

UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE TRANSPORTES

**UMA AVALIAÇÃO DO CONSUMO DE ENERGIA COM
TRANSPORTES EM CIDADES DO ESTADO DE SÃO PAULO**

Engº GUILHERME CAMARGO FERRAZ COSTA

Orientador: Prof. Associado Antônio Néilson Rodrigues da Silva

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Civil – Área de Concentração: Transportes.

SÃO CARLOS

2001

À minha família:

Patrícia e Bruna, por terem sido compreensivas nas vezes em que me ausentei e incentivadoras quando mais precisei;

Meus pais, irmãos e sobrinhos, pelo total apoio, colaboração e convívio despendidos no decorrer deste trabalho.

AGRADECIMENTOS

A Deus;

Ao Prof. Dr. Antônio Néelson Rodrigues da Silva, orientador com indiscutível competência acadêmica e, acima de tudo, grande motivador, capaz de enxergar e transmitir aos seus orientados a visão do trabalho como um instrumento enobecedor;

Aos Profs. do Departamento de Transportes, em especial: Dr. Edson Martins de Aguiar, Dr. Antonio Clóvis Pinto Ferraz, Dr. Eiji Kawamoto, Dr. João Alexandre Widmer e Dr. José Reynaldo Anselmo Setti, que compartilharam seus conhecimentos em transportes, de forma irrestrita, ao longo do programa de mestrado;

Ao Prof. Dr. André Carlos Ponce de Leon Ferreira de Carvalho, do Departamento de Ciência de Computação e Estatística da USP e ao Dr. Eduardo Alcântara Vasconcelos, da ANTP, por participarem do exame de qualificação;

Aos colegas do STT, especialmente: Charlie, Pastor, Renato, Laura, Alexandre, Ricardo, Rafael, João Marcello, Rômulo, Cida, Patrícia, Fabiana, Márcia, Célio, Marcos Vinícius, Adalberto, Adriana, Éverton e Mauro, pela agradável convivência dentro e fora do departamento;

A todos aqueles que, direta ou indiretamente, colaboraram para este trabalho.

SUMÁRIO

LISTA DE FIGURAS	iii
LISTA DE TABELAS	vi
RESUMO	viii
<i>ABSTRACT</i>	ix
1. INTRODUÇÃO	1
1.1. Caracterização do problema	1
1.2. Justificativa do trabalho	2
1.3. Objetivo	3
1.4. Estrutura do texto	3
2. FORMA URBANA E TRANSPORTES	5
2.1. Introdução	5
2.2. O processo de desenvolvimento das cidades	8
2.3. A importância do planejamento físico	13
2.4. Padrões de dependência do automóvel	17
2.5. Forma urbana e consumo de energia com transportes	22
3. REDES NEURAIS ARTIFICIAIS	32
3.1. Aspectos da inteligência artificial e analogia biológica	33
3.2. Histórico das redes neurais	36
3.3. Neurônio artificial	37
3.4. Tipos de função de ativação	38

3.5. Topologia da rede	40
3.6. Rede <i>multilayer perceptron</i>	41
3.7. Algoritmos de aprendizado	41
3.8. Regra delta generalizada ou <i>backpropagation</i>	43
3.9. Exemplo comparativo entre RNA e regressão linear múltipla	46
3.10. Exemplo de RNA reproduzida em uma planilha eletrônica	48
4. MÉTODO	51
4.1. Variáveis relativas à forma urbana	52
4.2. Variáveis sócio-econômicas	55
4.3. Variáveis envolvidas no consumo de energia com transportes	56
4.4. Processamento das variáveis através de Redes Neurais Artificiais	57
4.5. Simulador de Redes Neurais Artificiais <i>EasyNN</i>	58
5. ANÁLISE PRÉVIA DOS DADOS COLETADOS	60
5.1. Municípios	60
5.2. Conurbações	63
5.3. Banco de dados das cidades ou conurbações paulistas	65
5.4. Consumo de energia nas cidades paulistas e nas capitais de estados brasileiros	70
6. RESULTADOS E ANÁLISES	81
6.1. Resultados	81
6.2. Análise dos resultados	93
7. CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	94
REFERÊNCIAS BIBLIOGRÁFICAS	98

LISTA DE FIGURAS

Figura 1:	Centro com características da <i>Cidade da Caminhada</i> em Frankfurt	10
Figura 2:	Oslo é um exemplo de <i>Cidade do Transporte Público</i>	12
Figura 3:	<i>Freeways</i> de Chicago	13
Figura 4:	Comparação entre duas filosofias de planejamento urbano	20
Figura 5:	Groningen (acima) e Amsterdam (abaixo) são cidades com bastante tradição no uso de transporte não-motorizado	21
Figura 6:	A integração entre uso do solo e transporte público fez com que Hongcong se tornasse uma das cidades menos dependentes do automóvel e mais econômicas	23
Figura 7:	Uso de energia <i>per capita</i> anual <i>versus</i> densidade urbana	24
Figura 8:	Uso de energia e área urbana <i>per capita</i> , nas 22 cidades nórdicas pesquisadas	27
Figura 9:	Uso de energia e área urbana <i>per capita</i> , nas cidades pesquisadas por Newman & Kenworthy (1989a) e Næss (1995)	28
Figura 10:	Esquema de um neurônio biológico	35
Figura 11:	Modelo não linear de um neurônio	37
Figura 12:	Função sigmóide logística	39
Figura 13:	Rede <i>multilayer perceptron</i> com uma camada intermediária	41
Figura 14:	RNA replicada através de uma planilha eletrônica	48
Figura 15:	Planilha de cálculo utilizada para replicar a RNA treinada	49

Figura 16:	Camadas criadas com o <i>software</i> de Sistemas de Informações Geográficas, relativas à cidade de São Carlos	54
Figura 17:	Cidades paulistas com população entre 50 mil e 100 mil habitantes	61
Figura 18:	Cidades paulistas com população entre 100 mil e 500 mil habitantes	62
Figura 19:	Cidades paulistas com população acima de 500 mil habitantes	63
Figura 20:	Consumo de energia <i>per capita</i> anual nas capitais de estados	71
Figura 21:	Consumo de energia <i>per capita</i> anual nas cidades paulistas analisadas	72
Figura 22:	Faixas de consumo de energia das cidades paulistas e das capitais	73
Figura 23:	Consumo de energia total anual <i>versus</i> frota de veículos automotores, nas capitais de estados brasileiros (com linha de tendência linear)	75
Figura 24:	Consumo de energia total anual <i>versus</i> população, nas capitais de estados brasileiros (com linha de tendência linear)	76
Figura 25:	Consumo de energia total anual <i>versus</i> população, nas cidades paulistas (com linha de tendência linear)	77
Figura 26:	Consumo de energia <i>per capita</i> anual <i>versus</i> empregos no comércio <i>per capita</i> , nas cidades paulistas (com linha de tendência do tipo potência).	78
Figura 27:	Consumo de energia <i>per capita</i> anual <i>versus</i> densidade populacional, nas capitais de estados brasileiros (com linha de tendência logarítmica).	79
Figura 28:	Valores de EQMs obtidos na segunda abordagem	83
Figura 29:	Novos valores de EQMs (com energia total gasta em transportes)	84
Figura 30:	Comparação entre os valores observados e estimados pelo modelo	85
Figura 31:	Importância relativa das variáveis de entrada	86
Figura 32:	Comparação entre os valores observados e estimados pelo modelo, após a retirada das variáveis de pouca relevância	87
Figura 33:	Importância relativa das variáveis de entrada	88

Figura 34:	Valores de EQMs obtidos para as 27 capitais brasileiras	90
Figura 35:	Importâncias relativas das variáveis de entrada, no caso das 27 capitais	91
Figura 36:	Importâncias relativas das variáveis de entrada (sem <i>L-O/N-S</i>)	92

LISTA DE TABELAS

Tabela 1:	Eficiência energética dos modos de transporte urbano, por grupos regionais de cidades, em 1990	7
Tabela 2:	Eficiência energética dos modos de transporte na amostragem global de cidades, em 1990	8
Tabela 3:	Valores de erro relativo total para os dois métodos empregados	47
Tabela 4:	Distribuição das cidades paulistas, por faixas de população	52
Tabela 5:	Variáveis consideradas no modelo	56
Tabela 6:	Relação das cidades paulistas com população entre 50 mil e 100 mil habitantes	61
Tabela 7:	Relação das cidades paulistas com população entre 100 mil e 500 mil habitantes	62
Tabela 8:	Relação das cidades paulistas com população acima de 500 mil habitantes	63
Tabela 9:	Área conurbadas, segundo as manchas urbanas visualizadas através do SIG	64
Tabela 10:	Banco de dados das cidades paulistas	69
Tabela 11:	Banco de dados das capitais de estados brasileiros	71
Tabela 12:	Coefficientes de determinação para as relações bivariadas	75
Tabela 13:	Valores de EQM para os dados de validação das melhores configurações de redes	82

Tabela 14:	Novos valores de EQM para os dados de validação das melhores RNAs	83
Tabela 15:	Importâncias relativas das variáveis, segundo o <i>software</i> EasyNN	85
Tabela 16:	Importâncias relativas das variáveis	88
Tabela 17:	Variáveis envolvidas no caso das 27 capitais	89
Tabela 18:	Valores de EQM para os dados de validação das melhores configurações de redes	90
Tabela 19:	Importâncias relativas das variáveis de entrada, segundo o <i>software</i> EasyNN	91
Tabela 20:	Importâncias relativas das capitais de estados (sem a variável <i>L-O/N-S</i>)	92

RESUMO

Dados reais apontam um expressivo aumento do consumo de combustível no Brasil e no mundo, além de um crescimento acelerado da população urbana. Ambos os processos vem ocorrendo sem um controle adequado no país e, como consequência, têm surgido grandes deseconomias urbanas, tais como: congestionamentos, poluição ambiental, consumo exagerado de combustíveis e uso inadequado do espaço viário. Neste contexto, quaisquer iniciativas no intuito de frear estas deseconomias são relevantes e oportunas, tanto que pesquisas nacionais e internacionais vêm sendo realizadas buscando entender melhor os fatores que mais interferem na energia gasta com transportes.

O objetivo deste trabalho é investigar a relação entre o consumo de energia com transportes e algumas variáveis espaciais e sócio-econômicas dos municípios do estado de São Paulo com população superior a 50 mil habitantes. A caracterização dos padrões de forma das áreas urbanizadas foi viabilizada graças aos recursos de um Sistema de Informações Geográficas, que possibilitaram determinar com relativa precisão as variáveis espaciais das manchas urbanas a partir de imagens de satélite georeferenciadas. Uma vez levantados todos os dados possíveis, procedeu-se a uma análise através do emprego de Redes Neurais Artificiais, ferramenta que possibilita identificar e classificar as variáveis de acordo com suas importâncias relativas no consumo de energia, que é a variável dependente do modelo.

Os resultados encontrados para as cidades paulistas pesquisadas confirmam a tendência internacional, sobretudo no que concerne à grande relevância da densidade populacional urbana, juntamente com outras características sócio-econômicas, sobre o consumo de energia com transportes. Variáveis como a população urbana, a densidade populacional e o nível de empregos no comércio revelaram-se como as de maior importância relativa no contexto analisado.

ABSTRACT

The world has been experiencing in recent years an unprecedented increase in the amount of fuel consumed for transportation purposes, in addition to a fast growth of the urban population. Those conditions were also found in Brazil, where they have produced several problems for urban areas, such as: traffic congestion, environmental pollution, high fuel consumption, and an improper use of the urban space. In such a context, any attempt to reduce those problems and their consequences is relevant and opportune. That is the reason why a considerable research effort is being directed to the issue at both national and international levels, in order to better understand the factors that most significantly contribute for the high levels of energy use for transportation.

The aim of this work is to investigate the relationship between energy consumption for transportation and a few selected variables related to urban form and socioeconomic characteristics of urbanized areas with more than 50,000 inhabitants located in the state of São Paulo. The boundaries of the urbanized areas were obtained from satellite images georeferenced in a Geographic Information System environment, which also offered the tools for the analysis of some spatial attributes. After the spatial and socioeconomic data were combined in a single database, they were then analyzed using Artificial Neural Network models, in order to identify variables that are relevant to energy consumption for transportation, along with their relative weights.

The results found with the Brazilian cities selected for the current study confirmed the trend observed in several countries worldwide, in which urban density played an important role influencing energy use for transportation. In the case studied here, other relevant input variables that considerably influenced the energy consumed for transportation were population and employment level.

1. INTRODUÇÃO

Este capítulo descreve, de maneira sintética, a caracterização do problema estudado, que se refere ao impacto do espalhamento urbano no consumo de energia com transportes, bem como a justificativa, o objetivo e a estrutura deste trabalho.

1.1. Caracterização do problema

É notório o alto grau de espalhamento urbano de algumas cidades em várias partes do mundo, principalmente americanas e australianas. Houston, Phoenix, Los Angeles, Perth, Adelaide e Sydney são exemplos de cidades espalhadas cujos sistemas de transporte são direcionados ao uso de automóvel. Alguns autores, como Newman & Kenworthy (1989a e 1989b) e Næss (1995), por exemplo, defendem que este padrão de cidades não pode ser considerado como o mais econômico no que tange ao consumo de energia com transportes. Ratificam ainda que fatores como o planejamento urbano, voltado a um uso misto do solo, e a reorientação dos sistemas de transportes, incentivando o transporte coletivo e não-motorizado, podem amenizar este problema de cidades espalhadas.

No entanto, existe certa resistência de determinados pesquisadores (Gordon & Richardson, 1989, podem ser citados como exemplos) com relação a estas soluções, por considerá-las retrógradas e desnecessárias. Esta rejeição ao planejamento físico das cidades é sustentada por opiniões de que somente medidas econômicas seriam suficientes e adequadas

para economizar energia com transportes, como, por exemplo, elevar os preços dos combustíveis, ao invés de uma reurbanização e priorização do transporte público. Mais ainda, alguns analistas alegam, com fundamentação predominantemente teórica, que o consumo será menor onde estes preços forem elevados, independentemente de serem mais ou menos espalhadas as cidades. Tal raciocínio tem resultado em cidades cada vez mais espalhadas (com baixas densidades), desordenadas com relação aos seus sistemas de transporte e anti-econômicas no que tange ao consumo de energia com transportes.

O que se verifica na prática, através de estudos empíricos já realizados em várias partes do mundo, é uma forte relação de variáveis relativas à forma urbana com o consumo de energia com transportes. De tal modo que nas cidades mais espalhadas o consumo de energia para este fim é expressivamente mais elevado do que nas cidades compactas. Mais grave ainda é uma constatação que este processo de espalhamento já parece estar atingindo inclusive cidades de países em desenvolvimento, como observado por Silva *et al.* (1999). Estas cidades raramente têm sido consideradas nas pesquisas já desenvolvidas nesta área, embora o consumo de energia com transportes tenha crescido consideravelmente nestes países e apresente hoje elevados patamares de consumo.

1.2. Justificativa do trabalho

Nos diversos estudos que relacionam forma urbana com consumo de energia com transportes foram analisadas cidades dos Estados Unidos, Canadá, Austrália, Europa e Ásia (Newman & Kenworthy, 1989a e 1989b; Næss, 1995; Kenworthy & Laube, 1999). Porém, com relação à América do Sul, mais precisamente o Brasil, há até alguns anos não se dispunha de nada referente a esta área de pesquisa.

Considerando a escassez de estudos sobre o tema no Brasil, a idéia principal deste trabalho é realizar uma análise semelhante às já desenvolvidas, porém para o caso do estado de São Paulo, adaptando-se às limitações de dados típicas de países em desenvolvimento. Até onde se pôde constatar, somente um trabalho envolvendo cidades brasileiras foi desenvolvido até o presente momento, com o mesmo propósito aqui adotado, o

de Pampolha (1999), o qual envolveu, no entanto, apenas as 27 capitais do Brasil. Neste trabalho, somente algumas variáveis espaciais foram consideradas relevantes no modelo apresentado, ou seja, as variáveis sócio-econômicas e até mesmo as relativas aos sistemas de transportes não foram incorporadas ao modelo desenvolvido. Além de ampliar o universo de cidades estudadas e com o intuito de desenvolver um modelo um pouco mais refinado neste sentido, procurou-se incrementar o banco de dados deste trabalho com algumas das variáveis que não foram analisadas por Pampolha (1999), como, por exemplo, o nível de empregos, o grau de instrução, a renda média populacional e a porcentagem de vias pavimentadas.

Assim, a principal justificativa para este trabalho está em contribuir para uma melhor compreensão das variáveis que efetivamente interferem no consumo de energia com transportes nas cidades paulistas, sendo aqui analisadas somente aquelas com mais de 50 mil habitantes.

1.3. Objetivo

O objetivo deste trabalho é identificar, com recursos de um Sistema de Informações Geográficas e uma análise conduzida através de Redes Neurais Artificiais, algumas das variáveis urbanas que interferem de forma significativa no consumo de energia com transportes, nas cidades do estado de São Paulo com mais de 50 mil habitantes. Além de relacionar quais são as variáveis mais importantes neste contexto, este trabalho visa principalmente determinar suas importâncias relativas no consumo de energia com transportes.

1.4. Estrutura do texto

Este trabalho é composto por seis capítulos. O segundo capítulo é uma revisão bibliográfica sobre o tema em estudo, no qual constam alguns tópicos sobre o processo de desenvolvimento das cidades, a importância do planejamento físico, os padrões de dependência do automóvel e a influência da forma urbana no consumo de energia com transportes. O capítulo três apresenta alguns conceitos básicos sobre a ferramenta de análise

aqui utilizada, as Redes Neurais Artificiais, além de expor um exemplo comparativo entre esta ferramenta e a regressão linear múltipla. No capítulo quatro é apresentado o método adotado nesta pesquisa. Dividido em duas etapas, são descritos detalhadamente o procedimento de levantamento de dados e a maneira como estes foram analisados, além de algumas considerações sobre o simulador de Redes Neurais Artificiais utilizado neste trabalho. No quinto capítulo são mostrados os dados coletados e algumas análises prévias realizadas com os mesmos, através de gráficos contendo a energia gasta com transportes e outras variáveis de entrada. Além disto, são comparados os dados do estado de São Paulo com os das capitais dos estados brasileiros. No sexto capítulo são expostos os resultados encontrados e, na seqüência, são mostradas algumas análises acerca dos mesmos. São apresentadas as melhores topologias de redes, os valores de erros quadrático médio obtidos através da comparação de dados observados e estimados e, finalmente, as importâncias relativas das variáveis envolvidas. O capítulo sete contém as conclusões mais importantes, bem como as sugestões para trabalhos futuros. Por fim, são listadas as referências bibliográficas citadas no corpo do texto desta Dissertação.

2. FORMA URBANA E TRANSPORTES

Neste capítulo, com base em uma revisão bibliográfica acerca do tema aqui estudado, apresentam-se alguns conceitos e trabalhos nacionais e internacionais que relacionaram, de uma forma ou de outra, o consumo de energia com transportes com variáveis espaciais, sócio-econômicas e algumas referentes diretamente aos sistemas de transportes.

2.1. Introdução

A ocupação desordenada do solo urbano, em geral fruto de um turbulento processo de urbanização, afeta negativamente as características das viagens realizadas, com impactos diretos na quantidade de energia despendida para este fim. A dispersão espacial das atividades urbanas mais usuais da sociedade (trabalho, estudo, compras, lazer, etc.) influencia diretamente a dependência da população com relação aos sistemas de transportes motorizados.

Tais deslocamentos, embora com características específicas quanto ao itinerário, modo de transporte, frequência e tempo de viagem, devem ser restringidos, na medida do possível, de forma a reduzir suas quantidades e percursos, já que estes são responsáveis por uma série de inconvenientes, tais como: perda de tempo, dispêndio de esforço físico, exposição ao risco de acidente, etc. Além desses aspectos que atingem

diretamente os usuários do transporte motorizado, existem efeitos nocivos com relação ao meio ambiente, como, por exemplo, a destruição gradativa da camada de ozônio, o consumo excessivo de fontes não-renováveis e a poluição do ar, que atingem toda a sociedade.

Isto tudo sem levar em consideração os custos diretos, do ponto de vista do consumo de energia com transportes. No caso particular dos transportes urbanos, em função da forma como as cidades se desenvolvem, pode-se ter maior ou menor consumo de energia para a realização de viagens (Ferraz, 1990 e Silva, 1993). Ainda, dada à política de planejamento urbano, as cidades podem ser direcionadas ao uso do automóvel ou ao transporte coletivo, o que também se reflete nos custos globais de transportes.

