

MODELO NEURO-GEO-ESPACIAL PARA PREVISÃO DA DEMANDA DE VIAGENS NO CONTEXTO DO PLANEJAMENTO ESTRATÉGICO

André Dantas
Koshi Yamamoto

Departamento de Engenharia Civil - Instituto Tecnológico de Nagoya – Japão

Marcus Vinicius Lamar

Departamento de Engenharia Elétrica e Computação – Instituto Tecnológico de Nagoya – Japão

Yaeko Yamashita

Mestrado em Transportes – Universidade de Brasília - Brasil

RESUMO

Um modelo para o planejamento estratégico do transporte urbano é apresentado. Esse modelo é baseado na incorporação e representação da interação entre o uso do solo e o sistema de transportes sob uma abordagem espacial buscando a previsão da demanda de viagens em áreas urbanas. A concepção do modelo torna-se possível devido à integração das Redes Neurais (RN), dos Sistemas de Informação Geográfica (SIG) e Sensoriamento Remoto (SR). Um estudo de caso na área metropolitana de Boston foi realizado visando a verificação da eficiência do modelo e avaliar a melhor estrutura de RN e as mudanças nas camadas ocultas e de saída. Foi alcançada uma taxa de reconhecimento de 94% que expressa uma correta definição da RN. Tal fato indica que a integração das técnicas utilizadas no modelo também foi apropriada.

ABSTRACT

A strategic planning model for urban transportation analysis is presented. This model is based on the incorporation and representation of the land use-transportation system interaction under a spatial approach to forecast travel demand within urban areas. This conception becomes possible due to the integration of Neural Networks (NN), Geographical Information Systems (GIS) and Remote Sensing (RS). A case study in Boston Metropolitan Area was conducted to verify the efficiency of the model and evaluate the best NN structure and also changes in the hidden and output layers were simulated. A recognition rate of 94% was reached expressing the successful definition of the NN. It also does mean that the integration of techniques used in this model is appropriated.

1. INTRODUÇÃO

Recentemente, têm sido observadas mudanças no planejamento do transporte urbano em direção a uma abordagem estratégica. Após longo período, predominantemente voltado para a avaliação de congestionamentos e a construção e dimensionamento do sistema viário, os órgãos de planejamento têm direcionado suas atividades para o desenvolvimento de estratégias de longo prazo que permitam estabelecer sistemas de transporte melhor integrados através da utilização de recursos tecnológicos como os Sistemas Inteligentes (Lógica Fuzzy, redes neurais, algoritmo genéticos) (DOT, 1997). Como resultado dessas mudanças, as técnicas de modelagem no contexto do planejamento estratégico tendem a assumir um papel complementar, dedicando-se a prover informações adicionais para o planejamento. Segundo Ng (1993), uma vez que a abordagem estratégica é baseada na discussão e diálogo entre atores internos e externos, o trabalho analítico não assume importância fundamental como é verificado no planejamento tradicional. Nesse sentido, estratégias são formuladas e avaliadas considerando cenários e alternativas múltiplas visando obter o melhor aproveitamento dos recursos existentes.

Todavia, no planejamento estratégico em transportes, as técnicas de modelagem têm sido aplicadas num contexto operacional. Conforme relata Meyer (1983), existiram algumas

iniciativas de planejamento estratégico, mas segundo Tyndall *et al.* (1990) poucas foram aquelas realmente implantadas. Essa situação pode ser melhor entendida ao se analisar a natureza e o conceito da modelagem tradicional no planejamento de transportes. Originariamente desenvolvidas para a avaliação de problemas de rede de transportes utilizando dados sócio-econômicos e níveis de agregação para microanálises, os modelos são incapazes de representar o ambiente urbano através de um conjunto de leis e equações matemáticas devido à complexidade e à natureza caótica associada ao ambiente urbano (Openshaw e Openshaw, 1997) requeridos numa abordagem estratégica. Ademais, tais modelos têm sido criticados por envolver significativos custos e coletas extensivas de dados, que praticamente inviabilizam a aplicação em casos reais (Harris, 1996). Por outro lado, pode-se identificar um grande potencial na aplicação de processadores de alta performance associada a técnicas computacionais mais sofisticadas, que permitem a combinação do conhecimento e ferramentas de análise para a resolução dos complexos sistemas do mundo real (Jang *et al.*, 1997).

