamine e Silva (2004), a utilização de modelos neurais de interação espacial tem se mostrado bastante promissora para uso prático, possibilitando, no caso de serviços municipais de educação, a modelagem da demanda por Creches considerando variações no tempo e na sua localização espacial. O bom desempenho de tais previsões é, no entanto, crucial para a avaliação de inúmeros cenários de gestão da demanda e da oferta, buscando, por exemplo, a redução da distância percorrida pelos alunos até as escolas existentes através da realocação da demanda à oferta, ou o melhor local para a abertura de novas unidades de ensino, com o intuito de reduzir as distâncias de deslocamento dos alunos às escolas.

Ainda segundo Akamine e Silva (2004), uma possível maneira de se obter melhores estimativas a partir dos dados das Creches seria a utilização de outros parâmetros (além da localização e as distâncias, daí resultantes, entre pontos de oferta e demanda) que influam diretamente na escolha das instituições de ensino, o que do ponto de vista prático, nem sempre é fácil de se obter (Almeida e Gonçalves, 2001). Outra alternativa seria a aplicação de técnicas de otimização como os Algoritmos Genéticos e o método de divisão de dados *bootstrapping*, sugerido por Fischer e Reismann (2002), na construção dos modelos neurais de interação espacial.

O presente estudo tratou da aplicação da técnica de otimização de Algoritmos Genéticos na seleção de redes neurais artificiais. A análise comparativa entre os resultados do modelo gravitacional e dos modelos neurais mostrou a superioridade destes, no que diz respeito à estimativa de fluxos, após a utilização dos AGs. Os AGs apresentaram-se, portanto, bastante eficientes no caso dos modelos neurais de interação espacial, sendo capazes de selecionar melhores configurações de redes neurais a cada iteração. O que é importante, neste caso, para tornar o seu uso de fato viável em aplicações práticas, é desenvolver um conjunto de rotinas ou mesmo programas de computador que tornem a seleção da melhor rede através dos AGs um procedimento rápido e direto, o que ainda não ocorre.

### Agradecimentos

Os autores agradecem ao SAAE – Serviço Autônomo de Água e Esgoto de São Carlos – e à Secretaria Municipal de Educação, pelo fornecimento dos dados que viabilizaram esse projeto, e à FAPESP – Fundação de Amparo à Pesquisa do Estado de São Paulo – pelo apoio financeiro oferecido ao projeto de pesquisa que deu origem a esse trabalho.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Akamine, A. e A. N. R. Silva (2004) An evaluation of neural spatial interaction models based on a practical application. In: Van Leeuwen, J. P. e H. J. P. Timmermans (eds.) *Recent Advances in Design and Decision Support Systems in Architecture and Urban Planning*, p. 19-32.
- Almeida, L. M. W. e M. B. Gonçalves (2001) A methodology to incorporate behavioral aspects in trip-distribution models with an application to estimate student flow. In: *Environment and Planning A*, v. 33, p. 1125-1138.
- Bielli, M., M. Caramia e P. Carotenuto (2002) Genetic algorithms in bus network. In: *Transportation Research Part C*, v. 10, p. 19-34.
- Bocanegra, C. W. R. (2002) *Procedimentos para Tornar Mais Efetivo o Uso das Redes Neurais Artificiais em Planejamento de Transportes*. Dissertação (Mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo. 97 p.
- Brondino, N. C. M. (1999) *Estudo da Influência da Acessibilidade no Valor de Lotes Urbanos Através do Uso de Redes Neurais*. Tese (Doutorado). Escola de Engenharia de São Carlos, Universidade de São Paulo. 146 p.
- Costa, G. C. F. (2001) *Uma Avaliação do Consumo de Energia com Transportes em Cidades do Estado de São Paulo*. Dissertação (Mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo. 103 p.
- Dougherty, M. (1995) A review of neural networks applied to transport. In: *Transportation Research C*, v. 3, n. 4, p. 247-260.
- Dutra, N. G. S. (1998) *Planejando uma rede escolar municipal para reduzir custos de deslocamentos*. Dissertação (Mestrado), Escola de Engenharia de São Carlos, Universidade de São Paulo. 94 p.
- Fischer, M. M. e M. Reisman (2002) A methodology for neural spatial interaction modeling. In: *Geographical Analysis*, v. 34, n. 3.
- Gen, M., Y. Li e K. Ida (1999) Solving multi-objective transportation problem by spanning tree-based genetic algorithm. In: *IEICE Transportation Fundamental*, v. E82-A.
- Lacerda, E. G. M. e A. C. P. L. F. Carvalho (1999) Introdução aos algoritmos genéticos. In: *Galvão, C. O. e Valença, M. J. S. (orgs) Sistemas inteligentes: aplicações a recursos hídricos e sistemas ambientais*, Ed. Universidade, UFRGS, Porto Alegre.
- Lima, R. S., M. K. Naruo, R. J. Rorato e A. N. R. Silva (2001) Influência da desagregação espacial da demanda por educação no cálculo das distâncias de deslocamento em uma cidade média. In: *Congresso Brasileiro de Cartografia, 20, Conferência Ibero-Americano de SIG, 8*, Porto Alegre, 2001. Anais... (em CD-ROM). Rio de Janeiro, Sociedade Brasileira de Cartografia.
- Lima, R. S. e A. N. R. Silva (2000) Um Sistema de Apoio à Decisão para localização de serviços de educação e saúde. In: *Congresso de Pesquisa e Ensino em Transportes, 14*, Gramado, RS, 2001. Anais, v.2, p.107-110.
- Michalewicz, Z. (1995) *Genetic algorithms + Data structures = Evolution Programs*. Springer-Verlag, Berlim.
- Raia Jr., A. A. (2000) *Acessibilidade e Mobilidade na Estimativa de um Índice de Potencial de Viagens Utilizando Redes Neurais Artificiais e Sistemas de Informações Geográficas*. Tese (Doutorado). Escola de Engenharia de São Carlos, Universidade de São Paulo. 196 p.
- Raia Jr., A. A. e A. N. R. Silva (2001) A utilização de redes neurais artificiais na engenharia de transportes: o estado da arte. In: *Congreso Latinoamericano de Transporte Público y Urbano, 11*, Havana - Cuba, 2001. Memórias... (em CD-ROM). Cuba, Asociación de Investigación y Producción del Transporte – GRUPO IT.
- Rodrigue, J. P. (1997) Parallel modelling and neural networks: an overview for transportation/land use systems. In: *Transportation Research C*, v. 5, n. 5, p. 259-271.
- Torres, A. C. S. T. (2003) *Determinação de rotas ótimas de ônibus urbano utilizando algoritmo genético*. Dissertação (Mestrado). Faculdade de Tecnologia, Universidade de Brasília. 87 p.