O transporte coletivo parece contribuir para uma ocupação racional do solo, favorecendo o adensamento populacional e a concentração de comércio e serviços. Outro dado relevante é o consumo de energia por passageiro transportado, expressivamente mais econômico do que no transporte individual. Entre as várias consequências negativas do uso massivo do automóvel, por outro lado, pode-se destacar a urbanização acelerada e desordenada, desfavorável à racionalização e economia de combustível, com comprometimento do desenvolvimento sustentável, pois a maioria da energia consumida é derivada do petróleo e, portanto, finita.

Como forma de melhor representar estas deseconomias do uso do automóvel quando comparado com outros modos de transporte urbano, Newman & Kenwothy (1999), baseados em um estudo com 46 cidades de várias partes do mundo, elaboraram as Tabelas 1 e 2. A Tabela 1 mostra a eficiência energética em termos de MJ por passageiro quilômetro, em cada grupo regional de cidades. Os dados mostram que a eficiência energética das viagens por automóvel é pelo menos a metade da eficiência das viagens por transporte público, ou até mesmo pior quando comparadas com o transporte sobre trilhos (a única exceção são os ônibus das cidades americanas, que são ineficientes se comparados com os ônibus de outras cidades).

Cidades	(MJ por passageiro km)		
	Carro	Ônibus	Sobre trilhos
Americanas	3,52	2,52	0,74
Australianas	3,12	1,64	1,12
Canadenses	3,45	1,61	0,51
Européias	2,62	1,32	0,49
Asiáticas desenvolvidas	3,03	0,84	0,16
Asiáticas em desenvolvimento	2,12	0,74	0,24

Tabela 1: Eficiência energética dos modos de transporte urbano, por grupos regionais de cidades, em 1990.

Fonte: Newman & Kenworthy (1999).

A Tabela 2 relaciona os mesmos dados, porém de forma agregada e ainda mostra a ocupação média dos veículos, que contribui significativamente para a eficiência energética dos vários modos de transporte. Estes dados revelam que as viagens urbanas por automóvel consomem, em média, aproximadamente duas vezes a energia consumida nas viagens por ônibus, 6,6 vezes o que é gasto nas viagens por trem elétrico e 3,7 vezes o consumo das viagens por veículo leve sobre trilhos (VLT). Segundo Newman & Kenworthy (1999), os sistemas de VLT requerem mais paradas que os trens convencionais devido à maior proximidade das estações, fazendo com que os mesmos apresentem uma eficiência energética um pouco inferior a dos trens elétricos convencionais, no entanto são mais eficientes se comparados com os movidos a *diesel*. Outro dado importante para se ressaltar é a ocupação média dos trens e VLTs, que é da ordem de duas vezes a ocupação dos ônibus e 20 vezes a dos carros.

Modo de transporte	MJ por passageiro km	Ocupação média (passageiros)
Automóvel	2,91	1,52
Ônibus	1,56	13,83
Trem elétrico	0,44	30,96
Trem a <i>diesel</i>	1,44	27,97
VLTs	0,79	29,73

Tabela 2: Eficiência energética dos modos de transporte na amostragem global de cidades, em 1990.

Nota: A ocupação média dos trens e VLTs é referente a um vagão de passageiros

Fonte: Newman & Kenworthy (1999).

Face à extrema necessidade de se encontrar formas mais racionais de uso de energia com transportes, o planejamento físico das cidades mostra-se como uma alternativa com potencial para gerenciar esta situação. Dada a importância da densidade urbana na economia de energia, uma zona urbana pode gradualmente reformular seus padrões de transporte, desenvolvendo áreas e centros mais densos, com uso do solo mais misto e mais orientada ao transporte público e aos modos não motorizados (Kenworthy & Laube, 1999).

2.2. O processo de desenvolvimento das cidades

De acordo com Silva (1990), o processo de urbanização não se caracteriza apenas por um crescimento da população urbana, mas também por uma redução concomitante da população rural. O processo de urbanização no século XX apresentou significativas alterações na forma dos centros urbanos. O espalhamento urbano foi uma das modificações mais significativas, fruto muitas vezes da ausência de planejamento físico de seus meios de transporte e do zoneamento (distribuição e concentração de atividades, como:

trabalho, lazer, estudo, residências, etc.), os quais poderiam contribuir para a construção de cidades economicamente viáveis.

De acordo com Silva (1993) o espalhamento urbano pode ocorrer como consequência de dois processos:

- Baixas densidades em zonas residenciais, resultantes de grandes lotes individuais;
- Descontinuidade na ocupação do solo urbano.

Estes dois aspectos geram densidades urbanas baixas, que conduzem a cidades ineficientes no que tange ao consumo de energia com transportes. Densidade urbana, que é uma das formas de se medir o espalhamento urbano ou o grau de descentralização das cidades, “é a população dividida pelo total de área ocupada por uma cidade, excluindo-se todos os usos não urbanos de solo” (Newman & Hogan, 1981). Segundo estes autores, baixas densidades são aquelas inferiores a 25 pessoas por hectare e altas densidades ocorrem acima de 100 pessoas por hectare.

Newman (1992) analisa o padrão histórico de desenvolvimento das cidades, em decorrência do tipo de transporte utilizado, através da sua divisão em três períodos:

- A Cidade da Caminhada: este padrão de cidade desenvolveu-se há cerca de 10.000 anos e ainda existe em algumas localidades. Possuía altas densidades e uso do solo misto. Todos os destinos podiam ser atingidos a pé, em cerca de meia hora. Muito raramente, estas cidades possuíam mais do que cinco quilômetros de um lado a outro;

Muitas cidades hoje ainda mantêm suas características de *Cidade da Caminhada* – por exemplo, alguns centros antigos de cidades européias, como o ilustrado na Figura 1, a qual se refere à cidade de Frankfurt (Alemanha). Conforme Newman & Kenworthy (1999), as partes centrais de todas as cidades americanas e australianas uma vez

tiveram estas características, mas desapareceram quase que totalmente, com exceção de algumas regiões históricas que mantiveram suas formas antigas.



Figura 1: Centro com características da *Cidade da Caminhada* em Frankfurt.

Fotos tiradas por Antônio Néelson Rodrigues da Silva, em 1997.

- A Cidade do Transporte Público: na última parte do século XIX, as cidades expandiram-se cada vez mais em direção à periferia, graças aos trens e bondes que permitiam viagens mais rápidas. Os trens, geralmente, criavam sub-centros próximos às estações, onde se formavam pequenas cidades com características da *Cidade da Caminhada*. Os bondes, por sua vez, geravam desenvolvimentos lineares que seguiam suas rotas. Em ambos os casos, formavam-se densidades médias e áreas com usos mistos nas paradas dos trens e

nas rotas dos bondes. Com base nestas tecnologias, as cidades alcançavam até 20 a 30 quilômetros de um extremo a outro e, onde a linha férrea atingia o centro da cidade, havia intensa movimentação, tornando este local o principal pólo de atração da cidade.

Há uma tendência nas cidades européias de manterem suas formas orientadas ao transporte público, embora em décadas recentes tenha começado uma certa dispersão ao redor dos corredores principais, baseada nas viagens por automóvel. Existe um poderoso movimento hoje que está tentando re-enfatizar a importância do desenvolvimento orientado ao transporte público. Corredores de transporte público, como os VLTs de Oslo (Noruega) possibilitam desenvolvimento em conjunto com a preservação de áreas verdes dentro da zona urbana, como pode ser averiguado na Figura 2.

- A Cidade do Automóvel: começando antes da Segunda Guerra Mundial, e acelerando no seu fim, o automóvel praticamente transformou-se na tecnologia de transporte que passou a modelar as cidades. Junto com os ônibus, os automóveis possibilitaram o desenvolvimento em qualquer direção, primeiro inserindo-se entre as linhas de trem e depois indo a distâncias de até 50 quilômetros. Áreas residenciais com baixas densidades tornaram-se mais praticáveis e, como reação à cidade industrial, o planejamento das cidades começou a separar funções de acordo com o zoneamento. Isto aumentou as distâncias de viagens e as cidades passaram a descentralizar-se e dispersar-se ainda mais.



Figura 2: Oslo é um exemplo de *Cidade do Transporte Público*.

Fotos tiradas por Antônio Néelson Rodrigues da Silva, em 1996.

Algumas cidades americanas e australianas cresceram principalmente na era do automóvel. Cidades como Canberra e Phoenix desenvolveram-se quase que exclusivamente como *Cidade do Automóvel*; outras como Denver, Houston e Perth também apresentam fortes traços deste tipo de cidade. Agora, após cinquenta anos de crescimento baseado no automóvel, estas cidades espalharam-se até o limite de conforto das viagens por carro. Muitos dos residentes de áreas suburbanas não conhecem outro estilo de cidade. Novos subúrbios, além de estarem situados a quarenta ou cinquenta quilômetros do centro, estão cada vez mais isolados das amenidades urbanas básicas, sendo que o nível de problemas associados à dependência do automóvel em tais localidades está crescendo rapidamente. De acordo com Newman & Kenworthy (1999), grandes *freeways* como as de

Chicago (vide Figura 3) foram construídas com o intuito de se reduzir o tempo de viagem, contudo, na realidade, as distâncias percorridas é que acabaram aumentando.

Os padrões descritos por Newman (1992) refletem as etapas de desenvolvimento de muitas cidades, que culminaram no último modelo descrito. A cidade do automóvel tomou cada vez mais espaço. Como consequência, geraram-se prejuízos como: congestionamentos, diminuição das velocidades operacionais, aumento dos tempos de viagens, poluição, maior consumo de energia com transportes, entre outros.



Figura 3: *Freeways* de Chicago.

Foto tirada por Antônio Néelson Rodrigues da Silva, em 1992.

2.3. A importância do planejamento físico

Para McLaren (1992), as cidades que possuem altas densidades não se caracterizam necessariamente pelo menor uso do carro, mas por possuírem menor dependência com relação a este meio de transporte. O benefício oriundo deste tipo de cidade estende-se a menor quantidade de viagens por automóvel e maior possibilidade de emprego de modos alternativos, que contribuem para a economia local, além de possuir vantagens sob a ótica ambiental.

A crença de que cidades com alta densidade populacional levam ao estresse e prejudicam a saúde tem contribuído para um declínio na densidade urbana de vários países, particularmente os Estados Unidos e a Austrália. Ainda que muitos planejadores urbanos clamem por um aumento nesta densidade, pesquisas mostram que a maioria da população prefere morar em áreas residenciais de baixa densidade, afastadas do centro (Newman & Hogan, 1981).

A existência de áreas residenciais espalhadas, como subúrbios de baixa densidade, é um fato na vida dos americanos que muitos planejadores, urbanistas e políticos gostariam de mudar, porém há uma forte preferência pelo estilo de vida suburbano que persiste em direcionar o padrão de desenvolvimento residencial dos Estados Unidos. Greene (1997) confirma a tendência das cidades americanas pelo modo automóvel, ocasionando espalhamento em direção ao subúrbio. A maioria das grandes cidades do centro-oeste dos Estados Unidos está substituindo, de uma forma bastante rápida, áreas rurais por zonas residenciais de baixa densidade. Se as pessoas interessadas em reverter esta situação desejam conter o crescimento do espalhamento urbano é preciso um esforço para convencer os habitantes do subúrbio que há benefícios em se adotar um estilo de vida mais urbanizado e compacto (Talen, 2001).

Talen (2001) realizou uma pesquisa através de 185 questionários preenchidos por famílias americanas residentes em Twin Creeks, uma área residencial suburbana localizada a cerca de 40 quilômetros de Dallas, Texas, onde existe uma grande dependência ao automóvel. Nesta pesquisa foram investigadas as preferências dos americanos com relação aos seus estilos de vida, com o intuito de se verificar quais seriam os pontos fracos da vida suburbana que poderiam fortalecer uma provável preferência a um estilo de vida mais planejado e com o perfil das cidades compactas, com o uso do solo mais misto, maior acessibilidade, menor dependência ao automóvel e priorizando o transporte público, ou seja, um urbanismo tradicional, conforme definido pela autora.

Por meio de várias análises envolvendo a aceitação das características da cidade compacta, chegou-se a resultados interessantes sobre a preferência dos americanos: há uma certa evidência de que grande número de residentes de regiões suburbanas seriam

receptivos aos conceitos de urbanismo tradicional sob circunstâncias específicas, principalmente aqueles que gastam mais de uma hora por dia no carro, desempenhando qualquer atividade. Especificamente, dois principais resultados fortalecem a viabilização dos princípios de urbanismo tradicional:

- Há uma insatisfação com os aspectos de planejamento físico do desenvolvimento suburbano, definida pelas críticas ao espalhamento;
- Há uma predisposição dos moradores de regiões suburbanas em aceitarem alguns conceitos de urbanismo tradicional, como menor dependência de automóvel e uso do solo misto.

Através destes pontos levantados, Talen (2001) pretendeu mostrar que a filosofia do planejamento físico e das cidades compactas não é totalmente descartada pelas pessoas que vivem em regiões suburbanas. Para Newman *et al.* (1995), esta eventual rejeição ao planejamento físico das cidades deve-se a opiniões equivocadas sobre o assunto, as quais alegam que instrumentos de planejamento físico são secundários ou inferiores a instrumentos econômicos, com base em três argumentos principais:

- “As pessoas sempre compram mais espaço e mobilidade, ou seja, há uma relação entre a elevação do padrão de vida e o aumento da demanda por espaço próprio e uso do carro” (Troy, 1992; Gomez-Ibañez, 1991; Hall, 1991 e Stretton, 1989, todos citados por Newman *et al.*, 1995);

Com relação a este aspecto, Newman *et al.* (1995) não acreditam que a relação sugerida seja automática. Crêem sim em uma ligação mais complexa entre o poder aquisitivo e a forma urbana, afirmando que o uso do automóvel é significativamente menor em áreas de altas densidades, para todos os níveis de renda.

- “O preço do combustível é a variável mais importante na determinação da forma das cidades e seus padrões de transporte” (Gomez-Ibañez, 1991 e Kirwan, 1992, todos citados por Newman *et al.*, 1995);

Já neste caso, apesar da ênfase nos preços, Kirwan reconhece – assim como Newman *et al.* (1995) – a importância do planejamento físico das cidades, como forma de se reduzir o consumo de combustível.

- “A resolução dos problemas advindos de baixas densidades e respectivos custos com transporte tem ocorrido a partir de mudanças estruturais dentro da economia das cidades, ou seja, as oportunidades de emprego seguem as residências em direção ao subúrbio. Dessa maneira, a cidade tem a capacidade de se auto-ajustar, eliminando-se a necessidade de planejamento físico”. (Brotchie, 1992 e Gordon, Kumar & Richardson, 1989, todos citados por Newman *et al.*, 1995).

Sobre este último argumento, Newman *et al.* (1995) mencionam que as cidades têm duas opções de se desenvolver: uma que envolve mais espalhamento e, portanto baixa densidade (o modelo de “auto-ajuste”); outra que submete a um movimento em direção aos sub-centros, que são direcionados ao transporte público e possuem altas concentrações de empregos, residências e outros serviços. Na opinião destes autores, este último modelo tem muito mais chance de alcançar a eficiência esperada do ponto de vista do consumo de energia do que o primeiro.

Newman *et al.* (1995) não negam a importância de fatores econômicos, porém enfatizam que devam ser usados em conjunto com medidas de planejamento físico, visando economizar energia com transportes.

2.4. Padrões de dependência do automóvel

O ideal de tornar as cidades lugares cada vez melhores tem levado a uma série de discussões quanto à quantidade de transporte e o uso do carro, além dos seus impactos nos padrões de desenvolvimento urbano. A principal questão reflete-se na capacidade do automóvel em induzir o espalhamento observado nas cidades. E uma cidade espalhada inevitavelmente possui maior dependência de transporte por automóveis.

Segundo Fouchier (1997) com relação a planejamento urbano e transportes, existem dois pares harmônicos possíveis de acontecer:

- Cidade densa e transporte público;
- Cidade espalhada e automóvel.

Nesta pesquisa, Fouchier ratifica as hipóteses destas duas combinações, analisando para isto as densidades da região de Paris. Foram testadas diversas medidas de densidade; a mais significativa, no entanto, foi a “densidade humana líquida”, definida como (população + empregos)/área urbana, que descreve a intensidade urbana. Em uma escala regional (10,6 milhões de habitantes), a relação entre posse de automóveis e densidade humana líquida, para as 1300 zonas da região estudada, é clara: quanto mais densa for a zona, menor será a posse de automóveis. Neste caso, o coeficiente de correlação (r) encontrado entre estas duas variáveis foi igual a $-0,62$. Mais ainda, quando comparada com o uso de modos não motorizados, a densidade apresentou coeficiente de correlação ainda mais significativo: $r = +0,71$.

Em áreas de baixas densidades, o automóvel apresenta-se como uma alternativa de transporte bastante conveniente, em virtude das carências de transporte público, da fluidez do tráfego e da disponibilidade de estacionamentos, entre outras facilidades. A situação é totalmente inversa em setores mais densos, onde o uso de transporte público predomina e o automóvel sofre uma série de restrições, tais como: altos custos e escassez de estacionamentos, congestionamentos, etc.

Indivíduos que vivem em zonas de baixa densidade humana líquida viajam diariamente, em média, uma distância de 2,3 vezes o percurso dos que vivem em zonas mais densas: 35 km/dia contra 15 km/dia, sendo que a parcela de viagem correspondente ao automóvel é bem maior no primeiro caso do que no segundo. Com relação ao uso de energia com transportes, esta proporção é da ordem de 3,2, ou seja, um indivíduo que mora em uma zona de baixa densidade consome, em média, 3,2 vezes a energia consumida com transporte pelos indivíduos que vivem em zonas mais densas.

O automóvel proporciona bem mais mobilidade do que qualquer outro meio de transporte, no entanto, existem sérios efeitos adversos vinculados a esta mobilidade. De acordo com Fouchier (1997) o uso do carro é muito mais perigoso para o ambiente e para a saúde, por pessoa transportada, que o transporte público. Esta constatação pode ser feita em vários aspectos (ruído, poluição, consumo de energia, espaço viário requerido, etc.) e quanto maior o uso do carro, maiores serão estes efeitos nocivos. Desta forma, constatou-se também que quanto maior a densidade de onde as pessoas moram, menor a poluição ambiental e o consumo de energia quando elas viajam.

Existem hoje duas alternativas para os planejadores urbanos:

- Estender as áreas urbanas, com o risco de quebrar as ligações físicas da proximidade, através de um aumento na mobilidade (pelo carro), telefone, Internet, etc.
- Aumentar as densidades populacional e de empregos e o uso do solo misto nas cidades, para tirar proveito da centralização e proximidades, por meio de um incentivo ao transporte público.

Estas duas filosofias de planejamento urbano podem ser mais bem visualizadas pela Figura 4. Os dois cenários ilustrados têm sua própria coerência. Os objetivos iniciais são fundamentalmente diferentes e levam a políticas opostas, tentando levar a dois tipos diferentes de cidades, embora cada cenário não leve em conta todos os aspectos do problema. No caso do cenário do desenvolvimento sustentável, a riqueza econômica criada pela acessibilidade oferecida pelo carro (oportunidades de emprego, eficiência do sistema econômico) não é

totalmente levada em consideração. No caso do cenário do ganho de espaço individual, é dado um valor monetário ao impacto ecológico, mas é um valor mais baixo se comparado com as vantagens econômicas da mobilidade do carro. Os defensores do cenário do desenvolvimento sustentável acreditam que o aumento da densidade urbana possa ter um impacto significativo no uso do carro e que a economia com energia e a redução de poluentes serão importantes o bastante para justificar um adensamento. Já os defensores do cenário de ganho do espaço individual, no entanto, consideram como trivial o consumo natural de espaço pelas novas urbanizações, e que a tecnologia pode resolver todos os incômodos provocados pelo carro.

Frank (1996) também conduziu testes empíricos e analisou as relações entre forma urbana e comportamento de viagens em cidades americanas. O objetivo principal deste estudo foi descobrir como planejar e implementar padrões de forma urbana que melhorassem a acessibilidade e reduzissem a dependência do automóvel. Chegou-se a conclusões de que densidade populacional e densidade de empregos (empregos por unidade de área), além de ocupação mista do solo, afetam negativamente o uso de carro e a distância de viagem, o que vem a corroborar os princípios do desenvolvimento sustentável apresentados por Fouchier (1997). Por outro lado, têm impacto positivo na utilização de transporte coletivo, nas viagens a pé e no número de viagens ao trabalho, que também está de acordo com a filosofia sustentável ilustrada na Figura 4.