Neste trabalho apresenta-se o Modelo Neuro-Geo-Espacial (MNGE) especificamente dedicado ao planejamento estratégico com vistas a gerar informações acerca da demanda de viagens em áreas urbanas. Tais informações são quantificadas em forma de variáveis linguísticas como alto, médio, baixo, etc., que expressam a intensidade dos movimentos realizados diariamente. A partir desses níveis de demanda, torna-se possível a participação e discussão entre os atores no planejamento de transportes e a formulação de estratégias futuras. Por outro lado, o MNGE busca incorporar a dinâmica urbana como o fator principal afetando a demanda de viagens. Tal incorporação é conduzida através da modelagem não-linear por meio da utilização de RN, que permite analisar as complexas interações entre o uso do solo e o sistema de transportes. Essas interações são quantificadas através de dados obtidos a partir de imagens de SR em um ambiente computacional SIG.

Este artigo é organizado em cinco itens. Após esta introdução, o item dois descreve brevemente o papel do MNGE no contexto do planejamento estratégico, visando definir a relevância e a estrutura de integração do modelo. Em seguida, concentra-se na descrição da formulação do MNGE. No item quatro, o estudo de caso conduzido na área metropolitana de Boston, Estados Unidos é apresentado. Finalmente, no item cinco, discute-se sobre os principais pontos desenvolvidos nesta pesquisa e as perspectivas futuras para a melhoria do modelo.

2. MNGE NO CONTEXTO DO PLANEJAMENTO ESTRATÉGICO

Especificamente em relação às atividades de um típico processo de planejamento estratégico, Ng (1993) define a existência de cinco passos básicos, conforme apresentado na Figura 1. Inicialmente, deve-se detectar as condições do ambiente em que o planejamento será aplicado e identificar os motivos, participantes, compromissos de tempo e a organização apropriada da estrutura de planejamento. Em seguida, buscando identificar dificuldades (barreiras) à concretização das perspectivas futuras, tópicos estratégicos devem ser estabelecidos. O terceiro passo refere-se ao desenvolvimento de estratégias através da utilização dos esforços no sentido de ultrapassar as dificuldades identificadas anteriormente. Em seguida é realizada uma avaliação comparativa das alternativas que são classificadas de acordo com os critérios de aceitabilidade. Finalmente, no passo da implementação discute-se sobre possíveis barreiras

à concretização do planejamento e tópicos específicos relacionados à real condição de implantação.

Ao longo deste processo, o conhecimento, que foi gerado a partir de informações previamente obtidas, configura-se como um elemento essencial. Conforme apontado por Schaefer (1980), através dessas informações, que são os elementos dinâmicos interagindo com os estágios do processo de planejamento estratégico, decisões estratégicas podem ser melhoradas. No planejamento do transporte urbano, tais informações são relacionadas com a complexidade do ambiente urbano através da realidade espacial na qual complexas interações ocorrem diariamente e conseqüentemente devem ser cuidadosamente incorporadas.

Neste contexto, o MNGE pretende incorporar informações acerca dos movimentos urbanos na estrutura de planejamento estratégico. Conforme apresentado na Figura 1, o modelo está conectado às fases de: Identificação de tópicos estratégicos, Definição de opções estratégicas e a Avaliação de alternativas. Nessas fases, espera-se que os planejadores de transporte obtenham o conhecimento básico acerca dos movimentos diários, assim como do processo evolutivo (condições passadas) e das perspectivas futuras. Nesse sentido, o MNGE configura-se como um instrumento a ser utilizado, principalmente, para garantir aos planejadores e aos demais atores envolvidos no processo de planejamento a correta noção de como, quando e onde o sistema de transporte deve ser reorganizado e/ou melhorado. Essa noção será obtida através da previsão da demanda de viagens baseando-se em avaliações qualitativas dos movimentos.

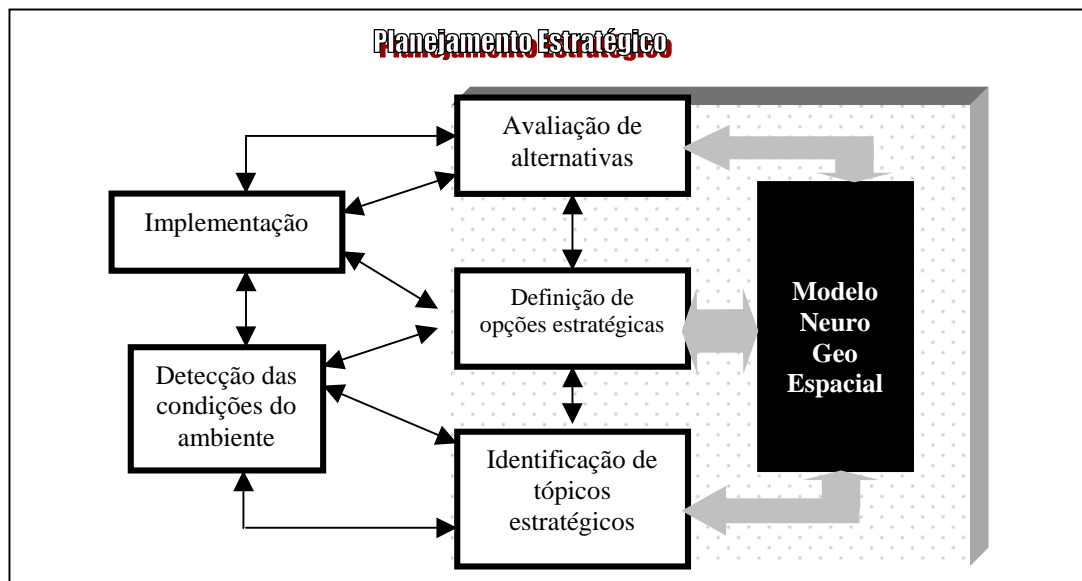


Figura 1: Integrando o MNGE à estrutura básica do planejamento estratégico
Adaptado de Ng (1993)

3. A FORMULAÇÃO DO MNGE

Considerando a estrutura de integração proposta no item 2, a formulação do MNGE concentra-se na incorporação da dinâmica urbana afetando a previsão da demanda de viagens, através do estabelecimento de avaliações em um nível macroscópico de análise e o desenvolvimento de uma estrutura de modelagem eficiente com poucos requerimentos de dados. Assim, o modelo é baseado em trabalhos anteriores de Rodrigue (1997) e Taco *et al.*

(1998). O primeiro apresentou um conceito teórico inovador para a previsão do uso do solo – transportes considerando a estrutura econômica, população, acessibilidade e a interações espaciais fazendo uso de RN. Todavia, pode-se verificar que esse conceito está baseado principalmente em dados sócio-econômicos e correlacionado ao planejamento urbano como um todo, ou seja, não especificamente voltado para análises de transportes. Por outro lado Taco *et al.* (1998) elaborou e aplicou um modelo de geração de viagens contemplando padrões de uso do solo extraídos de fotografias aéreas através do uso do SR e do SIG. Entretanto, o modelo não permite a avaliação de mudanças dinâmicas e da interação entre os padrões e limitado à fase da geração de viagens.

Na concepção do MNGE, tais abordagens são reunidas visando o estabelecimento de um modelo de previsão da demanda de viagens integrando RN, SIG e SR. Assim, partindo do processamento de imagens de SR num ambiente SIG, obtêm-se indicadores relacionados às interações entre uso do solo e sistema de transporte tais como as áreas dos padrões de uso do solo, as extensões dos modos de transportes e a separação espacial. Partindo desses dados, a RN é usada para prever as viagens dentro das áreas urbanas.

Considera-se, então, uma área urbana onde pessoas realizam deslocamentos de um lugar para outro buscando participar em atividades sócio-econômicas (Khisty, 1990). Estas atividades são representadas pelos padrões de uso do solo que ocupam a superfície terrestre e apresentam diversas separações espaciais. Por outro lado, o sistema de transporte atua no suprimento de infra-estrutura necessária para os deslocamentos e como um elemento indutor do desenvolvimento dos padrões de uso do solo. A interação entre os padrões de uso do solo pode ser realizada (Handy, 1996) através do uso do sistema de transportes (ruas, rodovias, linhas de ônibus, metrô, trem, etc.). Assim, mudanças na acessibilidade afetam diretamente o valor da terra e conseqüentemente devem afetar a forma como o uso do solo é desenvolvido. Em uma perspectiva temporal, se tais mudanças ocorrem, então as viagens serão diretamente afetadas em termos de intensidade e distribuição.