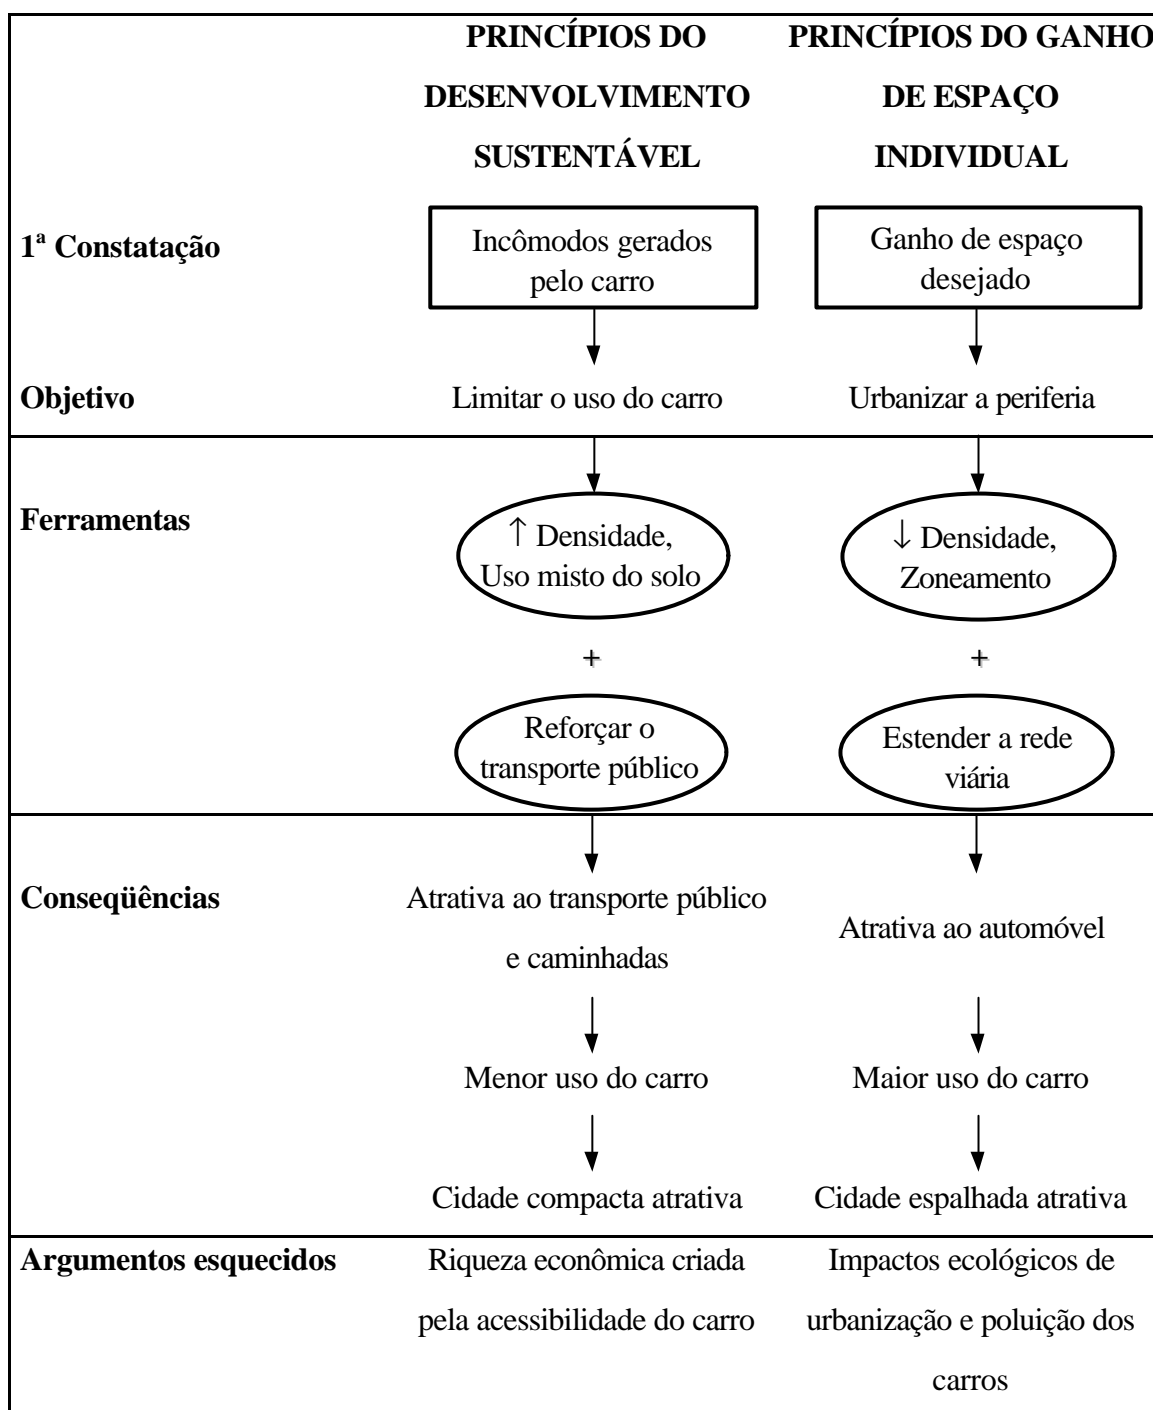


Figura 4: Comparação entre duas filosofias de planejamento urbano.

Fonte: Adaptado de Fouchier (1997).

Na comparação internacional de Newman & Kenworthy (1989a), as cidades européias mostraram-se bastante eficientes energeticamente, por serem mais compactas e possuírem características de um desenvolvimento sustentável: 25% das viagens ao trabalho realizaram-se com transporte público e somente 44% com automóvel. Outro fato relevante nesta análise é a importância do transporte não-motorizado nessas cidades mais compactas, evidenciado pelo fato de que 21% da população vão trabalhar a pé ou de bicicleta. A Holanda é um país europeu cujas cidades possuem bastante tradição no uso do transporte não-motorizado para trabalhar, como são os casos de Groningen e Amsterdam (vide Figura 5). As cidades asiáticas mostraram-se como as mais eficientes de todas, porque o carro é usado por somente 15% das pessoas nas viagens ao trabalho e 25% utilizam modos não-motorizados.



Figura 5: Groningen (acima) e Amsterdam (abaixo) são cidades com bastante tradição no uso de transporte não-motorizado.

Fotos tiradas por Antônio Néelson Rodrigues da Silva, em 1997.

2.5. Forma urbana e consumo de energia com transportes

Conforme Shipper (1994 *apud* Næss, 1995), a relação entre a organização espacial da sociedade e os sistemas de energia tem sido objeto de grande interesse desde o começo dos anos 1970. O mercado mundial de petróleo era marcado por uma certa estabilidade até 1973, quando o embargo árabe levou a um aumento considerável no preço deste combustível. Um novo salto nos preços do petróleo ocorreu em 1979, induzido pela Revolução Iraniana e a Guerra Irã-Iraque. Em meados na década de 1980, a produção e consumo de energia ganharam ainda mais atenção, devido, particularmente, a dois importantes eventos, a saber: o acidente nuclear de Chernobil, em 1986, e a publicação do relatório da Comissão Mundial em Ambiente e Desenvolvimento, ocorrida em 1987.

Nos anos 70, as principais preocupações eram relativas à economia e à estabilidade de fornecimento. Já na década seguinte o foco principal passou a centrar-se nos impactos negativos do uso e produção de energia, principalmente quanto à economia de fontes não-renováveis de combustível e poluição ambiental, decorrentes de um consumo exacerbado de derivados de petróleo (Næss, 1995).

Tão logo as preocupações com relação à economia de fontes não-renováveis de combustível intensificaram-se, novas pesquisas buscando alternativas para reduzir o consumo de energia emergiram no mundo acadêmico. Foi assim o caso de Newman & Kenworthy (1989a), em sua primeira pesquisa de grande impacto internacional, que buscaram estudar primeiramente os consumos de gasolina *per capita* nas cidades americanas e posteriormente, compará-los com cidades de outros países desenvolvidos. Na amostra americana, composta por dez grandes cidades, verificou-se que o gasto deste combustível variou em até 40%, principalmente devido ao uso do solo e planejamento de transportes, aliados a fatores secundários, tais como variações no preço do combustível e na renda média da população.

Os mesmos padrões, ainda mais expressivos, foram verificados na amostragem global, na qual constavam 32 cidades da América do Norte, Europa, Austrália e

Ásia. Constatou-se que a média do consumo de gasolina das cidades americanas foi da ordem de duas vezes a média das australianas, quatro vezes das cidades européias e dez vezes das cidades asiáticas. Nesta comparação internacional, observou-se que quanto mais densa fosse a cidade, menor seria o gasto *per capita* com transporte. Hongcong (vide Figura 6), por exemplo, apresentou um dos menores consumos de gasolina *per capita* e possuía a maior densidade urbana observada (cerca de 300 habitantes/hectare, em média), além de um uso do solo misto, fazendo com que o componente principal de várias viagens fosse o transporte vertical em um elevador. A Figura 7 compara o uso de gasolina *per capita* anual com a densidade das 32 cidades pesquisadas por Newman & Kenworthy (1989a). Nesta Figura aparece ainda uma linha de tendência ajustada com uma função potência, a qual apresentou um valor para o coeficiente de determinação (R^2) igual a 0,74.



Figura 6: A integração entre uso do solo e transporte público fez com que Hongcong se tornasse uma das cidades menos dependentes do automóvel e mais econômicas.

Fonte: Newman & Kenworthy (1999).




Figura 7: Uso de energia *per capita* anual *versus* densidade urbana.

Fonte: Adaptado de Newman & Kenworthy (1989b).

Com base nos resultados encontrados, Newman & Kenworthy (1989a) sugeriram políticas de planejamento físico, particularmente reurbanização e reorientação das prioridades nos sistemas de transporte, como meios de reduzir o consumo de gasolina e a dependência do automóvel. Segundo estes autores, a reurbanização seria uma intensificação das atividades urbanas dentro da área existente, ao invés de uma urbanização em novas áreas verdes da periferia das cidades. A reorientação dos sistemas de transportes seria feita através de um aperfeiçoamento e extensão da rede de transporte público e de um incentivo às viagens a pé ou de bicicleta.

Newman & Kenworthy (1989a) traçaram ainda o perfil de uma cidade hipotética de baixo consumo de gasolina. Esta cidade deveria ser compacta, com um forte centro, intensivamente ocupado por pessoas e empregos, que viabilizasse mais viagens com transporte público, a pé e de bicicleta. Políticas relacionadas a preços de automóveis, renda e eficiência dos veículos também foram destacadas como importantes, mas deveriam ser aplicadas concomitantemente às relacionadas ao planejamento físico. Dessa maneira, os autores sugeriram como medidas para economizar combustível:

- Aumentar a densidade urbana;
- Fortalecer o centro da cidade;
- Intensificar o uso do solo nas proximidades do centro;
- Proporcionar um transporte público com bom nível de serviço;
- Restringir a construção de infra-estrutura voltada ao automóvel.

Na mesma linha de pesquisa de Peter Newman e Jeffrey Kenworthy, inseriu-se posteriormente o pesquisador Peter Næss, que estudou o caso de cidades pertencentes a países nórdicos (Noruega, Suécia, Dinamarca e Islândia). Enquanto Newman & Kenworthy (1989a e 1989b) consideraram somente o consumo de gasolina como variável dependente em suas análises, os trabalhos desenvolvidos por Næss incluíam também os demais tipos de combustíveis utilizados para transportes, até mesmo a energia elétrica gasta em trens, metrô, trólebus, etc.

Inicialmente, Naess (1993, *apud* Naess *et al.*, 1996) investigou 97 cidades da Suécia e observou que o consumo de energia com transportes nestas cidades também era influenciado pela densidade da população. Neste caso, porém, a densidade foi representada pela sua função inversa, ou seja, a área urbana *per capita*. Chegou-se ao seguinte resultado: “Quando a área urbana *per capita* aumentava de 400 m² para 600 m², o uso de energia médio anual gasto com transporte aumentava cerca de 12%”.

Posteriormente, Naess (1995) realizou uma pesquisa semelhante para 22 cidades nórdicas, sendo treze da Noruega, quatro da Suécia, quatro da Dinamarca e uma da Islândia, confirmando a tendência verificada para as 97 cidades da Suécia, ou seja, o uso de energia *per capita* apresentou forte relação com a área urbana *per capita*. Quanto maior o valor da área urbana *per capita* (menor a densidade populacional) maior foi o uso médio de energia gasto com transporte por habitante, o que pode ser constatado na Figura 8. Nesta Figura, referente às 22 cidades nórdicas pesquisadas, é apresentada ainda uma linha de tendência ajustada com uma função linear, a qual apresentou um valor de $R^2 = 0,58$. Com a intenção de uma visualização das relações encontradas por estes pesquisadores em um mesmo gráfico, elaborou-se a Figura 9, a qual mostra os resultados encontrados por Newman & Kenworthy (1989b) e Naess (1995). É importante observar que diferentemente do gráfico da Figura 7, o eixo das abscissas refere-se à área urbana *per capita*, justamente para uniformizar os dois estudos e poder visualizá-los de forma conjunta. Sendo assim, também se tornou possível ajustar uma linha de tendência linear para os dados de Newman & Kenworthy (1989a), cujo coeficiente de determinação foi igual a 0,71.

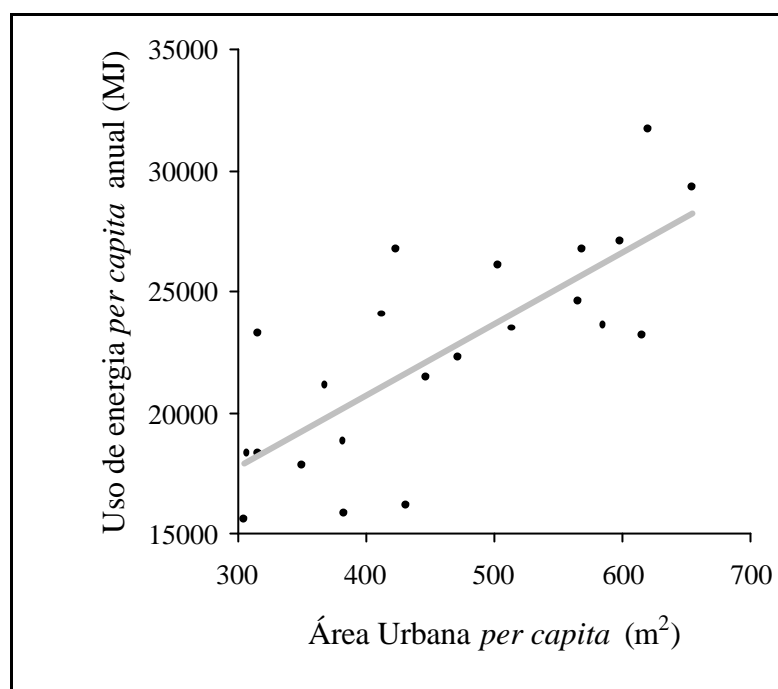


Figura 8: Uso de energia e área urbana *per capita*, nas 22 cidades nórdicas pesquisadas.

Fonte: Adaptado de Næss (1995).

Na análise de regressão múltipla de Næss (1995), observou-se que cinco variáveis respondiam por cerca de 74% das variações entre as cidades quanto ao uso de energia *per capita*. Classificadas a partir da mais importante para a de menor importância, são elas: frequência de viagens a trabalho em cidades vizinhas, composição dos empregos, área urbana *per capita*, índice de concentração das residências e renda média da população.

Outras variáveis afetaram indiretamente o uso de energia nas cidades nórdicas pesquisadas. A população urbana é citada como a principal delas. Já algumas variáveis que a priori pareciam bastante relevantes, neste caso apresentaram pouca ou nenhuma relação com o uso de energia, como são os casos da posse de automóveis e do nível de serviço do transporte público.

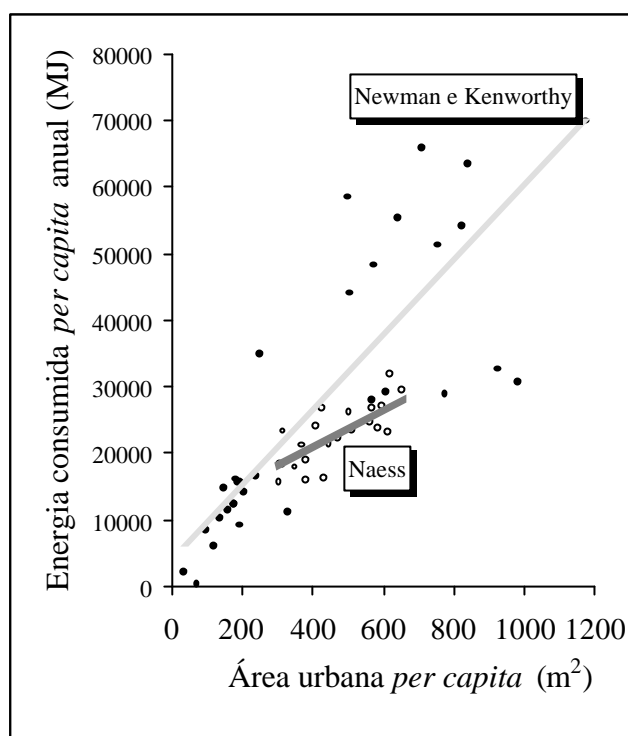


Figura 9: Uso de energia e área urbana *per capita*, nas cidades pesquisadas por Newman & Kenworthy (1989a) e Næss (1995).

Em um outro trabalho bastante abrangente, no qual constavam até mesmo cidades de países em desenvolvimento, Jeffrey Kenworthy e Peter Laube ratificaram a importância de variáveis relativas à forma urbana no consumo de energia com transportes. Kenworthy & Laube (1999) analisaram a influência da forma urbana nos padrões de dependência do automóvel em 46 cidades dos Estados Unidos, Canadá, Austrália, Europa Ocidental e Ásia (incluindo cidades asiáticas desenvolvidas e em desenvolvimento). Nesta pesquisa, os autores refutaram o pensamento equivocado de que somente variáveis econômicas seriam responsáveis por uma maior ou menor dependência do automóvel. Estes padrões de dependência não se relacionaram fortemente com a riqueza das cidades, mas variaram de uma forma mais clara e sistemática quando confrontadas com os padrões de uso do solo. Os custos de aquisição de carro próprio e seu combustível também apresentaram

uma certa relação com o grau de dependência do automóvel, embora não tão significativa quanto o uso do solo.

O padrão de riqueza das cidades não proporcionou evidência consistente, por si só, para explicar este grau de dependência. Em uma análise de regressão bivariada entre riqueza e uso de automóvel *per capita*, observou-se que o coeficiente de correlação (r) foi igual a +0,264. Resultados que comprovaram o fraco desempenho desta variável, ao contrário do que pregam alguns pesquisadores que somente consideram questões econômicas como relevantes no consumo de energia para transportes (Gordon *et al.*, 1988, e Gordon & Richardson, 1989, entre outros, têm este ponto de vista).

Em contraste com o poder aquisitivo das cidades, a forma urbana - em particular a densidade populacional - apresentou forte correlação negativa com o uso de carro ($r = -0,906$) e, indiretamente, com o consumo de energia com transportes, já que uma maior dependência do automóvel acarreta um maior uso de energia com transportes na área urbana (Kenworthy & Laube, 1999).

Reforçando a importância que a densidade urbana pode ter no consumo de energia com transportes, Kenworthy & Laube (1999) salientam que uma região pode gradualmente reformular seus padrões de transportes em benefício de uma maior economia de energia, desenvolvendo estrategicamente áreas e centros mais densos, com uso do solo mais diversificado, mais orientadas ao transporte público e aos modos não-motorizados.

Com relação às cidades de países em desenvolvimento, mais precisamente o Brasil, pode-se citar também o trabalho de Pampolha (1999), que fez um estudo sobre as 27 capitais brasileiras em que relacionou o espalhamento urbano com o consumo de energia com transportes, através de imagens de satélite para obter melhor visualização das áreas efetivamente urbanizadas. Estas foram obtidas através do ajuste das imagens da superfície da Terra captadas pelo sensor TM (“*Thematic Mapper*”) do satélite *Landsat* e georeferenciadas com o auxílio de um *software* de Sistema de Informações Geográficas. Este ajuste permitiu a visualização da mancha urbana no entorno das capitais brasileiras, incluindo suas conurbações (municípios agregados que em geral formam as regiões metropolitanas), a partir do conhecimento da localização das coordenadas centrais dos referidos municípios.

Desta forma, foi possível verificar quais cidades faziam parte das conurbações das capitais brasileiras e obter as novas dimensões das áreas que, de fato, formam a mancha urbana ao redor de cada capital. Observou-se também que muitas vezes as cidades que de fato compunham a mancha urbana não correspondiam àquelas das regiões metropolitanas definidas pelo Instituto Brasileiro de Geografia e Estatística - IBGE.

Após a definição das áreas urbanas, conforme citado acima, foram incluídas as populações relativas às cidades que pertenciam às mesmas manchas urbanas. Com as novas medidas, obteve-se um padrão de área urbana mais próximo da realidade, ou seja, o consumo de energia relacionou-se com áreas que a população tem acesso direto através dos modos motorizados, e não com áreas que, apesar de fazerem parte dos municípios, não são habitadas ou sequer foram desmatadas.