Baseando-se nessas premissas básicas, assume-se que a área ocupada e a extensão de cada modo podem ser utilizadas para quantificar os padrões de uso do solo e os sistemas de transporte, respectivamente. Então, seja uma área urbana dividida em Setores Agregados Homogêneos (SAH), conforme definição de Taco *et al.* (1998), viagens (T_{ij}) entre um par de SAH são observados, onde i e j denotam a origem e o destino, respectivamente. O uso do solo é representado pela área ocupada (metros quadrados) de cada padrão em um SAH, que é designado como rlu_{SAH} (uso do solo residencial), clu_{SAH} (uso do solo comercial) e slu_{SAH} (uso do solo serviço). O sistema de transporte é caracterizado pela extensão de cada modo (metros) em cada SAH, que são associados a rts_{SAH} (sistema de transporte rodoviário, ruas, avenidas, etc.), bts_{SAH} (sistema de transporte por ônibus), sts_{SAH} (sistema de transporte por metrô) e tts_{SAH} (sistema de transporte por trem). Adicionalmente, utiliza-se a distância entre um par de SAH como índice de separação espacial.

Em uma RN do tipo *Feedforward Multilayer Perceptron*, os vetores de entrada e saída devem ser estabelecidos conforme definido por Wasserman (1989). Assim, o vetor de entrada X é definido como:

$$x_{ij}=(rlu_i, clu_i, slu_i, rts_i, bts_i, sts_i, tts_i, rlu_j, clu_j, slu_j, rts_j, bts_j, sts_j, tts_j, d_{ij}) \quad (1)$$

Especificamente para o planejamento estratégico, a RN é definida como um classificador de padrões, onde a saída final do modelo gera a previsão da demanda de viagens em classes tais como alta, média-alta, média, média-baixa e baixa. Inicialmente, define-se o número de classes N , que deve ser estabelecido de acordo com o nível de detalhamento necessário. Em seguida passa-se a definição da amplitude r das classes, que é obtida através da equação 2.

$$r = \frac{(T_{ij}^{max} - T_{ij}^{min})}{N} \quad (2)$$

onde T_{ij}^{max} e T_{ij}^{min} são, respectivamente, os valores máximos e mínimos da matriz T de viagens. Dessa forma, cada classe k possui limites superiores (α_k) e inferiores (β_k) de acordo com a amplitude r , que são definidos pelas equações 3 e 4 a seguir:

$$\alpha_k = T_{ij}^{min} + (k-1) \cdot r \quad (3)$$

$$\beta_k = \alpha_k + r \quad (4)$$

Em seguida, classifica-se cada T_{ij} da saída das seqüências de treino e teste considerando os limites para cada uma das classes k . Obtêm-se o vetor $Y (y_1, y_2, \dots, y_N)$ referente às unidades de saída, conforme descrito na equação 5.

$$y_k = \begin{cases} 1.0, & \alpha_k \leq T_{ij} < \beta_k \\ 0.0, & \text{outros} \end{cases} \quad \text{onde } k \in (1, 2, \dots, N) \quad (5)$$

Tal procedimento de definição do vetor Y a partir da matriz T consiste em uma quantização linear comumente utilizada em processamento de sinais conforme descrito em Oppenheim e Schaffer (1989) e que se aplica diretamente ao caso do MNGE.

A formulação proposta neste artigo refere-se à previsão espacial, ou seja, sem variações temporais. Obviamente, as variações temporais são essenciais para o desenvolvimento do planejamento estratégico, mas no corrente estágio desta pesquisa busca-se inicialmente avaliar se as variáveis selecionadas e as premissas básicas definidas são adequadas no sentido de representar a interação entre uso do solo, sistema de transporte e demanda de viagens. Nesse sentido, o estudo de caso, a seguir, busca conduzir tais análises.

4. ESTUDO DE CASO

Aplicou-se o MNGE ao estudo da área metropolitana de Boston (Estado de Massachusetts – EUA), que cobre cerca de 3.580 quilômetros quadrados e possuía em 1992 população de 3 milhões de habitantes. A área de estudo selecionada localiza-se na região sul de Boston, próximo ao Boston Medical Center e envolve 17 Zonas de Tráfego (ZT). Assume-se que as ZT s são equivalentes à definição de uma SAH. A área de estudo é principalmente ocupada por padrões de uso do solo residencial e localizada nas proximidades do centro da cidade.

Dados de SR e do sistema de transportes foram obtidos do banco de dados *MassGIS* (<http://www.magnet.state.ma.us/mgis/massgis.htm>). Nesse banco de dados, os dados estão georeferenciados numa projeção chamada Massachusetts State plane Mainland Zone (FIPZONE 2001), Datum NAD83, unidade metros. Utilizou-se orto-fotografias aéreas produzidas em 1992 numa escala 1:5000. Os mapas de rotas de ônibus foram obtidos da

Metropolitan Boston Transportation Authority (MBTA) e incorporados ao banco de dados. Os dados de viagens foram cedidos pelo *Central Transportation Planning Staff* (CTPS), que foram coletados por meio de pesquisa domiciliar realizada em 1990 envolvendo todos os motivos e modos.

A seguir, descreve-se as atividades de construção do banco de dados do SIG, para em seguida apresentar os experimentos e resultados de simulações.

4.1 Banco de dados SIG

Inicialmente, usando um software de SIG, as ZTs foram definidas conforme mostrado na Figura 2. Em seguida, os padrões de uso do solo foram obtidos seguindo o sistema de classificação do *United States Geological Service* (USGS) (Avery e Berlin, 1990) e a metodologia de Taco (Taco *et al.* 1998). Os padrões, apresentados na Figura 3a, foram definidos até o nível II (Residencial, Comercial e Serviços) segundo os requerimentos do MNGE. Seguiu-se, então, a transformação dos dados do sistema de transporte no formato digital do SIG conforme mostra a Figura 3b.

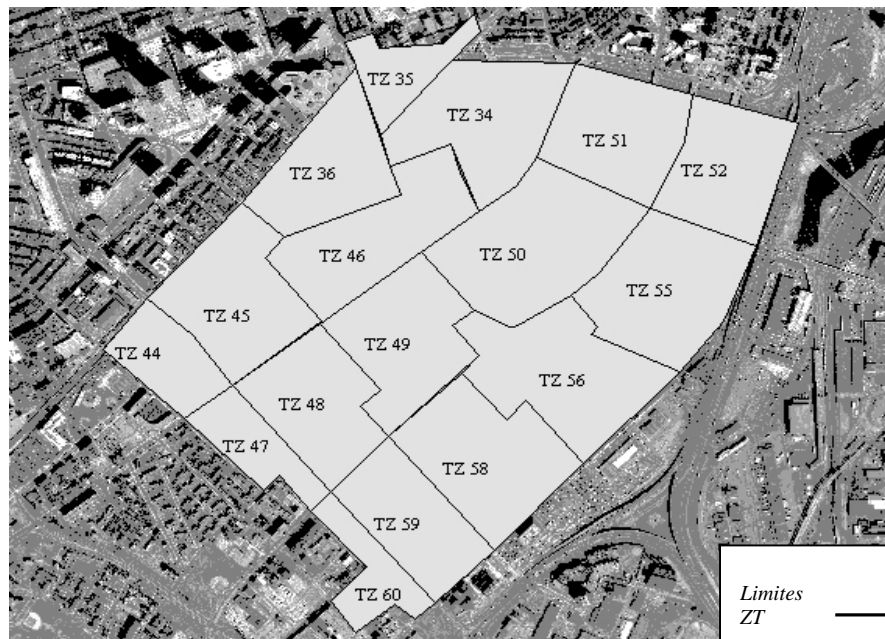


Figura 2: Área de estudo e a definição das ZTs

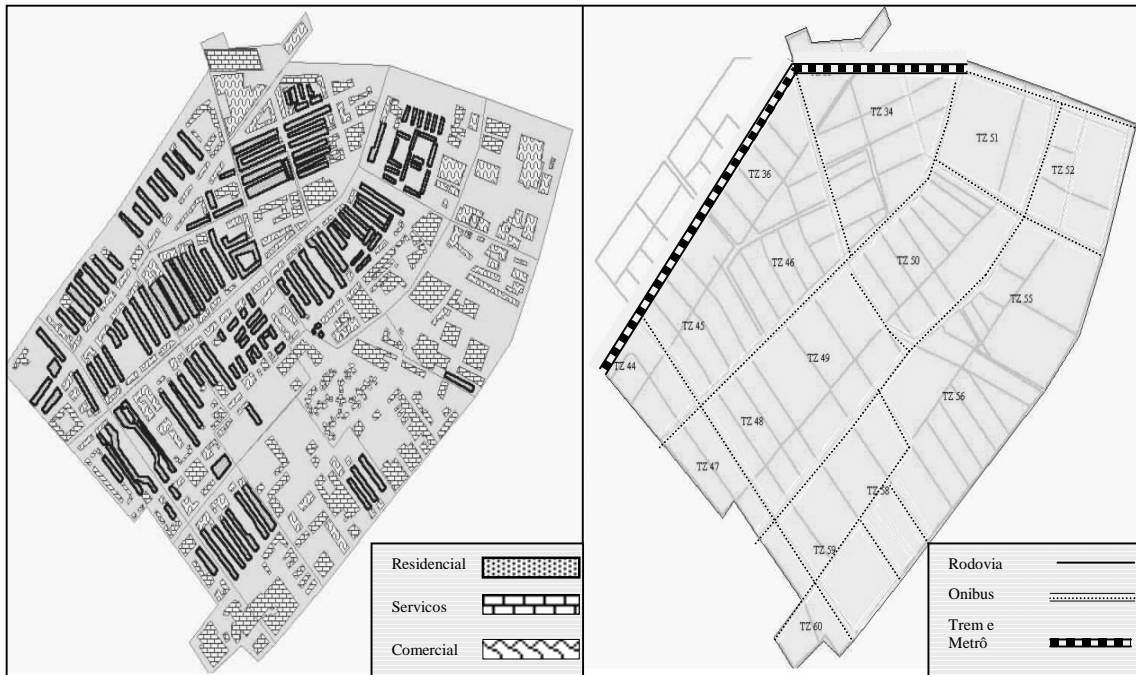


Figura 3: a) Padrões de uso do solo; b) sistema de transporte

4.2 Experimentos e resultados com as simulações da RN

A partir de consultas espaciais na base de dados do SIG, obteve-se um conjunto de dados formado por 289 vetores, incluindo dados do uso do solo, transportes e viagens. O vetor de entrada X foi normalizado aplicando a equação 6. Através dessa normalização, os valores de cada uma das variáveis são mapeados no intervalo entre -1 e 1 , permitindo um processamento da RN mais eficiente.

$$\bar{x}_c = -1 + 2 \left[\frac{(x_c - x_c^{\min})}{(x_c^{\max} - x_c^{\min})} \right] \quad (6)$$

onde x_c , obtido da equação 1, é o valor do vetor de entrada X para a variável c ($c \in \{1, 2, \dots, 15\}$), \bar{x}_c é o valor normalizado, e x_c^{\min} e x_c^{\max} são, respectivamente, os valores mínimo e máximo para a característica c .

Deste conjunto de dados normalizados selecionou-se, aleatoriamente, a seqüência de vetores para treino e teste da RN. A distribuição dos vetores entre as seqüências de treino e teste foi de 75 e 25%, respectivamente. Como definido pela equação 1, a camada de entrada da RN deve ter 15 unidades, enquanto que a camada de saída foi estabelecida com 5 unidades, ou seja, N igual a 5 (alto, médio-alto, médio, médio-baixo e baixo classes de demanda de viagens). Definiu-se r igual 14, já que T_{ij}^{\max} e T_{ij}^{\min} são, respectivamente, iguais a 67 e 0. Em seguida, foram calculados os valores de α_k e β_k para cada classe k que permitiram aplicar a equação 5 e assim obter o vetor valor de saída Y para as seqüências de treino e teste.