Foi através do consumo de combustível automotivo que Pampolha (1999) pôde estimar a energia que é gasta para movimentar os meios de transporte de cada cidade. Os combustíveis considerados na pesquisa foram: a gasolina automotiva, o óleo diesel e o álcool combustível. Nas capitais que possuíam sistemas de trólebus (São Paulo e Recife) e metrô (São Paulo, Rio de Janeiro e Porto Alegre) foi ainda considerado o consumo de energia elétrica para movimentá-los.

As cinco capitais (algumas delas incluindo cidades conurbadas) que apresentaram o menor gasto de energia *per capita* com transporte, em ordem crescente de consumo, foram: João Pessoa, Teresina, Salvador, Fortaleza e Belém. Na média, seus habitantes consumiram cerca de 10.280 megajoules *per capita*, no ano de 1996.

Em um outro extremo, estão as cinco capitais que mais consumiram energia *per capita* com transportes naquele mesmo ano, são elas, em ordem decrescente: Boa Vista, Cuiabá, Rio Branco, Porto Velho, e Campo Grande. Os habitantes destas cinco cidades consumiram, em média 37.020 megajoules *per capita*, durante aquele ano. Este valor é cerca de 260% superior à média de consumo das cidades mais econômicas.

Visando contribuir com as discussões acerca do tema, onde há uma linha de pesquisadores que consideram a forma urbana, mais precisamente a densidade populacional, como grande responsável pelo elevado consumo de energia com transportes (Newman e

Kenworthy, por exemplo) e, por outro lado, há aqueles que discordam desta opinião e afirmam que os fatores econômicos são decisivos nos padrões de consumo de energia (Gordon e Richardson podem ser referenciados), a proposta deste trabalho é realizar novos estudos em cidades ainda não pesquisadas, no contexto de um país em desenvolvimento.

Neste caso, serão estudadas as cidades do estado de São Paulo com população superior a 50 mil habitantes, com exceção da região conurbada no entorno da capital. Dentre as diversas técnicas disponíveis para análises desta natureza, desde as mais tradicionais, como a regressão linear, até outras mais recentes, como as Redes Neurais Artificiais, optou-se pela última, por oferecer algumas vantagens, que estão descritas no capítulo seguinte.

3. REDES NEURAIIS ARTIFICIAIS

Segundo Brondino (1999), a modelagem através de redes neurais artificiais aparece como um substituto potencial aos modelos estatísticos convencionais, devido à fácil interface dos programas com o usuário e a não necessidade de conhecimentos prévios da relação entre as variáveis envolvidas. Ao contrário de modelos estatísticos usados para o mesmo fim, a utilização deste método não requer a verificação de nenhuma suposição, como, por exemplo, o estudo da relação entre as variáveis independentes e da distribuição do distúrbio aleatório, como ocorre no caso da Regressão Múltipla.

Neste contexto, as Redes Neurais Artificiais surgem como uma alternativa bastante atraente. Uma Rede Neural Artificial (RNA) é baseada na estrutura biológica do cérebro humano através de uma analogia com o funcionamento dos neurônios e tem como objetivo fornecer subsídios para que o computador extraia características dos dados a partir de um conjunto de situações conhecidas e, desta forma, consiga estender tais informações para uma situação real. Prova da eficiência deste tipo de modelagem são vários estudos efetuados na engenharia de transportes (Brega, 1996; Furtado, 1998; Brondino, 1999; Wermersch & Kawamoto, 1999; Coutinho Neto *et al.*, 1999, Coutinho Neto, 2000 e Raia Jr., 2000), o que comprova o bom desempenho deste método com relação a modelos matemáticos convencionais.

Além disso, a escolha de redes neurais apresenta dentre outras vantagens: processamento em tempo real, desenvolvimento das relações entre as variáveis pela própria

rede, tolerância no que diz respeito a erros ou distúrbios de entrada (pela sua arquitetura, a própria rede é capaz de proporcionar uma saída correta para uma entrada deste tipo), além da não necessidade de determinadas condições impostas pelos métodos estatísticos (Trippi & Turban, 1992 *apud* Brondino, 1999).

Conforme Bittencourt (1996 *apud* Furtado, 1998) as redes neurais artificiais são ferramentas importantes na resolução de problemas, visto que apresentam as seguintes propriedades:

- Têm capacidade de aprender através de exemplos e de generalizar esse aprendizado, para reconhecer propriedades similares que não foram usadas no processo de treinamento;
- Apresentam bom desempenho para encontrar soluções em situações onde o conhecimento não está explícito;
- Não requerem conhecimento sobre os modelos matemáticos usados nos domínios das aplicações;
- São pouco afetadas na presença de informações ausentes, falsas ou com ruídos.

Assim, diante dos bons resultados que vêm sendo observados pelo emprego das Redes Neurais Artificiais em várias áreas e, em particular, na Engenharia de Transportes e dada a natureza do problema analisado, a utilização desta técnica parece adequada para a pesquisa aqui proposta. Em virtude disto, uma breve revisão bibliográfica sobre RNA é apresentada na seqüência.

3.1. Aspectos da inteligência artificial e analogia biológica

Com o surgimento do computador, o homem sentiu-se mais próximo de realizar um sonho antigo: construir equipamentos capazes de desempenhar tarefas semelhantes às dele. A ânsia em produzir uma máquina com tais requisitos fez com que surgisse um ramo

da ciência da computação responsável por esta questão, denominado inteligência artificial (IA).

Segundo Galvão & Valença (1999), a rede neural artificial é uma ramificação da IA, pertencente à classe do aprendizado mecânico. As RNAs são modelos computacionais que buscam reproduzir o funcionamento do cérebro humano, no seu processo de aquisição e recuperação de conhecimento. Os modelos computacionais tradicionais são eficazes em resolver problemas matemáticos, porém não são capazes de reconhecer padrões com o mesmo sucesso. As RNAs apresentam como vantagem o fato de resolverem problemas complexos que envolvem reconhecimento de padrões, assim como o cérebro humano.

O cérebro das pessoas é um sistema de processamento de informação que tem a capacidade de organizar os neurônios de tal forma, que seu desempenho na execução de certas tarefas (reconhecimento de exemplos, percepção e controle motor) dá-se de forma muito mais rápida do que o mais rápido computador hoje existente, ainda que sua velocidade de processamento seja relativamente baixa quando comparada a este. Sendo composto por cerca de 10 bilhões de neurônios que se interconectam, formando uma verdadeira rede, o cérebro é capaz de processar milhões de informações e realizar algo em torno de 60 trilhões de ligações sinápticas, o que o qualifica como uma coleção de redes neurais (Galvão & Valença, 1999).

De maneira geral, pode-se definir uma rede neural artificial como um sistema constituído por elementos de processamento interconectados, também chamados de neurônios artificiais, os quais estão dispostos em camadas (uma camada de entrada, uma ou várias intermediárias e uma de saída) e são responsáveis pela não-linearidade da rede, através do processamento interno de certas funções matemáticas. Estas redes neurais artificiais possuem alguma forma de regra de aprendizagem, que é responsável pela modificação dos pesos sinápticos a cada ciclo de iteração, de acordo com os exemplos que lhes são apresentados. Assim, pode-se dizer que as redes neurais artificiais aprendem com exemplos.

Uma vez que as redes neurais artificiais têm sua base de fundamentação na neurotransmissão ocorrida nas células nervosas, é importante que se conheça o funcionamento de um neurônio biológico e o seu grau de semelhança com um neurônio artificial.

Galvão & Valença (1999) definem, de maneira bastante simples, que o neurônio biológico é composto por um corpo celular, de onde saem ramificações que são os dendritos (similares aos galhos de uma árvore). Desse corpo celular, sai um prolongamento maior do que os dendritos, que é chamado de axônio, cujo terminal é ramificado e denominado de telodendro. A passagem de impulso nervoso entre dois neurônios se dá na região de sinapse, geralmente formada pela união dos axônios de um neurônio e os dendritos do outro. Essa transmissão ocorre quase sempre do axônio de um neurônio para os dendritos do neurônio seguinte, e não no sentido inverso. A Figura 10 ilustra um esquema de neurônio biológico.

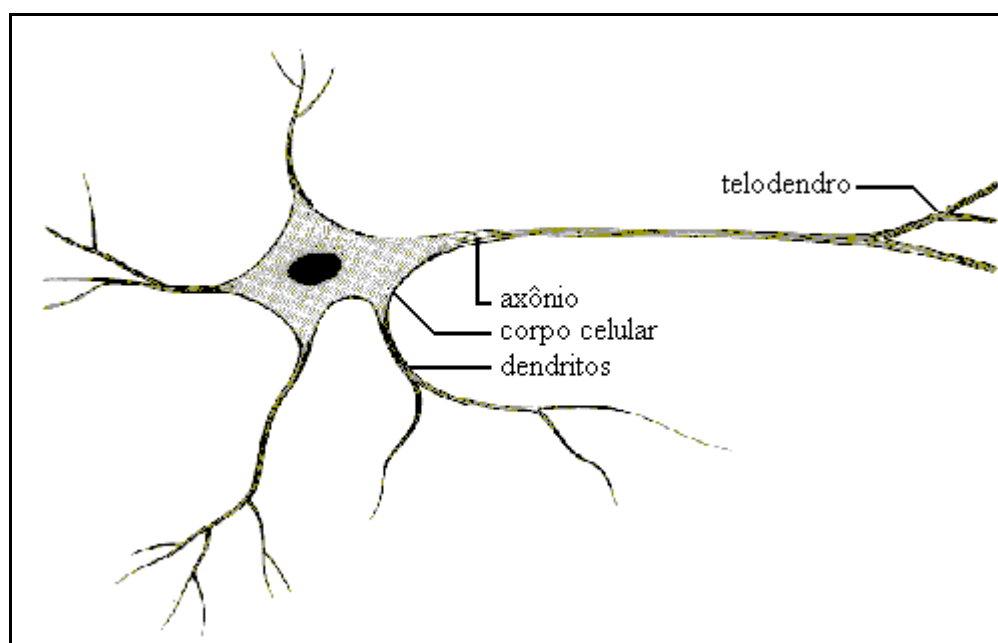


Figura 10: Esquema de um neurônio biológico

Ressalta-se que somente os estímulos com uma mínima intensidade (a partir de um certo limiar, chamado limiar excitatório), são capazes de provocar impulsos nervosos. Portanto, se o estímulo for muito pequeno, isto é, se a sua intensidade for inferior ao limiar excitatório, não ocorrerá nenhum impulso nervoso. Por outro lado, passado este limiar, o

potencial de ação do neurônio será sempre o mesmo, qualquer que seja a intensidade do estímulo.

3.2. Histórico das redes neurais

Em 1943, McCulloch e Pitts propuseram um modelo de neurônio artificial, cuja proposta não era copiar o neurônio biológico, mas sim modelá-lo (Beale & Jackson, 1990). Tratava-se de um modelo extremamente simples de neurônio, com entradas excitatórias e inibitórias. Quando o número de entradas excitatórias excedesse o número de entradas inibitórias, o neurônio sofreria uma ativação e produziria uma saída igual a 1, caso contrário a saída seria 0, ou seja, o neurônio proposto não apresentava um limiar (*threshold*). Tal limiar corresponde a um valor que determina se o neurônio vai ou não responder à determinada entrada, permanecendo inibido se a entrada total for menor que o mesmo e, excitado quando for maior, ocorrendo uma propagação do estímulo recebido.

Em 1949, Hebb propôs uma forma de aprendizado para as redes neurais, a qual ele denominou aprendizado “hebbiano”. Por esta lei de aprendizado, se dois neurônios estiverem ativos simultaneamente, a conexão entre eles deverá ser reforçada (Haykin, 1994).

Nos anos 50, Rosenblatt adicionou limiares aos neurônios e propôs um procedimento pelo qual a rede poderia aprender, ajustando sistematicamente seus pesos sinápticos. Esta rede foi batizada de *perceptron* e podia aprender problemas simples de classificação (Luger & Stubblefield, 1989 *apud* Brondino, 1999). Porém, este modelo era bastante limitado, como será visto a seguir.

Em 1969, Minsky e Papert mostraram que a rede *perceptron* não era capaz de resolver o problema do ou-exclusivo, ou seja, só poderia classificar padrões linearmente separáveis, fato que culminou com um desaquecimento do estudo sobre redes neurais, que só voltaram à tona nos anos 80, quando alguns problemas apresentados pelo *perceptron* passaram a ser resolvidos através do uso de novos modelos. Em 1986, Rumelhart, Hinton e Willians desenvolveram as redes de várias camadas, conhecidas como *multilayer perceptron* (MLP).

Neste caso em particular, as redes neurais com várias camadas (*multilayer perceptron*) são indicadas como ferramenta de análise devido à sua elevada capacidade de reconhecimento de padrões. Sendo assim, faz-se necessário um esclarecimento dos componentes envolvidos nas redes neurais artificiais, a partir do seu elemento fundamental: o neurônio artificial.

3.3. Neurônio artificial

O neurônio artificial é uma unidade de processamento matematicamente simples, que recebe uma ou mais entradas e as transforma em saídas. Cada entrada tem um peso associado, que determina sua intensidade (Haykin, 1994). A Figura 11 mostra um esquema de neurônio artificial.

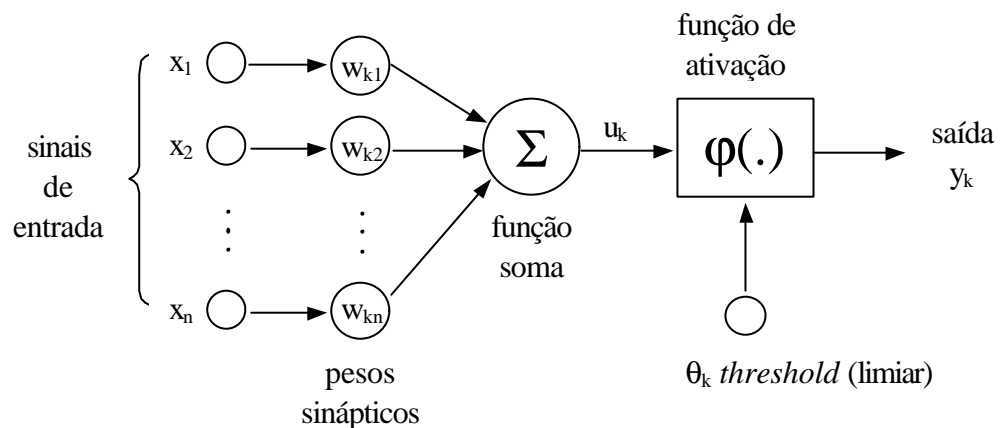


Figura 11: Modelo não linear de um neurônio.

Fonte: Haykin (1994).

É possível distinguir alguns elementos importantes do neurônio mostrado na Figura 11:

- As sinapses, que são caracterizadas por um peso, w , o qual representa a sua intensidade. A função do peso w_{kj} é multiplicar o sinal x_j na entrada da

sinapse j , conectada a um neurônio k . O peso w_{kj} será positivo se a sinapse associada for excitatória e negativo se a sinapse associada for inibitória;

- Um somatório, que adiciona as entradas ponderadas pelos seus pesos respectivos, ou seja,

$$u_k = \sum_{i=1}^n w_{ij} x_j \quad (1)$$

- Um limiar (*threshold*), θ_k , que tem uma função determinante na saída do neurônio. Se o valor de u_k for menor que este limiar, então a saída do neurônio fica inibida. Caso contrário, o neurônio fica ativo;
- Uma função de ativação, que funciona como um limitante à amplitude da saída do neurônio, ou seja, a entrada é normalizada dentro de um intervalo fechado, comumente $(0,1)$ ou $(-1,1)$;
- A saída do neurônio y_k , sendo:

$$y_k = \mathbf{j}(u_k - \mathbf{q}_k) \quad (2)$$

onde φ é a função de ativação.

A seguir, são apresentados alguns tipos de função de ativação.

3.4. Tipos de função de ativação

A função de ativação define a saída do neurônio em termos do nível de atividade do mesmo (Haykin, 1994). Dentre as funções de ativação mais comuns, pode-se citar:

- Função linear: $\mathbf{j}_i(t+1) = u_i(t)$ (3)

- Função *threshold* ou limiar: $\mathbf{j}_i(t+1) = \begin{cases} 1, & \text{se } u_i(t) \geq \theta \\ 0, & \text{se } u_i(t) < \theta \end{cases}$ (4)

- Função sigmóide logística: $\mathbf{j}_i(t+1) = \frac{1}{(1 + e^{-u_i(t)})}$ (5)

- Função tangente hiperbólica: $\mathbf{j}_i(t+1) = \frac{(1 - e^{-u_i(t)})}{(1 + e^{-u_i(t)})}$ (6)

- Função linear por partes: $\mathbf{j}_i(t+1) = \begin{cases} +1, & \text{se } u_i(t) > \theta \\ -1, & \text{se } u_i(t) < \theta \\ u_i(t), & \text{em outra parte} \end{cases}$ (7)

Segundo Smith (1996), cada neurônio da camada intermediária e da camada de saída calcula a soma dos pesos de suas entradas e aplica a função de ativação nesta soma, ajustando-a entre os limites de 0 e 1. O gráfico de uma função sigmóide logística tem a forma de um S achatado e pode ser visualizado na Figura 12.




Figura 12: Função sigmóide logística.

3.5. Topologia da rede

A maneira como os neurônios são organizados é chamada de topologia da rede. A topologia afeta o desempenho da rede, assim como as aplicações para as quais ela é concebida. Sua estrutura está intimamente ligada ao algoritmo de aprendizado usado na fase de treinamento. Algumas redes permitem que as conexões caminhem tanto no sentido entrada-saída, quanto saída-entrada. Outras permitem que os neurônios da mesma camada estejam conectados. Ainda há as que permitem que o neurônio envie sinais de volta para ele mesmo (Tubb, 1993 *apud* Brondino, 1999).

Dentre as topologias existentes, enquadra-se a *multilayer perceptron* como sendo a arquitetura mais utilizada, que é formada de uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída. Há também a rede *de Kohonen*, que é formada por uma camada de entrada e uma única camada de saída, em que cada neurônio está conectado a todos os seus vizinhos. Na rede *de Hopfield*, não há neurônios de entrada ou saída. A entrada de um neurônio é a saída dos demais neurônios, e a sua saída será a entrada dos demais neurônios da rede. A rede *ART* é formada por camada de entrada e saída, além de controladores de fluxo de sinais (Brondino, 1999).

Dougherty (1995) fez uma revisão sobre as redes neurais aplicadas na área de Transportes. Neste estudo, ele salienta a importância da rede *multilayer perceptron* e afirma que este tipo de rede, juntamente com o algoritmo *backpropagation*, têm sido os mais utilizados nas pesquisas em Transportes, embora outras topologias também venham sendo empregadas por alguns. Para este trabalho, em particular, foi adotada a rede *multilayer perceptron*, por ser a mais conhecida e utilizada, além de ter apresentado bons resultados em estudos semelhantes.

3.6. Rede *multilayer perceptron*

Diante do problema de que a rede *perceptron*, que é constituída de apenas duas camadas (uma de entrada e outra de saída), só consegue classificar padrões que sejam

linearmente separáveis, uma possibilidade de melhoria desta limitação seria usar mais que um *perceptron*. Nesta situação, cada um seria empregado para distinguir seções linearmente separáveis de entrada, combinando suas saídas em outro *perceptron* (Beale & Jackson, 1990).

A nova rede arranja as unidades *perceptron* em camadas e o novo modelo passa a ser chamado *multilayer perceptron*, passando a contar com uma ou mais camadas de neurônios intermediárias. Cada unidade pertencente à camada intermediária funciona como o *perceptron*, exceto porque sua função de ativação é a sigmoideal ou a *threshold*. Esta escolha pelo tipo de função de ativação é para que a atualização dos pesos ocorra de forma mais suave, ou seja, sem sofrer alterações bruscas. A topologia de uma rede *multilayer perceptron* com três camadas (sendo uma de entrada, uma intermediária e outra de saída) está apresentada a seguir, na Figura 13. Neste caso, cada neurônio artificial está representado por um círculo e suas conexões por linhas.




Figura 13: Rede *multilayer perceptron* com uma camada intermediária.

3.7. Algoritmos de aprendizado

Segundo Braga *et al.* (2000), denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem vários tipos de algoritmos de aprendizado, que são específicos para determinados modelos de redes neurais e que diferem entre si, principalmente, pela forma com que os pesos são

atualizados. Os paradigmas de aprendizado, por sua vez, definem a maneira com que a rede relaciona-se com o ambiente. Existem quatro grupos de algoritmos de aprendizado, a saber: supervisionado, por reforço, não supervisionado e por competição.