Aplicando-se um algoritmo de *backpropagation*, as redes foram treinadas até que o mínimo Erro Médio Quadrado (*EMQ*) fosse atingido para a seqüência de teste. O melhor resultado (*EMQ*=0.15) foi alcançado com uma estrutura de 4 camadas, onde as camadas intermediárias

da RN eram constituídas por 15 e 17 unidades, representando uma taxa de reconhecimento de 94.5%. Todavia, analisando os resultados da previsão, nota-se que os erros (valores incorretamente previstos) ocorreram em 5 vetores da seqüência de teste. Tais vetores estão relacionados às classes 2, 3 e 4. Por outro lado, todos os outros vetores relacionados à classe 5 ($0 \leq T_{ij} \leq 14$ viagens) foram corretamente calculados.

A composição da seqüência de treino pode explicar esse desempenho da RN. Pode-se observar que existe uma grande concentração de dados na classe 5 (252 vetores = 87% do total). Por outro lado, nas classes 1, 2, 3, 4 existem apenas 1, 3, 5 e 28 vetores, respectivamente. Assim, apesar da alta taxa de reconhecimento alcançada no treinamento e teste, os resultados finais são comprometidos em termos da generalização.

Este tipo de problema tem sido recentemente tratado pela comunidade científica internacional como o problema de desbalanceamento de classes (*class imbalanced problem*) (Japkowicz, 2000). Tal problema refere-se ao domínio de uma classe em relação a outras, devido à sub-representação (número reduzido de vetores) destas. Esse tipo de problema tem sido notado em diversas áreas de aplicação de RN, principalmente nos casos relacionados a fenômenos naturais. Buscando resolver alcançar uma solução, duas abordagens distintas têm sido propostas. A primeira refere-se à modificação de algoritmos de treinamento da rede conforme discutido em Anand *et al.* (1993). Na outra abordagem dedica-se ao desenvolvimento do pré-processamento dos vetores de treinamento buscando atingir uma seqüência de dados balanceada (Kubat e Matwin, 1997).