Para o aprendizado supervisionado, apresenta-se à rede, na fase de treinamento, um conjunto de entradas com suas respectivas saídas. O objetivo é minimizar o erro, que é uma função da diferença entre a saída desejada e aquela fornecida pela rede. Esta minimização ocorre através do ajuste dos pesos da rede. Um exemplo deste paradigma de aprendizado é o método *backpropagation*, que será aqui utilizado e, portanto, melhor discutido no item seguinte.

O aprendizado por reforço pode ser visto como um caso particular de aprendizado supervisionado. A principal diferença entre o aprendizado supervisionado clássico e o aprendizado por reforço é a medida de desempenho usada em cada um dos sistemas. No aprendizado por reforço, a única informação de realimentação fornecida à rede é se uma determinada saída está correta ou não, isto é, não é fornecida à rede a resposta correta para o padrão de entrada.

No aprendizado não supervisionado, a rede aprende por si só, sem uma mensagem de erro externa, ou seja, sem supervisão. É necessário que entradas parecidas sejam apresentadas à rede, para que esta possa extrair características estatisticamente relevantes e criar classes de forma automática. Apesar da semelhança entre o aprendizado supervisionado e o aprendizado dos seres humanos, muitos dos sistemas biológicos ocorrem através de aprendizado não-supervisionado, como por exemplo, os estágios iniciais dos sistemas de visão e audição. Para estes algoritmos, somente os padrões de entrada estão disponíveis para a rede, ao contrário do aprendizado supervisionado, cujo conjunto de treinamento possui pares de entrada e saída. A partir do momento em que a rede estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se nela uma habilidade de formar representações internas para codificar características da entrada e criar novas classes ou grupos automaticamente. Este tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada. Sem redundância seria impossível encontrar quaisquer padrões ou características dos dados de entrada.

O aprendizado por competição, por sua vez, é um caso particular de aprendizado não-supervisionado. A idéia neste caso é, dado um padrão de entrada, fazer com que as unidades de saída disputem entre si para serem ativadas. Existe, portanto, uma competição entre as unidades de saída para decidir qual delas será a vencedora e, conseqüentemente, terá sua saída ativada e seus pesos atualizados no treinamento. As unidades de entrada são diretamente conectadas às unidades de saída, e estas últimas também podem estar ligadas entre si via conexões laterais inibitórias, ou negativas. A unidade de saída com maior ativação inicial terá maior chance de vencer a disputa com as outras unidades, que perderão o poder de inibição ao longo do tempo sobre a unidade de maior ativação. A unidade mais forte fica ainda mais forte, e seu efeito inibidor sobre as outras unidades de saída torna-se dominante. Com o tempo, todas as outras unidades de saída ficarão completamente inativas, exceto a vencedora.

3.8. Regra delta generalizada ou *backpropagation*

A regra de aprendizado mais utilizada para treinar uma rede *multilayer perceptron* é denominada “regra delta generalizada” ou, mais comumente, “*backpropagation*”.

Quando um padrão é apresentado à rede pela primeira vez, esta produz uma saída aleatória. A diferença entre esta saída e a desejada constitui o erro. A função da fase de treinamento é buscar constantemente diminuir o valor deste erro. Para tanto, o valor dos pesos deve ser ajustado a cada nova iteração. A regra *backpropagation* faz com que os pesos da camada de saída sejam os primeiros a serem ajustados e, posteriormente, os pesos das demais camadas, de trás para frente.

Seja E_p a função erro para o padrão p , d_{pj} o valor da saída desejado (para o padrão p e o neurônio j), o_{pj} o valor da saída obtido e w_{ij} o peso do neurônio i para o neurônio j . Então, a função E_p pode ser dada por:

$$E_p = \frac{1}{2} \sum_j (d_{pj} - o_{pj})^2 \quad (8)$$

Portanto, o objetivo é minimizar esta função de erro. Se esta for simples, a rede tem garantia de encontrar solução. Caso contrário, a rede pode cair em um mínimo local e não produzir uma saída satisfatória.

A atualização dos pesos ocorre com a adição de um termo de variação a eles (Δw_{ij}), ou seja, para um peso w_{ij} o seu peso atualizado será dado por:

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij} \quad (9)$$

onde:

$$\Delta w_{ij} = \mathbf{h}x_i o_j (1 - o_j) \mathbf{d}_j \quad (10)$$

$$\mathbf{d}_j = (d_j - o_j), \text{ para a última camada} \quad (11)$$

$$\mathbf{d}_j = \sum w_{jk} \mathbf{d}_k, \text{ para camadas intermediárias} \quad (12)$$

A variável η é denominada taxa de aprendizado. Seu valor vai determinar o quão suavemente será a atualização dos pesos. Se η for grande, o valor de Δw_{ij} será grande e, conseqüentemente os pesos sofrerão uma alteração mais brusca.

Uma outra variável, que pode ser incluída na atualização de pesos é o *momentum* (μ). Este novo termo pode aumentar a velocidade do aprendizado e tem como característica acelerar o treinamento em regiões planas da superfície de erro. Com a adição do *momentum*, Δw_{ij} passa a ser dado por:

$$\Delta w_{ij}(t+1) = \mathbf{h}x_i o_j (1 - o_j) \mathbf{d}_j + \mu [\mathbf{h}x_i o_j (1 - o_j) \mathbf{d}_j + \mathbf{h}x_i o_j (1 - o_j) \mathbf{d}_j - w_{ij}(t) - w_{ij}(t-1)] \quad (13)$$

A atualização de pesos pode ocorrer de duas maneiras: por padrão ou por ciclo. Na primeira, os pesos são atualizados após a apresentação de cada padrão. Na segunda, os pesos são atualizados após a apresentação de todos os padrões. A maneira a ser utilizada é função da aplicação. Se o conjunto de dados for grande e redundante (poucos

padrões e muitas entradas, por exemplo), a primeira será mais indicada. Caso contrário, quando o conjunto apresentar muitos padrões a serem classificados, será preferível a atualização por ciclo.

O algoritmo *backpropagation* apresenta algumas dificuldades de aprendizado. Em superfícies muito complexas, o treinamento é muito lento e existe o risco da rede cair em um mínimo local. Além disso, pode ocorrer *overfitting*, fenômeno que surge depois de um certo tempo de treinamento, quando a rede memoriza os padrões que já foram apresentados e o processo de classificação piora sensivelmente. Para evitar estes tipos de problemas, Braga *et al.* (2000) recomendam alocar para a rede um número de neurônios intermediários suficientes para a solução do problema de reconhecimento de padrões, tomando-se cuidado para não utilizar nem neurônios demais, o que pode levar a rede ao *overfitting*, nem um número muito pequeno, que pode forçar a rede a gastar tempo em excesso, tentando encontrar uma representação ótima.

De acordo com Smith (1996), o risco de a rede memorizar os dados ocorre em função de um excessivo poder da mesma, sendo que este poder deve ser limitado para que não ocorra *overfitting*. Uma das formas de se precaver de tal fenômeno e reduzir o problema de ruído é aumentar o número de elementos da amostra. Na prática, porém, há severas restrições com relação ao tamanho da amostra, tornando o número de exemplos disponíveis geralmente mais baixo que o número estatisticamente desejável, em virtude da indisponibilidade de todas as informações desejadas. E, à medida que o problema se torna mais complexo ou o nível de ruído cresce, o tamanho da amostra estatisticamente desejável aumenta muito rapidamente. Desta forma, surgem outras maneiras de se restringir o poder da rede neural, como limitar a quantidade de neurônios na camada intermediária e o número de ciclos de treinamento.

Mesmo sabendo dos cuidados necessários para sua utilização, optou-se por trabalhar com a rede *multilayer perceptron* associada com o algoritmo *backpropagation*, em virtude dos bons resultados que vêm apresentando na solução de problemas de natureza semelhante ao aqui enfrentado. Além do mais, tais peculiaridades deste tipo de rede podem ser controladas, na medida em que se busca iterativamente uma configuração de melhor

desempenho, através do menor valor do erro quadrático médio, por exemplo, que será mais bem discutido no método deste trabalho.

Em seguida, visando elucidar ainda mais a aplicabilidade das Redes Neurais Artificiais em problemas de planejamento urbano e transportes, é apresentado um exemplo real que compara os resultados de um método tradicional (no caso, a regressão linear múltipla) com RNAs.

3.9. Exemplo comparativo entre RNA e regressão linear múltipla

Brondino (1999) realizou um trabalho sobre o processo de avaliação de imóveis para fins de cobrança de impostos, com o intuito de criar uma sistemática de tributação mais justa da propriedade urbana, onde a valorização de terras ociosas devido à acessibilidade aos meios de transporte e à infra-estrutura deveria ser levada em conta.

Dentre os critérios de modelagem matemática utilizados para avaliação imobiliária, incluem-se alguns métodos estatísticos. Segundo Brondino (1999), embora eficientes, desde que utilizados por pessoas capacitadas, em geral, eles podem estar comprometidos por vários fatores, como por exemplo: complexidade dos modelos, dificuldade de implementação, excesso de variáveis envolvidas e desconhecimento das relações entre estas variáveis. Nesta categoria enquadram-se os modelos de regressão linear múltipla, onde descontinuidades e não linearidades podem destruir a eficácia de toda uma análise. Por outro lado, as Redes Neurais Artificiais aparecem como uma alternativa bastante atraente na resolução de problemas desta espécie.

Diante disto, o trabalho realizado por Brondino (1999) visou identificar as variáveis que interferem no valor das propriedades, através do emprego das RNAs e da regressão linear múltipla, comparando os resultados obtidos por ambos os métodos. Como medida de desempenho e critério de comparação, utilizou-se o erro relativo total (Σerros), cuja fórmula é dada pela equação (14).

Brondino (1999) ordenou seu conjunto de dados três vezes, de forma aleatória, gerando três conjuntos distintos e garantindo uma análise eficiente dos dados

coletados. Para cada conjunto, calculou-se o erro através da equação (14), sendo, posteriormente, determinada a média aritmética destes valores tanto para regressão quanto para RNAs.

$$\sum \text{erros} = \sum \left| \frac{o - e}{o} \right| \quad (14)$$

onde: o representa o valor observado;
 e o valor estimado pelo modelo;

A comparação dos resultados obtidos pelos dois métodos está representada na Tabela 3 e mostra que o erro relativo total obtido pelo modelo de regressão ficou em torno de 43% maior que aquele fornecido pelas Redes Neurais, o que significa que neste caso as RNAs tiveram um desempenho superior ao método tradicional de regressão linear múltipla.

	Σ Erros	
	Regressão	RNA
Conjunto 1	29,49	18,77
Conjunto 2	18,99	12,88
Conjunto 3	22,61	17,98
Média ± Desvio padrão	23,70 ± 5,33	16,54 ± 3,20

Tabela 3: Valores de erro relativo total para os dois métodos empregados.

Além do melhor desempenho das Redes Neurais sobre a regressão neste caso, aferido pelos menores valores de erros, Brondino (1999) ratifica ainda mais a aplicabilidade deste novo método em problemas de planejamento urbano e transportes ao mencionar a maior facilidade de aplicação com relação à estatística tradicional. Ainda com o intuito de frisar a praticidade e o entendimento da RNA após a mesma ter sido treinada, um

exemplo bastante simples é apresentado no próximo item, o qual refere-se a uma rede desenvolvida com o *software EasyNN* e reproduzida, após o treinamento, através de uma planilha eletrônica.

3.10. Exemplo de RNA reproduzida em uma planilha eletrônica

O *software EasyNN* fornece alguns exemplos de Redes Neurais Artificiais já treinadas. Entre eles, pode-se citar um que busca replicar o comportamento da rede treinada através de uma planilha eletrônica, a fim de se tornar explícito o procedimento de cálculo do valor do neurônio de saída a partir dos valores de entrada do modelo. Visando facilitar a compreensão da lógica das RNAs, acrescentou-se este exemplo neste item. Trata-se de uma rede com dois neurônios na camada de entrada, dois neurônios na camada intermediária e apenas um neurônio na camada de saída, que pode ser visualizada na Figura 14. A Figura 15 ilustra numericamente este problema.




Figura 14: RNA replicada através de uma planilha eletrônica.

A lógica para o cálculo do neurônio de saída, a partir dos valores de entrada da rede neural treinada, é bastante simples. Primeiramente, o valor do neurônio de entrada é normalizado no intervalo entre 0 e 1, através da equação (15).

$$norm = \frac{real - mín}{máx - mín} \quad (15)$$

onde: *norm* representa o valor normalizado entre 0 e 1;
real o valor observado;
mín o menor valor observado da variável;
máx o maior valor observado da variável.

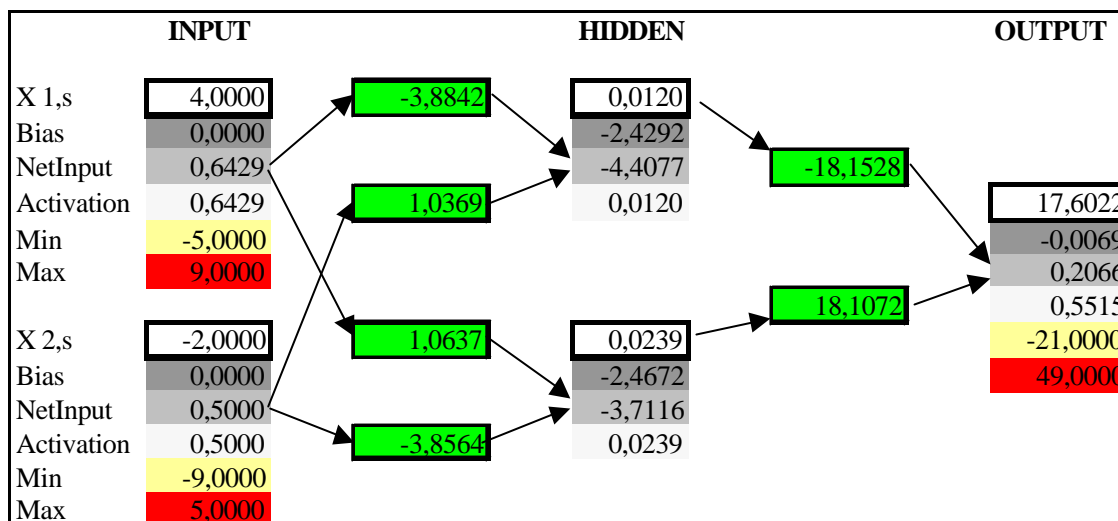


Figura 15: Planilha de cálculo utilizada para replicar a RNA treinada.

Numericamente, a situação para o primeiro neurônio de entrada é a seguinte: substituindo-se o valor *real* por “4,0000”, *mín* por “-5,0000” e *máx* por “9,0000”, tem-se *norm* igual a “0,6429”. Para o segundo neurônio de entrada o cálculo é análogo, e o valor de entrada “-2,0000” foi convertido para “0,5000”, dados os limites “-9,0000” e “5,0000”. Após terem sido normalizados, os valores de entrada são multiplicados pelos pesos das conexões entre os neurônios da camada de entrada e os da camada intermediária e somados. Nesta etapa, também são acrescentados os valores de *Bias* de cada neurônio da camada intermediária, conforme indica a equação (16), e calculadas as funções de ativação, neste caso, sigmóide logística, com a equação (17).

$$u_k = Bias + \sum_{i=1}^n w_{ij} x_j \quad (16)$$

$$j^k = \frac{1}{(1 + e^{-uk})} \quad (17)$$

onde: u_k é a soma dos pesos

$\mathbf{j}k$ é a função de ativação

Os valores dos pesos das ligações e de *Bias* são fornecidos diretamente pelo *software* de RNA, após o treinamento da rede. No exemplo dado, no caso do primeiro neurônio da camada intermediária, o mesmo é calculado da seguinte forma:

$$u_k = -2,4292 + 0,6429 \times (-3,8842) + 0,5000 \times (1,0369) = -4,4077 \quad (18)$$

$$\mathbf{j}k = \frac{1}{(1 + e^{-(-4,4077)})} = 0,0120 \quad (19)$$

Após aplicar a função de ativação no valor obtido com a equação (16), ter-se-á o valor do neurônio da camada intermediária. O procedimento de obtenção do neurônio de saída, a partir dos neurônios da camada intermediária é o mesmo para a obtenção destes últimos, a partir da camada de entrada. No entanto, o valor obtido após aplicada a função de ativação pela segunda vez estará normalizado. Para obter o valor real de saída, basta aplicar a equação (20).

$$real = norm \times (máx - mín) + mín \quad (20)$$

Numericamente, tem-se:

$$real = 0,5515 \times (49,0000 + 21,0000) - 21,0000 = 17,6022 \quad (21)$$

4. MÉTODO

O método desta pesquisa seguiu, em linhas gerais, a investigação pioneira desenvolvida por Newman & Kenworthy (1989a e 1989b) e o trabalho posterior de Næss (1995). Todas estas obras buscaram, de uma forma ou de outra, explicar as relações entre o consumo de energia com transportes e a forma urbana.

Particularmente, este trabalho está restrito ao caso do estado de São Paulo, o qual possui 645 municípios, cujas faixas de população são demonstradas na Tabela 4 (conforme a Contagem da População de 1996, realizada pelo Instituto Brasileiro de Geografia e Estatística – IBGE). Como pode ser observado nesta Tabela, 81% da população total do estado viviam em 106 municípios com mais de 50 mil habitantes, os quais, em princípio, constituiriam a amostra desta pesquisa por tratarem-se de uma parcela bastante significativa da população total do estado. Cidades de porte inferior a estas podem não possuir transporte público urbano e, portanto ter características muito diferentes da amostra adotada, o que poderia comprometer os resultados do trabalho proposto.

A seguir, são descritos os métodos para a obtenção de dados relacionados à forma urbana, bem como algumas variáveis sócio-econômicas que foram investigadas. Vale ressaltar a dificuldade de aquisição dos mesmos, por tratarem-se de valores referentes aos municípios, já que a grande maioria das estatísticas disponíveis é agregada por estado ou região, o que limita bastante a quantidade de variáveis investigadas. No final deste item, está

descrito o método de processamento das variáveis com Redes Neurais Artificiais, bem como algumas das principais características do simulador de RNA empregado.

Faixa de população	Municípios	População por faixa
Menor que 10.000 habitantes	305 (47%)	1.417.004 habitantes (4%)
10.001 a 20.000 habitantes	118 (18%)	1.642.558 habitantes (5%)
20.001 a 50.000 habitantes	116 (18%)	3.574.879 habitantes (10%)
50.001 a 100.000 habitantes	50 (8%)	3.576.963 habitantes (11%)
100.001 a 500.000 habitantes	50 (8%)	10.279.409 habitantes (30%)
Maior que 500.000 habitantes	6 (1%)	13.628.297 habitantes (40%)
TOTAL	645 (100%)	34.119.110 habitantes (100%)

Tabela 4: Distribuição das cidades paulistas, por faixas de população.

Fonte: Contagem da População de 1996, IBGE (1997).

4.1. Variáveis relativas à forma urbana

A primeira etapa deste trabalho consistiu em identificar as principais características geométricas das manchas urbanas dos municípios paulistas. A partir de imagens de satélite referentes aos anos de 1998 e 1999, o Departamento de Estradas e Rodagem do estado de São Paulo (DER-SP) disponibilizou um arquivo em formato digital vetorizado, já contendo o contorno dessas áreas urbanizadas. Como o arquivo não estava georeferenciado no *software* de SIG utilizado nesta pesquisa (o *TransCAD*, produzido pela *Caliper Corporation*, EUA), primeiramente fez-se necessária a sua conversão em imagens de formato TIFF (*Tagged Image File Format*). Posteriormente, as imagens TIFF foram incorporadas ao SIG, ajustando-as às suas reais localizações geográficas, através de, no mínimo, três pontos não alinhados de coordenadas conhecidas, de maneira que o mapa todo estivesse georeferenciado com latitudes e longitudes corretas.

Após terem sido georeferenciadas no *TransCAD*, as manchas urbanas foram analisadas uma a uma com o intuito de se verificar a existência de áreas urbanas contíguas pertencentes a municípios vizinhos. Também conhecidas como conurbações, estas áreas foram identificadas através da sobreposição de uma camada de pontos referentes aos centros geográficos dos municípios. Desta forma, analisaram-se as características geométricas das manchas urbanas da região conurbada como um todo e não mais como áreas independentes.

Prosseguiu-se com o processo para obtenção dos padrões de forma, desenhando com o “*mouse*” sobre os contornos das manchas urbanas, olhando diretamente para a tela do computador, através de uma nova camada do tipo área que representava as áreas urbanizadas em questão, processo conhecido como “*heads-up digitizing*”. A partir daí foram criadas outras camadas de informações, com as quais se determinou o raio envolvente (*Raio*) e as maiores dimensões nas direções Leste-Oeste (*L-O*) e Norte-Sul (*N-S*). Estas camadas estão ilustradas na Figura 16, a qual mostra a cidade de São Carlos como exemplo. Para que fossem obtidos *L-O* e *N-S* de maneira correta, desenharam-se retângulos cujos lados eram equivalentes aos pontos mais extremos das manchas urbanas, nas direções Leste-Oeste e Norte-Sul. Dessa maneira, procurou-se garantir que os comprimentos *L-O* e *N-S* estivessem ortogonais e efetivamente nas direções desejadas.

Através de ferramentas do *software* de SIG, foi possível calcular e indicar no banco de dados as seguintes características relativas à forma urbana: a área urbanizada (*Aurb*), a área do menor círculo que envolve a mancha urbana (*Acirc*), o raio deste círculo (*Raio*) a relação *Aurb/Acirc*, os comprimentos extremos nas direções Leste-Oeste (*L-O*) e Norte-Sul (*N-S*), bem como a relação *L-O/N-S* (com o intuito de se verificar a importância de um desenvolvimento maior em uma direção do que na outra). Os valores de *Aurb*, *L-O* e *N-S* foram agregados ao banco de dados de maneira automática, ou seja, ao finalizar o desenho de uma determinada cidade, os mesmos eram atualizados pelo *software*. Já nos demais casos, alguns procedimentos adicionais fizeram-se necessários.

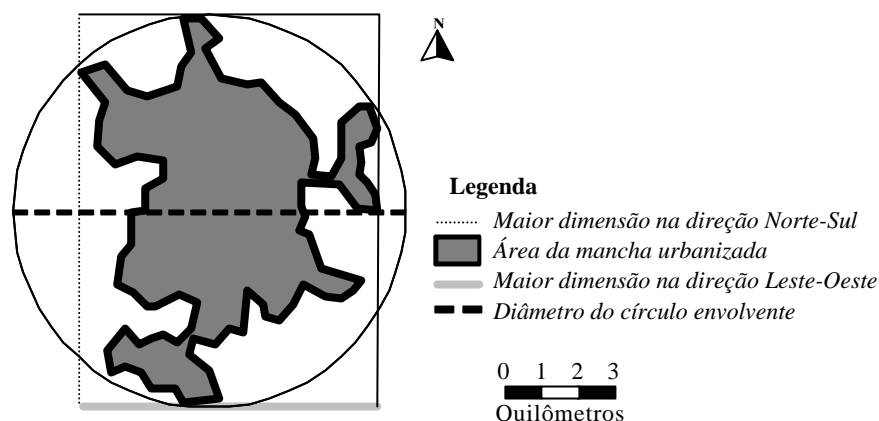


Figura 16: Camadas criadas com o *software* de Sistemas de Informações Geográficas, relativas à cidade de São Carlos.

Para se obter *Acirc*, obviamente era preciso dispor de *Raio*, pois o círculo desenhado não estava vinculado ao banco de dados e, portanto, sua área não era fornecida diretamente. Sendo assim, calculou-se *Raio* como sendo a metade do diâmetro do círculo mostrado na Figura 16, visto que o valor fornecido ao banco de dados era o diâmetro e não o raio do círculo. Procedeu-se, então, ao cálculo de *Acirc* e da relação *Aurb/Acirc*, visando estipular um índice que fosse capaz de representar a proporção de vazios urbanos. Quanto menos vazios, mais próxima da unidade seria *Aurb/Acirc*. Vale salientar que este índice refere-se somente aos vazios externos da área urbanizada e não aos vazios internos, fato que seria de suma importância se fosse considerado na análise, uma vez que cidades paulistas de médio porte – como Bauru, Araraquara e Ribeirão Preto – já demonstraram ter grandes parcelas de suas áreas urbanas desocupadas (entre 50% e 60%, conforme Raia Jr., 1995 *apud* Silva *et al.*, 2000 e Azevedo, 1981 *apud* Silva *et al.*, 2000). No entanto, em virtude da indisponibilidade de tais informações referentes a todos os municípios analisados, optou-se por trabalhar somente com *Aurb/Acirc* por representar um tipo de vazios urbanos, ou seja, os vazios externos à área urbanizada (ou o grau de compacidade da área urbanizada).

4.2. Variáveis sócio-econômicas

Completando a etapa de aquisição de dados, procedeu-se a busca de informações sócio-econômicas pertinentes à análise. Algumas variáveis citadas na literatura internacional que poderiam interferir no consumo de energia com transportes não puderam ser analisadas em virtude da indisponibilidade das mesmas, como são os casos de frota de veículos automotores, extensão da rede viária, velocidade média do tráfego, nível de serviço do transporte público e preço de combustíveis. Dados de população urbana (*Pop_urb*) foram obtidos em uma Base de Informações Municipais, contendo totais relativos à Contagem da População de 1996 (IBGE,1997). Com estas informações e as áreas urbanizadas determinadas com o uso do SIG, calcularam-se as densidades populacionais urbanas (*Dens_urb*), como sendo a razão entre *Pop_urb* e *Aurb*. Contudo, deve-se observar que os mesmos cuidados tomados no levantamento das variáveis espaciais com relação às regiões contíguas, ou seja, às conurbações, foram considerados no caso das variáveis sócio-econômicas. Desta forma, garantiu-se que todas as variáveis envolvidas no modelo estivessem agregadas por conurbação quando esta fosse verificada visualmente no *TransCAD*.

O grau de escolaridade foi representado pelo número médio de anos de estudo do chefe do domicílio (*Anos_est*), cujos valores foram obtidos na página mantida na Internet pelo SEADE (2001), assim como a renda média do chefe do domicílio (*Renda*) em salários mínimos e o número de empregos no comércio (*Emp_com*), indústria (*Emp_ind*) e serviços (*Emp_serv*). A porcentagem de vias pavimentadas (*Vias_pav*) foi extraída de IBGE (2001). As variáveis *Anos_est* e *Renda* são relativas ao ano de 1991, já que em 1996 não foram levantados estes dados. No entanto, as demais variáveis sócio-econômicas referem-se a 1996.

Finalmente, completou-se este banco de dados com a variável de saída do modelo, ou seja, o consumo anual de energia com transportes (*Energia*). Tal variável foi compilada por Pampolha (1999), que por sua vez adquiriu os dados na Agência Nacional do Petróleo (ANP) e junto à Empresa Brasileira de Planejamento de Transportes (GEIPOT).

São dados de 1996, relativos aos consumos de gasolina, óleo diesel, álcool e, até mesmo, energia elétrica gasta em metrô, trem e trólebus. Como forma de padronizar as unidades, estes valores foram convertidos por Pampolha (1999) em energia consumida com transportes, em megajoules (MJ).

4.3. Variáveis envolvidas no consumo de energia com transportes

A Tabela 5 contém todas as variáveis de entrada (independentes) investigadas, tanto as relativas à forma urbana como as sócio-econômicas, além da variável de saída (dependente) do modelo: a energia consumida com transportes.

Variável	
<i>Anost_est</i>	Número médio de anos de estudo do chefe do domicílio
<i>Aurb/Acirc</i>	Relação entre área urbanizada e área do círculo envolvente
<i>Dens_urb</i>	Densidades populacionais urbanas
<i>Emp_com</i>	Número de empregos no comércio
<i>Emp_ind</i>	Número de empregos na indústria
<i>Emp_serv</i>	Número de empregos em serviços
<i>L-O/N-S</i>	Relação entre os comprimentos nas direções L-O e N-S
<i>Pop_urb</i>	População residente na zona urbana
<i>Renda</i>	Renda média do chefe do domicílio
<i>Vias_pav</i>	Porcentagem de vias pavimentadas
<i>Energia</i>	Consumo anual de energia com transportes

Tabela 5: Variáveis consideradas no modelo.

A fim de identificar as relações entre as variáveis envolvidas que influenciavam o consumo de energia com transportes, bem como suas importâncias relativas,

procedeu-se à análise através das Redes Neurais Artificiais, através de procedimentos que serão detalhados a seguir.

4.4. Processamento das variáveis através de Redes Neurais Artificiais

Conforme Braga *et al.* (2000), a capacidade de aprender através de exemplos e de generalizar a informação aprendida é, sem dúvida, o atrativo principal da solução de problemas através de Redes Neurais Artificiais (RNAs). Outra característica importante é a capacidade de auto-organização e de processamento temporal, que faz das RNAs uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos, onde a relação das variáveis não ocorre de forma linear.

Segundo Brondino (1999), para uma análise eficiente através das Redes Neurais Artificiais, o conjunto de dados deve ser ordenado três vezes, de forma aleatória, gerando três conjuntos distintos. Este procedimento é necessário para que em cada fase do método (treinamento, validação e teste) sejam utilizados dados distintos em cada conjunto, uma vez que os primeiros 50% dos dados são destinados à fase de treinamento, os 25% seguintes são para validação e os últimos 25% são relativos à etapa de teste.

Como, em geral, a escolha do número de camadas escondidas e de neurônios em cada uma destas camadas que garantem o melhor desempenho se dá por experimentação, redes com várias configurações precisam ser testadas. Cada configuração de rede tem de ser testada para cada um dos três conjuntos de dados e um valor de erro precisa ser calculado em cada caso, como por exemplo, o erro quadrático médio (EQM), cuja fórmula é dada pela equação (22). Desta forma, são gerados três valores de erro para cada topologia (um para cada conjunto de dados), sendo, em seguida, calculada a média destes três erros. Assim, o valor mínimo para esta média conduz à melhor topologia, ou seja, à configuração de rede que fornece estimativas mais próximas aos valores observados.

$$EQM = \frac{\sum (o - e)^2}{n} \quad (22)$$

onde: o representa o valor observado;
 e o valor estimado pelo modelo;
 n é igual ao número de registros.

Uma vez determinada a melhor configuração de rede, através da aplicação dos valores de validação na equação (22), o passo seguinte é calcular novos valores de EQMs, utilizando-se, porém, os dados separados para teste dos modelos. Este procedimento é fundamental porque simula o comportamento da RNA para uma situação real, ou seja, no cálculo do novo EQM são apresentados dados que não foram previamente apresentados à rede nas fases de treinamento e validação. Finalmente, a relevância de cada variável pode ser verificada através das importâncias relativas fornecidas diretamente pelo *software* de RNA utilizado, denominado *EasyNN* e desenvolvido por Stephen Wolstenholme, no Reino Unido, cujas características principais são comentadas no item seguinte.

De posse dos valores das importâncias relativas, uma nova rede deve ser treinada, considerando-se apenas as variáveis mais relevantes como dados de entrada. O percentual de representação de uma variável que a torne irrelevante depende do autor e do assunto. Para este caso em particular, se a variável tivesse percentual igual ou inferior a 7% nos três conjuntos de dados, excluir-se-ia a mesma do modelo.

4.5. O simulador de Redes Neurais Artificiais *EasyNN*

O *software* utilizado para construir as Redes Neurais Artificiais foi o *EasyNN 7.1*, desenvolvido por Wolstenholme (2001). Este simulador é de fácil aplicação, sendo composto por ícones que facilitam o projeto das RNA. O número de camadas intermediárias, bem como a quantidade de neurônios que as compõem, podem ser estipulados automaticamente pelo aplicativo ou manualmente pelo operador, admitindo, no máximo, a criação de três camadas intermediárias, sendo que, normalmente, uma ou duas camadas já são suficientes. As redes criadas são do tipo *multilayer perceptron* e o algoritmo de

aprendizado é o *backpropagation*, com função de ativação do tipo sigmóide. Os dados para a criação dos arquivos para o processo de aprendizado podem ser gerados com base em arquivos em formato de texto ou planilhas eletrônicas.

O simulador *EasyNN* gera os seguintes resultados: um arquivo tipo texto, com todos os resultados do conjunto de validação e teste (contendo as variáveis de entrada e saída previstas pela rede), o gráfico de erro gerado durante o processo de aprendizado, os pesos das conexões entre neurônios, e um gráfico contendo as importâncias relativas de cada variável de entrada no modelo. Este último possibilita identificar e ordenar as variáveis que mais interferem no consumo de energia com transportes, que é a principal meta desta pesquisa.

5. ANÁLISE PRÉVIA DOS DADOS COLETADOS

Neste capítulo são listados os municípios do estado de São Paulo com população superior a 50 mil habitantes, conforme a Contagem da População de 1996. Também são apresentadas as conurbações identificadas com o auxílio dos recursos de um SIG, bem como os bancos de dados contendo todas as variáveis investigadas. Finalmente são mostrados alguns gráficos e comentários sobre a energia consumida nas cidades paulistas e nas capitais de estados brasileiros, fazendo um paralelo entre estas cidades.

5.1. Municípios

Os 106 municípios pertencentes ao estado de São Paulo com população superior a 50 mil habitantes em 1996 são apresentados, em ordem alfabética e separados por faixa de população, nas Tabelas 6, 7 e 8. As Figuras 17, 18 e 19 ilustram as posições geográficas dos referidos municípios.

50 municípios paulistas com população entre 50 mil e 100 mil habitantes				
Amparo	Caieiras	Itapeva	Mococa	São Roque
Andradina	Campo L. Paulista	Itapira	Moji-Mirim	Sertãozinho
Araras	Caraguatatuba	Itatiba	Ourinhos	Taquaritinga
Arujá	Cruzeiro	Jaboticabal	Penápolis	Tatuí
Assis	Cubatão	Jandira	Pirassununga	Tupã
Atibaia	Fernandópolis	Leme	Poá	Ubatuba
Avaré	Franco da Rocha	Lençóis Paulista	Ribeirão Pires	Valinhos
Bebedouro	Guaratinguetá	Lins	Salto	Várzea Paulista
Birigui	Ibiúna	Lorena	Sant. de Parnaíba	Votorantim
Caçapava	Itanhaém	Matão	S. J. Boa Vista	Votuporanga

Tabela 6: Relação das cidades paulistas com população entre 50 mil e 100 mil habitantes.

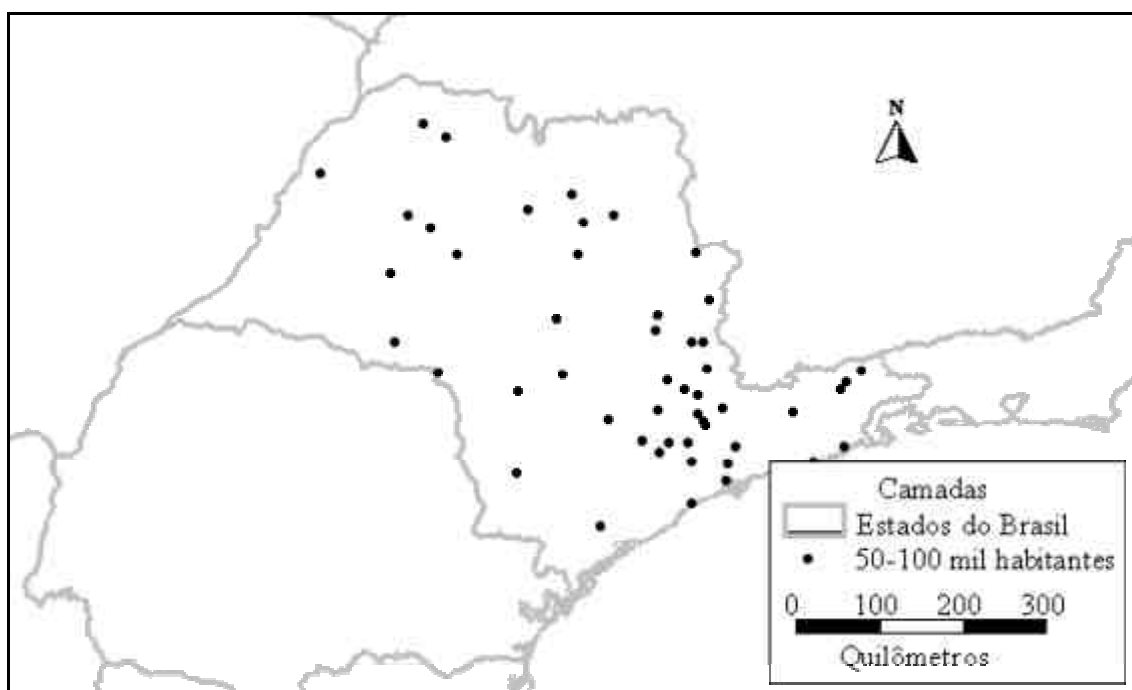


Figura 17: Cidades paulistas com população entre 50 mil e 100 mil habitantes.

50 municípios paulistas com população entre 100 mil e 500 mil habitantes				
Americana	Cotia	Itapetininga	Moji das Cruzes	São Caetano do Sul
Araçatuba	Diadema	Itapevi	Moji-Guaçu	São Carlos
Araraquara	Embu	Itaquaquetuba	Pindamonhangaba	S. J. do Rio Preto
Barretos	Ferraz de Vasc.	Itu	Piracicaba	S. J. dos Campos
Barueri	Franca	Jacareí	Praia Grande	São Vicente
Bauru	Francisco Morato	Jaú	Presidente Prudente	Sorocaba
Botucatu	Guarujá	Jundiaí	Ribeirão Preto	Sumaré
Bragança Paulista	Hortolândia	Limeira	Rio Claro	Suzano
Carapicuíba	Indaiatuba	Marília	S. Bárbara d'Oeste	Taboão da Serra
Catanduva	Itapeçerica da Serra	Mauá	Santos	Taubaté

Tabela 7: Relação das cidades paulistas com população entre 100 mil e 500 mil habitantes.



Figura 18: Cidades paulistas com população entre 100 mil e 500 mil habitantes.

6 municípios paulistas com população acima de 500 mil habitantes		
Campinas	Osasco	São Bernardo do Campo
Guarulhos	Santo André	São Paulo

Tabela 8: Relação das cidades paulistas com população acima de 500 mil habitantes.



Figura 19: Cidades paulistas com população acima de 500 mil habitantes.

5.2. Conurbações

A partir das manchas urbanas constantes nas Tabelas 6, 7 e 8 e Figuras 17, 18 e 19 verificaram-se algumas áreas contíguas, por meio de um Sistema de Informação Geográfica (SIG), as quais constam de dois ou mais municípios vizinhos pertencentes a uma mesma conurbação. Estas áreas conurbadas podem ser constatadas na Tabela 9, sendo que a conurbação referida leva o nome da cidade com maior população.

ÁREAS CONURBADAS	
Conurbação	Municípios
Americana	Americana, Nova Odessa e Santa Bárbara D'Oeste
Araraquara	Américo Brasiliense e Araraquara
Barra Bonita	Barra Bonita e Igarapu do Tietê
Campinas	Campinas, Hortolândia, Valinhos e Vinhedo
Itanhaém	Itanhaém, Mongaguá e Praia Grande
Jundiaí	Campo Limpo Paulista, Jundiaí e Várzea Paulista
Santos	Santos e São Vicente
São Paulo	Barueri, Carapicuíba, Diadema, Embu, Ferraz de Vasconcelos, Guarulhos, Itapeperica da Serra, Itapevi, Itaquaquecetuba, Jandira, Mauá, Moji das Cruzes, Osasco, Poá, Ribeirão Pires, Santo André, São Bernardo do Campo, São Caetano do Sul, São Paulo, Suzano e Taboão da Serra
São Roque	Mairinque e São Roque
Sorocaba	Sorocaba e Votorantim
Taubaté	Taubaté e Tremembé

Tabela 9: Área conurbadas, segundo as manchas urbanas visualizadas através do SIG.

Desta forma, os 106 municípios que inicialmente faziam parte do banco de dados, em princípio independentes, reduziram-se para 78 registros em razão das conurbações constatadas. Além desta redução de registros no banco de dados, as cidades de Rio Claro, Santana de Parnaíba e a região conurbada da cidade de São Paulo foram retiradas da amostra. Rio Claro e Santana de Parnaíba foram desconsiderados por apresentarem alguns dados não muito confiáveis, exagerados ou até mesmo incoerentes, se comparados com os demais municípios da amostra. Já a região conurbada de São Paulo apresentou algumas variáveis (população e área urbanizada, por exemplo) com valores excessivamente superiores

aos das demais cidades analisadas, o que a qualifica como muito heterogênea com relação às demais, fato que prejudicaria a análise se fosse incorporada em meio a cidades com características muito diferentes. Finalmente, o banco de dados considerado neste estudo totalizou 75 registros em função das áreas conurbadas levantadas e da disponibilidade de dados confiáveis.

5.3. Banco de dados das cidades ou conurbações paulistas

A seguir, são mostrados os dados coletados para as cidades paulistas ou conurbações (quando constatadas), na Tabela 10. Tratam-se de todos os valores referentes às variáveis que englobam o modelo, tanto as de entrada como a de saída, neste caso apenas a variável *Energia*. Vale ressaltar que a densidade populacional urbana é dada em habitantes/hectare, os valores das variáveis relativas ao número de empregos são *per capita*, a renda média do chefe do domicílio está expressa em salários mínimos e o consumo anual de energia com transportes, cuja unidade é 1000 MJ, é também *per capita*.