Neste trabalho, segue-se a linha de desenvolvimento da segunda abordagem (pré-processamento) através da aplicação combinada das técnicas de Quantização Vetorial (QV) e *Jittering* (Reed *et al.*, 1992). A primeira técnica dedica-se à seleção de vetores representativos dentro de um conjunto dominante, ou seja, são eliminados os vetores redundantes que não contribuem significativamente para o treinamento da RN. Já a técnica de *Jittering* consiste na adição de uma pequena quantidade de ruído às classes que apresentam poucos vetores para o treinamento. Dessa forma, obtêm-se vetores altamente correlacionados com os originais sem alterar as propriedades fundamentais para o treinamento.

Assim, define-se que cada classe deve ter 40 vetores na seqüência de treino e um conjunto de dados balanceados é gerado. Inicialmente, baseando-se nos fundamentos de *Jittering*, aplica-se um ruído gaussiano com média zero e variância 0.001 aos vetores das classes 1, 2, 3 e 4, obtendo assim a quantidade estabelecida de vetores para o treinamento. Segue-se a criação de um novo conjunto de dados através da QV por meio da aplicação do algoritmo *LBG* desenvolvido por Linde *et al.* (1980). O *LBG* busca atingir a definição de vetores representativos (*codebook*) de forma quase ótima, através da minimização do *EMQ* desta representação. Deste modo, calcula-se 40 vetores para representar o universo de 252 vetores da classe 5.

Usando esses dados balanceados no treinamento, o melhor resultado obtido com a RN (*EMQ*=0.10 e taxa de reconhecimento 94.0%) com 15 e 7 unidades nas camadas intermediárias. Pode-se observar que utilizando os dados balanceados a modelagem alcançou um melhor poder de generalização para todas classes, quando comparado aos dados desbalanceados conforme apresentado na Tabela 1. Nela pode-se comparar o desempenho da RN na previsão das viagens para a seqüência de teste. Em todas as categorias, a RN foi capaz

de prever corretamente a maioria dos vetores de teste. Naqueles vetores que resultaram em uma previsão incorreta, pode-se notar que uma ou mais características do vetor de entrada (X) eram zero. Especificamente, os erros estão relacionados a viagens entre zonas que não possuem sistemas de transporte por trem e metrô. Fisicamente, os erros expressam a dificuldade da RN em obter um resultado esperado considerando a inexistência da informação para a variável.

Tabela 1: Taxa de reconhecimento para as classes e final

	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Final
Dados Desbalanceados	0%	0%	0%	33%	100%	94.5%
Dados Balanceados	100%	100%	100%	80%	90%	94.0%

5. CONCLUSÃO

O desenvolvimento do MNGE busca contribuir para o planejamento do transporte em diferentes perspectivas. Primeiramente, trata-se de um instrumento voltado especificamente para as atividades de planejamento estratégico. Em termos do problema clássico da previsão da demanda de viagens, o MNGE apresenta-se como uma ferramenta flexível e direta auxiliando na geração de informações qualitativas sobre os deslocamentos urbanos. Ademais, dado que os deslocamentos relacionam-se à complexa dinâmica urbana, a modelagem de transporte não deve ser limitada a formulações lineares tais como se têm desenvolvido em abordagens tradicionais. Nesse sentido, o MNGE está baseado em uma técnica de processamento paralelo não-linear que busca abranger a análise das interações uso do solo – transportes. Finalmente, o uso de fontes alternativas de dados tais como o SR promove a incorporação de propriedades urbanas na modelagem de transporte e conseqüentemente estabelece-se um novo panorama para a coleta de dados em estudos de transportes.

Analisando particularmente a formulação do MNGE, os resultados das simulações mostram a eficiência do modelo em representar o processo de previsão da demanda de viagens. A taxa de 94% de reconhecimento demonstra a considerável capacidade de modelagem dos movimentos. Em se tratando de um típico problema de classes desbalanceadas, foi necessário efetuar um pré-processamento dos dados, de modo a obter dados balanceados. O balanceamento através das técnicas *QV* e *Jittering* possibilitou um melhor treinamento, obtendo-se uma RN com maior capacidade de generalização.