	<i>Anos_est</i>	<i>Aurb/Acirc</i>	<i>Dens_urb</i>	<i>Emp_com</i>	<i>Emp_ind</i>	<i>Emp_serv</i>	<i>L-O/N-S</i>	<i>Pop_urb</i>	<i>Renda</i>	<i>Vias_pav</i>	<i>Energia</i>
Americana-SP	5,92	0,29	52,22	0,03	0,11	0,06	0,64	360230,00	4,19	0,88	19,74
Amparo-SP	5,93	0,26	39,16	0,04	0,16	0,10	0,51	44803,00	3,96	0,90	17,94
Andradina-SP	5,40	0,52	37,55	0,03	0,02	0,06	0,85	48743,00	3,13	0,70	19,70
Araçatuba-SP	6,42	0,46	33,67	0,04	0,06	0,08	0,85	157773,00	3,93	0,68	24,12
Araraquara-SP	6,56	0,28	33,84	0,04	0,06	0,10	0,81	182827,00	4,52	0,85	34,33
Araras-SP	5,75	0,54	47,55	0,03	0,10	0,08	0,96	89344,00	4,11	0,95	28,95
Arujá-SP	5,18	0,28	33,39	0,02	0,09	0,06	0,56	45848,00	3,38	0,80	26,66
Assis-SP	6,14	0,42	43,69	0,05	0,03	0,08	0,96	78948,00	3,67	0,70	36,03
Atibaia-SP	5,80	0,30	30,45	0,04	0,06	0,07	0,71	84751,00	4,25	0,70	22,00
Avaré-SP	5,75	0,36	30,21	0,04	0,04	0,05	0,74	64717,00	3,52	0,80	26,05
Barretos-SP	5,92	0,46	46,63	0,03	0,02	0,06	0,68	95689,00	3,43	0,95	20,83
Bauru-SP	7,19	0,38	29,82	0,05	0,06	0,09	0,76	287530,00	4,73	0,70	31,09
Bebedouro-SP	5,56	0,31	48,27	0,04	0,04	0,07	0,89	67864,00	3,76	0,94	22,59
Birigui-SP	5,75	0,45	42,20	0,03	0,17	0,06	0,80	81563,00	3,48	0,95	14,80
Botucatu-SP	6,73	0,33	30,24	0,04	0,05	0,10	0,62	95215,00	4,57	0,85	19,52
Bragança Paulista-SP	5,70	0,32	40,57	0,04	0,06	0,08	0,59	98678,00	3,94	0,80	21,63
Caçapava-SP	6,46	0,49	63,95	0,03	0,08	0,06	0,97	60432,00	4,28	0,95	22,51
Caieiras-SP	5,52	0,22	68,54	0,02	0,08	0,05	0,68	55450,00	3,81	0,90	9,99
Campinas-SP	7,59	0,17	46,53	0,05	0,08	0,13	0,85	980367,00	5,80	0,66	24,22
Caraguatatuba-SP	5,51	0,36	40,60	0,04	0,01	0,06	0,93	63627,00	2,59	0,25	18,16
Catanduva-SP	5,80	0,29	50,22	0,04	0,06	0,08	0,61	98942,00	3,31	0,68	31,50
Cotia-SP	5,78	0,12	76,94	0,04	0,08	0,11	0,29	126956,00	4,57	0,70	18,20
Cruzeiro-SP	6,36	0,28	53,09	0,03	0,06	0,05	0,70	69501,00	3,29	0,67	25,86
Cubatão-SP	5,28	0,35	120,72	0,02	0,17	0,09	0,72	96693,00	3,44	0,85	30,52

	<i>Anos_est</i>	<i>Aurb/Acirc</i>	<i>Dens_urb</i>	<i>Emp_com</i>	<i>Emp_ind</i>	<i>Emp_serv</i>	<i>L-O/N-S</i>	<i>Pop_urb</i>	<i>Renda</i>	<i>Vias_pav</i>	<i>Energia</i>
Fernandópolis-SP	5,43	0,44	37,66	0,04	0,04	0,05	0,99	56186,00	3,19	0,70	25,35
Franca-SP	6,23	0,29	43,71	0,03	0,08	0,05	0,79	261327,00	4,08	0,70	15,96
Francisco Morato-SP	4,22	0,44	50,13	0,01	0,00	0,02	0,72	105881,00	3,23	0,10	3,65
Franco da Rocha-SP	5,03	0,51	105,61	0,02	0,03	0,02	0,65	92831,00	3,58	0,35	5,81
Guaratinguetá-SP	6,59	0,18	33,84	0,04	0,05	0,13	0,87	92107,00	4,05	0,65	15,23
Guarujá-SP	5,20	0,14	88,94	0,02	0,02	0,08	0,77	226357,00	3,23	0,53	14,12
Ibiúna-SP	3,70	0,45	48,00	0,06	0,08	0,08	0,86	19680,00	2,74	0,80	22,38
Indaiatuba-SP	5,62	0,37	47,80	0,03	0,11	0,06	0,80	119346,00	4,39	0,75	16,70
Itanhaém-SP	5,86	0,04	22,24	0,03	0,02	0,07	0,55	234677,00	3,57	0,67	14,67
Itapetininga-SP	6,02	0,39	28,39	0,04	0,04	0,07	1,00	99886,00	3,55	0,70	22,42
Itapeva-SP	4,52	0,56	63,45	0,03	0,04	0,07	0,90	58309,00	2,59	0,60	21,57
Itapira-SP	5,08	0,42	35,28	0,03	0,09	0,08	1,00	54898,00	3,50	0,98	20,66
Itatiba-SP	5,47	0,38	53,54	0,04	0,12	0,14	0,92	63604,00	4,13	0,96	27,93
Itu-SP	5,74	0,37	55,15	0,04	0,13	0,10	0,72	112006,00	4,27	0,90	36,18
Jaboticabal-SP	6,08	0,63	36,80	0,04	0,07	0,08	0,98	58622,00	4,39	0,95	25,24
Jacareí-SP	6,16	0,30	53,13	0,03	0,07	0,08	0,84	158180,00	4,03	0,35	20,07
Jaú-SP	5,91	0,36	47,41	0,04	0,09	0,07	0,94	97088,00	4,00	0,90	21,17
Jundiaí-SP	6,09	0,21	62,53	0,04	0,10	0,08	0,66	405672,00	4,64	0,63	23,80
Leme-SP	5,00	0,60	52,31	0,03	0,05	0,04	0,84	74646,00	3,43	0,82	20,63
Lençóis Paulista-SP	5,28	0,27	42,43	0,04	0,10	0,06	0,68	47653,00	3,97	0,75	30,21
Limeira-SP	5,93	0,48	40,00	0,04	0,10	0,07	0,89	196577,00	3,92	0,90	30,30
Lins-SP	6,61	0,50	54,97	0,04	0,07	0,08	0,89	59096,00	3,74	0,80	16,85
Lorena-SP	6,61	0,46	56,73	0,03	0,04	0,06	0,81	72789,00	3,74	0,80	22,32
Marília-SP	6,52	0,31	31,05	0,05	0,06	0,09	0,64	170746,00	4,17	0,85	23,40

	<i>Anos_est</i>	<i>Aurb/Acirc</i>	<i>Dens_urb</i>	<i>Emp_com</i>	<i>Emp_ind</i>	<i>Emp_serv</i>	<i>L-O/N-S</i>	<i>Pop_urb</i>	<i>Renda</i>	<i>Vias_pav</i>	<i>Energia</i>
Matão-SP	5,22	0,37	53,45	0,03	0,09	0,04	0,83	65742,00	3,84	0,98	27,90
Mococa-SP	5,38	0,38	41,25	0,03	0,06	0,05	0,57	54654,00	3,23	0,78	18,25
Moji-Guaçu-SP	5,50	0,34	37,55	0,03	0,06	0,06	0,60	104988,00	3,74	0,85	8,49
Moji-Mirim-SP	6,16	0,39	34,77	0,04	0,09	0,07	0,76	68714,00	4,14	0,90	15,64
Ourinhos-SP	5,88	0,42	34,47	0,04	0,05	0,06	0,97	81977,00	3,48	0,80	36,32
Penápolis-SP	5,69	0,53	40,60	0,03	0,08	0,06	0,74	46613,00	3,20	0,80	29,79
Pindamonhangaba-SP	6,43	0,33	56,65	0,03	0,08	0,05	0,85	106897,00	3,79	0,80	21,54
Piracicaba-SP	6,66	0,28	54,14	0,04	0,08	0,09	0,70	290935,00	4,82	0,95	24,77
Pirassununga-SP	6,73	0,21	40,35	0,04	0,06	0,11	0,44	54708,00	4,29	0,95	28,12
Presidente Prudente-SP	6,73	0,37	35,76	0,06	0,05	0,12	0,93	162339,00	4,26	0,77	31,84
Ribeirão Preto-SP	7,59	0,48	49,38	0,06	0,04	0,13	0,74	454124,00	5,36	0,92	33,82
Salto-SP	5,59	0,27	58,18	0,03	0,09	0,05	0,92	86928,00	3,79	0,90	14,64
Santos-SP	7,81	0,32	108,35	0,04	0,02	0,14	0,58	689842,00	5,28	0,83	17,91
São Carlos-SP	6,73	0,43	42,40	0,04	0,11	0,09	0,77	164103,00	3,27	0,80	22,73
São João da Boa Vista-SP	5,91	0,43	45,16	0,05	0,06	0,07	0,97	66752,00	3,03	0,90	20,44
São José do Rio Preto-SP	6,95	0,45	44,46	0,06	0,05	0,10	0,80	304893,00	4,74	0,90	31,12
São José dos Campos-SP	7,51	0,28	58,13	0,04	0,09	0,10	0,90	462429,00	5,16	0,82	20,60
São Roque-SP	5,50	0,21	49,45	0,04	0,10	0,07	0,58	72593,00	3,89	0,70	21,60
Sertãozinho-SP	5,30	0,43	57,16	0,03	0,09	0,06	0,97	83509,00	4,28	1,00	32,84
Sorocaba-SP	6,50	0,39	47,36	0,04	0,07	0,07	0,66	514330,00	4,51	0,85	20,89
Sumaré-SP	4,92	0,27	83,62	0,03	0,05	0,03	0,67	166909,00	3,47	0,75	16,87
Taquaritinga-SP	5,41	0,26	57,64	0,03	0,03	0,05	0,74	44842,00	3,23	0,70	24,49
Tatuí-SP	5,65	0,42	42,38	0,04	0,08	0,05	0,80	78312,00	3,48	0,90	37,34
Taubaté-SP	6,94	0,31	42,39	0,04	0,07	0,10	0,95	238463,00	4,41	0,70	17,15

	<i>Anos_est</i>	<i>Aurb/Acirc</i>	<i>Dens_urb</i>	<i>Emp_com</i>	<i>Emp_ind</i>	<i>Emp_serv</i>	<i>L-O/N-S</i>	<i>Pop_urb</i>	<i>Renda</i>	<i>Vias_pav</i>	<i>Energia</i>
Tupã-SP	5,78	0,61	39,26	0,05	0,03	0,08	0,84	58339,00	3,29	0,90	28,91
Ubatuba-SP	5,47	0,19	27,60	0,03	0,01	0,09	0,63	53745,00	3,30	0,70	20,22
Votuporanga-SP	5,78	0,52	36,09	0,04	0,08	0,05	0,98	66483,00	3,21	0,75	20,68

Tabela 10: Banco de dados das cidades paulistas.

5.4. Consumo de energia nas cidades paulistas e nas capitais de estados brasileiros

Com o objetivo de confrontar os valores de energia consumida com transportes nas cidades paulistas com os das capitais brasileiras, reuniram-se alguns dados referentes às capitais dos 27 estados brasileiros, os quais estão expressos na Tabela 11. Aqui sim foi incluída a conurbação relativa à cidade de São Paulo.

Há de se comentar que a variável *Dens_urb* está expressa em habitantes/hectare, *Frota* refere-se ao número total de veículos automotores na cidade, *Vias_pav* é dada em porcentagem e *Energia* é o consumo anual *per capita* com transportes (em 1000 x MJ). Esta tabela mostra os dados coletados para um estudo em paralelo com as capitais dos estados brasileiros, sendo que os mesmos, com exceção de *Frota* e *Vias_pav*, foram obtidos de Pampolha (1999). A frota de veículos automotores foi extraída de GEIPOT (2001), sendo proveniente do ano de 1999, e a porcentagem de vias pavimentadas de IBGE (2001). A Figura 20 ilustra a distribuição do consumo *per capita* anual de energia com transportes nas capitais de estados brasileiros.

	<i>Aurb/Acirc</i>	<i>Dens_urb</i>	<i>Frota</i>	<i>L-O/N-S</i>	<i>Pop_urb</i>	<i>Vias_pav</i>	<i>Energia</i>
Aracaju	0,33	97,56	106206	0,66	444974	40,00	12,98
Belém	0,39	64,34	155152	0,81	1215181	65,00	11,08
Belo Horizonte	0,49	69,78	622390	0,95	2816276	65,80	17,60
Boa Vista	0,36	19,47	38886	1,20	150442	47,00	48,92
Brasília	0,42	66,38	762043	0,96	1692248	90,00	21,25
Campo Grande	0,47	29,15	174362	0,80	592007	43,00	31,81
Cuiabá	0,30	38,52	130964	1,58	628144	49,50	36,50
Curitiba	0,39	43,01	668295	0,96	2066178	42,00	22,37
Florianópolis	0,19	13,31	137639	0,72	526856	60,00	25,47
Fortaleza	0,34	57,07	353493	1,09	1965513	45,00	10,79
Goiânia	0,44	33,21	502750	0,81	1285778	41,50	19,72
João Pessoa	0,18	48,43	105838	0,70	549363	45,00	8,50
Macapá	0,18	65,05	38193	0,35	209663	30,00	13,34
Maceió	0,24	65,88	121209	0,80	667915	63,00	11,39
Manaus	0,49	49,73	169905	0,76	1150193	90,00	18,31
Natal	0,41	83,53	146768	0,91	656037	60,00	12,21

	<i>Aurb/Acirc</i>	<i>Dens_urb</i>	<i>Frota</i>	<i>L-O/N-S</i>	<i>Pop_urb</i>	<i>Vias_pav</i>	<i>Energia</i>
Palmas	0,14	14,43	16903	0,50	82535	25,00	14,00
Porto Alegre	0,26	48,38	602009	0,66	1631066	77,00	21,72
Porto Velho	0,41	35,34	68856	1,58	238421	30,00	32,68
Recife	0,16	135,77	319772	0,45	1697416	48,50	13,10
Rio Branco	0,22	39,72	34367	1,28	201480	50,00	35,17
Rio de Janeiro	0,24	148,40	1592438	1,00	9009675	54,88	13,09
Salvador	0,23	95,27	389613	0,96	2238363	55,00	10,73
São Luís	0,32	68,74	126697	1,45	762172	50,00	15,46
São Paulo	0,48	102,99	4853864	1,31	15323014	72,36	18,52
Teresina	0,40	58,52	121930	0,82	734935	67,50	10,28
Vitória	0,34	34,82	86161	0,88	879072	61,67	17,35

Tabela 11: Banco de dados das capitais de estados brasileiros.




Figura 20: Consumo de energia *per capita* anual nas capitais de estados.

Através de uma análise dos dados apresentados na Tabela 9 e na Figura 20, constatou-se que aproximadamente 4% das capitais dos estados brasileiros consomem menos que 10000 MJ *per capita* por ano, 74% entre 10000 MJ e 25000 MJ, e 22% gastam mais que 25000 MJ. Visando comparar estes valores com os referentes às cidades paulistas analisadas, construiu-se o gráfico da Figura 21. Já, neste caso, cerca de 5% das cidades

paulistas usam menos que 10000 MJ *per capita* por ano, 62% gastam entre 10000 MJ e 25000 MJ e, todavia, 33% têm um consumo acima de 25000 MJ. Frente a estes valores, é possível afirmar que tanto em São Paulo como nas capitais de estados a maioria das cidades consome em média entre 10000 MJ e 25000 MJ *per capita*. No entanto, em São Paulo há uma parcela mais significativa de cidades que gastam mais que 25000 MJ *per capita* se comparadas com a mesma faixa de consumo nas capitais de estados brasileiros (33% contra 22% das capitais). A Figura 22 ilustra bem esta situação.




Figura 21: Consumo de energia *per capita* anual nas cidades paulistas analisadas.




Figura 22: Faixas de consumo de energia das cidades paulistas e das capitais.

Com o intuito de se utilizar os dados coletados como variáveis de um modelo de Redes Neurais Artificiais, uma primeira providência faz-se necessária: verificar se existe alguma indicação de que os mesmos podem, de alguma forma, estar relacionados à variável que se deseja estimar, ou a variável de saída, neste caso a *Energia*. Uma forma preliminar e

bastante eficiente de verificar isto é através do grau de correlação observado entre cada uma das variáveis de entrada e a variável de saída. Em geral, quando o coeficiente de correlação é alto (valor próximo de ± 1), há uma grande possibilidade daquela variável ter forte influência na variável de saída, portanto sua inclusão no modelo pode vir a ser adequada. Por outro lado, valores baixos (próximos de 0) não significam que a variável deva ser necessariamente descartada da análise.

O que se recomenda neste caso é a inclusão no modelo, para fins de teste, primeiro das variáveis de entrada que são mais fortemente relacionadas com a variável de saída. Mais adiante, se com estas variáveis o modelo ainda não satisfizer integralmente as expectativas que se tem dele em termos de desempenho (medido de diferentes maneiras), não há porque não testar a inclusão no mesmo de variáveis aparentemente menos influentes, ou seja, aquelas com coeficiente de determinação mais baixo. Esta lógica, aliás, é semelhante tanto para modelos estatísticos convencionais como para as Redes Neurais Artificiais.

No caso em questão, visando fazer uma análise prévia entre pares de variáveis, buscou-se relacionar as variáveis independentes com o consumo de energia com transportes (variável dependente). Para isto, utilizou-se os bancos de dados das cidades do estado de São Paulo e das capitais de estados brasileiros. Através de diversas tentativas, usando tanto a energia *per capita* como o total consumido na cidade, chegou-se às melhores relações. Na Tabela 12 estão apresentados os coeficientes de determinação (R^2) mais expressivos, considerando inclusive outras funções além da linear. Pode-se verificar que o total de energia consumido com transportes na cidade resultou em valores de R^2 bem mais significativos, se comparados ao consumo de energia *per capita*. As Figuras 23 a 27 ilustram estas relações.

Variável dependente	Variável independente	Conjunto de dados	R ²
Energia total	<i>Frota</i>	Capitais	0,99
Energia total	<i>Pop_urb</i>	Capitais	0,96
Energia total	<i>Pop_urb</i>	Cidades de SP	0,91
Energia <i>per capita</i>	<i>Emp_com</i>	Cidades de SP	0,46
Energia <i>per capita</i>	<i>Dens_urb</i>	Capitais	0,30

Tabela 12: Coeficientes de determinação para as relações bivariadas.




Figura 23: Consumo de energia total anual *versus* frota de veículos automotores, nas capitais de estados brasileiros (com linha de tendência linear).




Figura 24: Consumo de energia total anual *versus* população, nas capitais de estados brasileiros (com linha de tendência linear).




Figura 25: Consumo de energia total anual *versus* população, nas cidades paulistas (com linha de tendência linear).

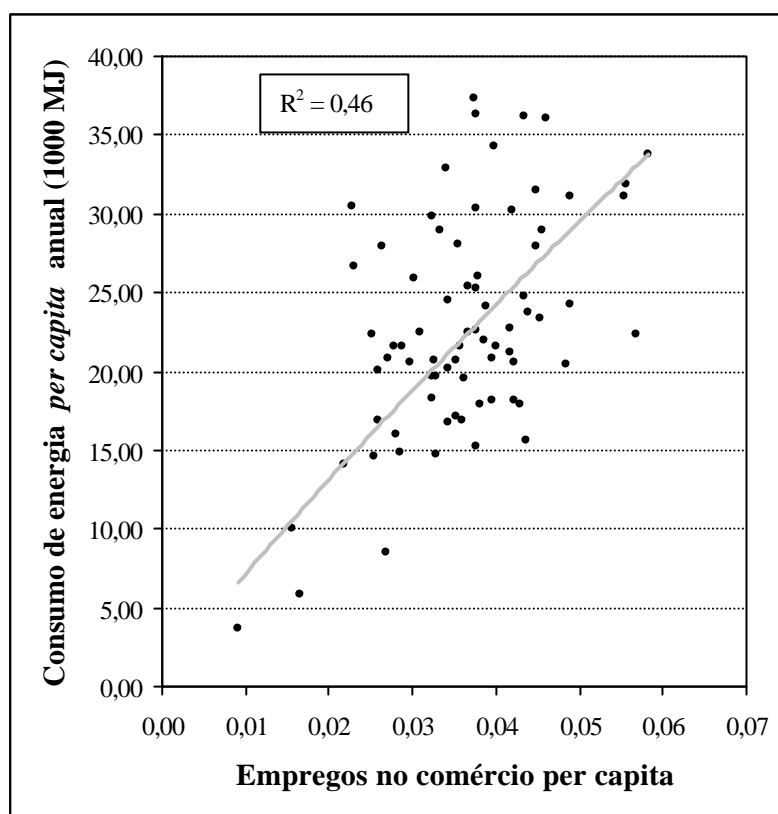


Figura 26: Consumo de energia *per capita* anual *versus* empregos no comércio *per capita*, nas cidades paulistas (com linha de tendência do tipo potência).