Como esta pesquisa está ainda em desenvolvimento, existem algumas atividades futuras que se pretende realizar visando melhorar o MNGE. Após o desenvolvimento do modelo para a dimensão espacial, o próximo passo será a concepção e simulação do módulo temporal. Buscar-se-á o desenvolvimento de um modelo capaz de realizar a previsão de cenários futuros baseando-se em dados temporais. Adicionalmente, pretende-se realizar experimentos quanto aos níveis de agregação dos dados e automação na obtenção dos padrões de uso do solo por meio do SR-SIG.

Agradecimentos: O primeiro autor deseja agradecer o Ministério da Educação do Japão (Monbushou) pela bolsa de estudos concedida. Os autores agradecem a Central Transportation Planning Staff (CTPS) de Boston e a Massachusetts GIS (*MassGIS*) pelo acesso aos dados utilizados nesta pesquisa.

REFERÊNCIAS BIBLIOGRÁFICAS

- Anand, R., Mehrotra, K.G., Mohan, C.K. e Ranka, S. (1993) *An Improved Algorithm for Neural Network Classification of Imbalanced Training Sets*, IEEE Trans. on Neural Networks, Vol.4, N.6, pp.962-969, Nov.
- Avery, T.E. e Berlin, G. E., (1990) *Fundamental of Remote Sensing and Airphoto Interpretation*, Maxwell Macmillan International, New York, EUA.
- Department of Transportation – DOT. (1997) *Urban transportation planning in USA: an historical overview*, DOT-T88-26, September, EUA.
- Handy, S. (1996) *Methodologies for exploring the link between urban form and travel behavior*, Transportation Research – D, vol. 1, no. 2, pp.151-165.
- Harris, B. (1996) *Land use Models in Transportation Planning: a review of past developments and current best practice*, Delaware Valley Regional Planning Commission, EUA.
- Jang, J.S.R; Sun, C.T. e Mizutani, E. (1997) *Neuro-Fuzzy and Soft Computing: a computational approach to learning and machine intelligence*, Prentice Hall, EUA.
- Japkowicz, N. (2000) *Learning from imbalanced data sets: a comparison of various strategies*; AI 2000 Workshop on Imbalanced data sets (a ser publicado).
- Khisty, C. J. (1990) *Transportation Engineering: an introduction*, Prentice-Hall, EUA.
- Kubat, M. e Matwin, S. (1997) *Addressing the curse of imbalanced training sets: one –sided selection*; Proceedings of the Fourteenth International Conference on Machine Learning, 179-186; Morgan Kauffman.
- Linde, Y., Buzo, A. e Gray, R.M. (1980) *An Algorithm for vector Quantizers design*, IEEE Trans. on Communications, V.COM-28, pp.84-95, Jan.
- Meyer, M. D. (1983) *Strategic planning in response to environmental change*, Transportation Quarterly, vol. 37, no. 2, Abril.
- Ng, M. K. (1993) *Strategic planning in Hong Kong*, Town Planning Review, vol. 64, no. 3.
- Openshaw, S. e Openshaw, C. (1997) *Artificial Intelligence in Geography*, 348 pages; first edition (June) John Wiley & Son Ltd; Reino Unido.
- Oppenheim, A. V. e Schaffer, R. W. (1989) *Discrete-Time Signal Processing*, Prentice Hall.
- Reed, R., Oh, S., e Marks II, R.J. (1992) *Regularization Using Jittered Training Data*, Proc. of International Joint Conference on Neural Networks, Vol. III, pp. 147-152, Baltimore, EUA.
- Rodrigue, J. P. (1997) *Parallel modelling and Neural Networks: an overview for transportation / land use systems*, Transportation Research C, Vol. 5, N. 5, pp.259-271.
- Schaefer, P. (1980) *Strategic Planning: What Works ... And What Doesn't*; Presentations from APQC's Third Knowledge Management Symposium, EUA.
- Taco, P. W. G., Yamashita; Y., Dantas, A.S. e Souza, N. M., (1998) *Trip Model with the Application of Remote Sensing and the Geographic Information Systems*, CD ROM 004 - 68th ITE Meeting, Agosto, Canadá.
- Tyndall, G., Cameron, J. e Taggart, C. (1990) *Strategic planning and management guidelines for transportation agencies*, National Cooperative Highway Research Program, Report 331, Transportation Research Board, Washington, Dezembro, EUA.
- Wasserman, P. D. (1989) *Neural Computing: theory and practice*, Van Nostrand Reinhold, New York, EUA.