Figura 27: Consumo de energia *per capita* anual *versus* densidade populacional, nas capitais de estados brasileiros (com linha de tendência logarítmica).

Através das melhores relações entre as variáveis independentes com o consumo de energia com transportes, que é a variável dependente no caso, pode-se supor que as variáveis *Frota* e *Pop_urb* tenham elevada importância relativa sobre as demais, quando estiverem todas relacionadas com a *Energia*. Isto não implica, contudo, que outras variáveis também não venham a ser relevantes no modelo de Redes Neurais Artificiais, devendo, portanto, ser verificadas no desenvolvimento do mesmo.

No capítulo seguinte são mostrados os resultados encontrados através do emprego das Redes Neurais Artificiais, que é a principal meta deste trabalho, utilizando os dados aqui apresentados. Serão enfatizadas as variáveis mais relevantes no consumo de energia com transportes nas cidades paulistas, bem como outras variáveis que,

provavelmente, seriam importantes se estivessem disponíveis para os municípios do estado de São Paulo.

6. RESULTADOS E ANÁLISES

A seguir são apresentados os resultados obtidos para as cidades paulistas pesquisadas. São mostradas as topologias de Redes Neurais Artificiais com melhores desempenhos, bem como seus respectivos erros quadráticos médios. As importâncias relativas das variáveis envolvidas referentes à melhor configuração de rede também fazem parte deste item. Para explorar outras variáveis, é mostrado um estudo baseado nas 27 capitais de estados brasileiros sobre a importância de se utilizar outras variáveis pertinentes, como por exemplo a *frota de veículos automotores* em um modelo em que a energia consumida com transportes é a variável de saída.

6.1. Resultados

Com as cidades constantes na amostra, inicialmente, foram adotados os dados em sua forma original, para efeito de treinamento de rede. Após diversas tentativas de análise dos dados com Redes Neurais Artificiais de diferentes arquiteturas não foram obtidos resultados satisfatórios, mesmo variando os valores da taxa de aprendizado (η) e *momentum* (μ).

Em uma segunda abordagem, optou-se por um pré-processamento dos dados através de uma normalização tanto das variáveis de entrada como da variável de saída do modelo (energia gasta em transportes *per capita* anual), fazendo com que estivessem

compreendidos entre os valores 0 e 1. Tomando os menores valores de erros dos dados de validação como critérios de seleção das configurações de redes, observou-se que algumas configurações apresentaram resultados relativamente satisfatórios. Os resultados de EQMs para as melhores configurações de RNAs obtidos nesta abordagem são apresentados na Tabela 13 e na Figura 28, onde “ η ” = taxa de aprendizado, “ μ ” = *momentum*, “EQM” = erro quadrático médio e “s” = desvio padrão da amostra. A melhor delas apresentou dez neurônios de entrada, quatro neurônios na primeira camada escondida, quatro neurônios na segunda camada escondida e um neurônio de saída, além de taxa de aprendizado e *momentum* iguais a 0,8. Visando representar o comportamento da RNA em uma situação real, ou seja, perante valores que não foram previamente apresentados à rede na etapa de treinamento, utilizaram-se os registros separados para teste no cálculo de um novo erro quadrático médio. O valor do EQM calculado com os valores de teste foi de $7,63\% \pm 2,40\%$.

$\eta=0,8$ $\mu=0,8$	EQM $\pm s$ (%)	$\eta=0,6$ $\mu=0,6$	EQM $\pm s$ (%)	$\eta=0,3$ $\mu=0,3$	EQM $\pm s$ (%)	$\eta=0,1$ $\mu=0,1$	EQM $\pm s$ (%)
10-4-1	10,89 \pm 0,79	10-4-1	11,03 \pm 1,99	10-4-1	15,31 \pm 4,23	10-4-1	12,81 \pm 4,54
10-6-1	10,41 \pm 1,87	10-6-1	9,27 \pm 1,97	10-6-1	12,03 \pm 1,14	10-6-1	10,24 \pm 0,81
10-8-1	8,97 \pm 1,40	10-8-1	10,60 \pm 1,67	10-8-1	10,62 \pm 1,05	10-8-1	11,15 \pm 1,94
10-4-4-1	7,95 \pm 1,95	10-4-4-1	10,36 \pm 3,84	10-4-4-1	10,79 \pm 2,92	10-4-4-1	13,06 \pm 0,74
10-6-6-1	9,05 \pm 3,01	10-6-6-1	8,86 \pm 1,75	10-6-6-1	9,05 \pm 1,93	10-6-6-1	10,98 \pm 1,86
10-8-8-1	8,70 \pm 2,18	10-8-8-1	10,08 \pm 1,52	10-8-8-1	11,12 \pm 4,00	10-8-8-1	10,22 \pm 1,16

Tabela 13: Valores de EQM para os dados de validação das melhores configurações de redes.

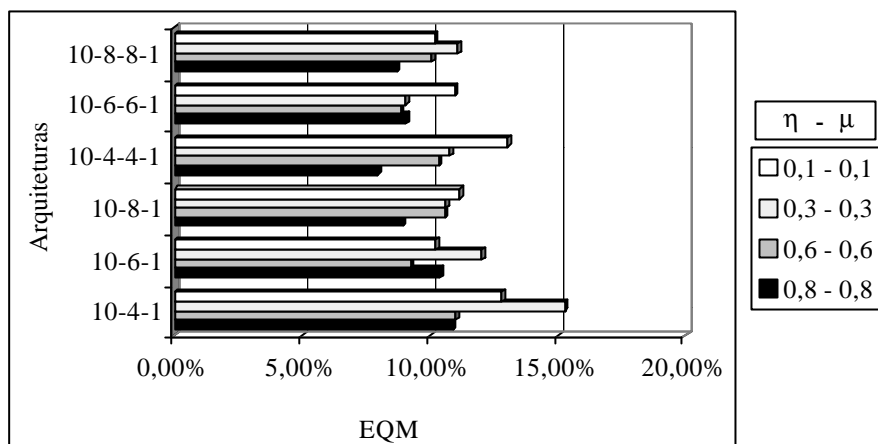


Figura 28: Valores de EQMs obtidos na segunda abordagem.

Com o intuito de aprimorar ainda mais os resultados, fez-se uma nova tentativa de análise, novamente utilizando-se os dados normalizados entre 0 e 1, porém tendo como variável de saída a energia total gasta em transportes por ano na área urbanizada. Como consequência, os valores de EQM baixaram significativamente, conforme pode ser constatado na Tabela 14 e Figura 29, com os dados de validação. Escolhida a melhor configuração (dez neurônios de entrada, quatro neurônios na primeira camada escondida, quatro neurônios na segunda camada escondida e um neurônio de saída, além de taxa de aprendizado e *momentum* iguais a 0,1), o passo seguinte foi o cálculo do EQM com os dados de teste, quando os novos valores obtidos foram de $0,26\% \pm 0,06\%$.

$\eta=0,8$ $\mu=0,8$	EQM $\pm s$ (%)	$\eta=0,6$ $\mu=0,6$	EQM $\pm s$ (%)	$\eta=0,3$ $\mu=0,3$	EQM $\pm s$ (%)	$\eta=0,1$ $\mu=0,1$	EQM $\pm s$ (%)
10-4-1	0,32 ± 0,17	10-4-1	0,59 ± 0,28	10-4-1	0,46 ± 0,18	10-4-1	0,23 ± 0,14
10-6-1	0,30 ± 0,08	10-6-1	0,44 ± 0,14	10-6-1	0,53 ± 0,34	10-6-1	0,25 ± 0,06
10-8-1	0,56 ± 0,36	10-8-1	0,52 ± 0,19	10-8-1	0,44 ± 0,17	10-8-1	0,23 ± 0,04
10-4-4-1	0,27 ± 0,07	10-4-4-1	0,34 ± 0,06	10-4-4-1	0,42 ± 0,16	10-4-4-1	0,21 ± 0,03
10-6-6-1	0,24 ± 0,12	10-6-6-1	0,31 ± 0,10	10-6-6-1	0,61 ± 0,24	10-6-6-1	0,36 ± 0,06
10-8-8-1	0,33 ± 0,17	10-8-8-1	0,29 ± 0,09	10-8-8-1	0,28 ± 0,13	10-8-8-1	0,25 ± 0,05

Tabela 14: Novos valores de EQM para os dados de validação das melhores RNAs.




Figura 29: Novos valores de EQMs (com energia total gasta em transportes).

Outra forma de se avaliar a precisão do modelo é visualizando a relação entre os valores observados da variável de saída e os estimados pelo modelo, utilizando para isto os dados da amostra separados para teste (Smith, 1996). Na Figura 30, cada ponto representa um exemplo de teste de cada conjunto, referente à rede de menor EQM, considerando-se a energia total gasta em transportes como variável de saída, conforme a Tabela 14 e a Figura 29. A linha tracejada diagonal mostra onde os pontos cairiam se os valores previstos fossem idênticos aos valores observados, ou seja, se a rede fosse perfeitamente precisa.

Uma vez determinado o melhor modelo, as importâncias relativas de cada variável relacionada com o consumo de energia com transportes foram fornecidas diretamente pelo software de RNA e podem ser verificadas na Tabela 15 e na Figura 31.

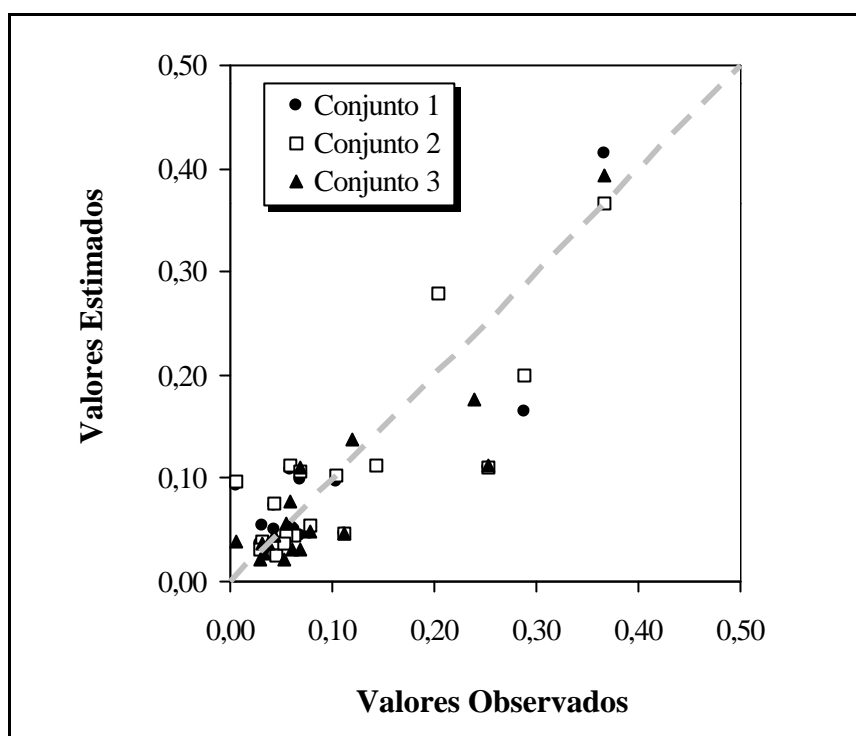


Figura 30: Comparação entre os valores observados e estimados pelo modelo.

Variável	Importância Relativa (%)		
	Conjunto 1	Conjunto 2	Conjunto 3
<i>Anos_est</i>	10,65	11,36	9,10
<i>Aurb/Acirc</i>	7,97	7,83	10,38
<i>Dens_urb</i>	11,19	11,92	9,25
<i>Emp_com</i>	12,73	10,92	9,20
<i>Emp_ind</i>	6,07	6,85	6,08
<i>Emp_serv</i>	2,14	3,40	6,36
<i>L-O/N-S</i>	6,65	5,79	5,70
<i>Pop_urb</i>	21,10	24,94	24,44
<i>Renda</i>	9,76	6,70	9,46
<i>Vias_pav</i>	11,74	10,29	10,03

Tabela 15: Importâncias relativas das variáveis, segundo o *software* EasyNN.




Figura 31: Importância relativa das variáveis de entrada.

Por meio dos valores da importância relativa apresentados na Tabela 15 e na Figura 31, pode-se perceber a grande relevância de variáveis como *Pop_urb*, *Dens_urb* e *Emp_com*, entre outras. Percebe-se também a baixa relevância de outras variáveis no consumo de energia com transportes. Conforme já estipulado no método deste trabalho, as variáveis que obtivessem percentual igual ou inferior a 7% nos três conjuntos de dados deveriam ser retiradas da análise. Sendo assim, *Emp_ind*, *Emp_serv* e *L-O/N-S* foram desconsideradas e uma nova rede foi treinada, mantendo-se as demais variáveis de entrada. Calculou-se um novo erro quadrático médio com os dados de teste, cujo valor obtido foi ainda melhor ($0,22\% \pm 0,03\%$ contra $0,26\% \pm 0,06\%$ anterior). A comparação visual entre os valores observados e os estimados pelo modelo sem as três variáveis de menor desempenho, com os dados de teste da amostra, é apresentada na Figura 32.




Figura 32: Comparação entre os valores observados e estimados pelo modelo, após a retirada das variáveis de pouca relevância.

Da mesma forma que no modelo anterior, as novas importâncias relativas de cada variável de entrada computadas pelo software de RNAs são apresentadas na Tabela 16 e na Figura 33. Tais resultados confirmam a tendência já verificada no modelo anterior com relação às variáveis de maior importância no consumo de energia com transportes nas cidades paulistas pesquisadas. Novamente, a população, a densidade populacional e o nível de empregos no comércio portaram-se como as mais relevantes no total de energia consumida.

Variável	Importância Relativa (%)		
	Conjunto 1	Conjunto 2	Conjunto 3
<i>Anos_est</i>	9,53	10,65	11,86
<i>Aurb/Acirc</i>	8,94	4,87	4,46
<i>Dens_urb</i>	19,56	18,53	18,70
<i>Emp_com</i>	14,91	11,02	11,34
<i>Pop_urb</i>	32,20	33,45	34,49
<i>Renda</i>	5,24	10,12	8,35
<i>Vias_pav</i>	9,62	11,36	10,80

Tabela 16: Importâncias relativas das variáveis.




Figura 33: Importância relativa das variáveis de entrada.

Sabendo que outras variáveis, *a priori* relevantes, poderiam ser incorporadas ao modelo se estivessem disponíveis para as cidades aqui pesquisadas e, com o intuito de se verificar na prática a importância de se utilizar a *frota de veículos automotores* como variável de entrada, analisou-se esta nova variável em um outro contexto, onde a utilização da mesma fosse possível. Em virtude de sua disponibilidade somente para as 27 capitais de

estados brasileiros, procurou-se fazer um estudo através das Redes Neurais Artificiais semelhante ao aqui conduzido, porém relacionando o consumo de energia com transportes nas capitais de estados com algumas variáveis de forma obtidas de Pampolha (1999), além de outras sócio-econômicas adquiridas nas mesmas fontes deste trabalho. Portanto, todas as variáveis utilizadas na análise de RNA com as capitais de estados estão listadas abaixo, na Tabela 17.

Variável	
<i>Aurb/Acirc</i>	Relação entre área urbanizada e área do círculo envolvente
<i>Dens_urb</i>	Densidades populacionais urbanas
<i>Frota</i>	Frota de veículos automotores
<i>L-O/N-S</i>	Relação entre os comprimentos nas direções L-O e N-S
<i>Pop_urb</i>	População residente na zona urbana
<i>Vias_pav</i>	Porcentagem de vias pavimentadas
<i>Energia</i>	Consumo anual de energia com transportes

Tabela 17: Variáveis envolvidas no caso das 27 capitais.

Da mesma forma que nas cidades paulistas, optou-se por um pré-processamento dos dados através de uma normalização de todas as variáveis envolvidas, fazendo com que se enquadrassem entre os valores 0 e 1. Os resultados de erros para as melhores configurações de RNAs (utilizando os dados de validação) obtidos nesta abordagem são apresentados na Tabela 18 e na Figura 34. A melhor delas apresentou seis neurônios de entrada, oito neurônios na camada intermediária e um neurônio de saída, além de taxa de aprendizado e *momentum* iguais a 0,1; sendo que o valor do EQM calculado com os valores de teste foi de $0,04\% \pm 0,02\%$.

$\eta=0,8$ $\mu=0,8$	EQM $\pm s$ (%)	$\eta=0,5$ $\mu=0,5$	EQM $\pm s$ (%)	$\eta=0,1$ $\mu=0,1$	EQM $\pm s$ (%)
6-4-1	0,20 \pm 0,13	6-4-1	0,20 \pm 0,12	6-4-1	0,15 \pm 0,09
6-6-1	0,13 \pm 0,05	6-6-1	0,10 \pm 0,03	6-6-1	0,09 \pm 0,04
6-8-1	0,09 \pm 0,03	6-8-1	0,09 \pm 0,03	6-8-1	0,08 \pm 0,03

Tabela 18: Valores de EQM para os dados de validação das melhores configurações de redes.

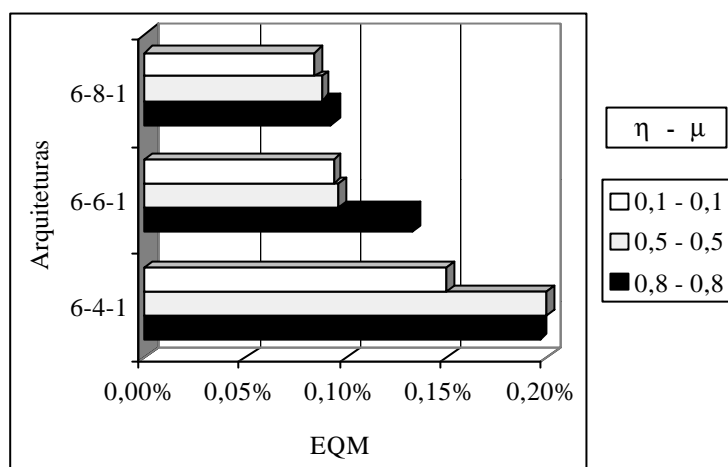


Figura 34: Valores de EQMs obtidos para as 27 capitais brasileiras.

Através da melhor configuração de rede, determinaram-se as importâncias relativas das variáveis de entrada relacionadas com o consumo de energia com transportes no caso das capitais dos estados brasileiros, as quais podem ser constatadas na Tabela 19 e Figura 35.

Variável	Importância Relativa (%)		
	Conjunto 1	Conjunto 2	Conjunto 3
<i>Aurb/Acirc</i>	14,98	14,52	8,99
<i>Dens_urb</i>	18,65	19,51	20,77
<i>Frota</i>	17,53	23,26	26,68
<i>L-O/N-S</i>	8,24	4,36	4,44
<i>Pop_urb</i>	26,77	22,20	20,50
<i>Vias_pav</i>	13,83	16,15	18,62

Tabela 19: Importâncias relativas das variáveis de entrada, segundo o *software* EasyNN.




Figura 35: Importâncias relativas das variáveis de entrada, no caso das 27 capitais.

Os resultados das análises conduzidas para as capitais de estados confirmaram a importância prevista da frota de veículos automotores no que tange ao consumo de energia com transportes, no entanto apontaram o fraco desempenho da variável *L-O/N-S*. Desta forma, embora a importância relativa desta variável para o primeiro conjunto de dados seja superior a 7% (valor mínimo aceitável, estipulado no método deste trabalho), optou-se por retirá-la da análise pela sua baixa importância relativa em dois dos três conjuntos. Um novo valor de EQM foi calculado com os dados de teste, porém constatou-se que não houve alteração no valor do mesmo.

As novas importâncias relativas são apresentadas na Tabela 20 e Figura 36, onde constam as variáveis da análise anterior com exceção da relação entre os comprimentos nas direções Leste-Oeste e Norte-Sul. Pode-se observar que, além da variável frota de veículos automotores, população urbana e densidade populacional apareceram com destaque nesta análise, o que, de certa forma, confirma o estudo realizado com as cidades paulistas, além daqueles efetuados por Newman & Kenworthy (1989a) e Næss (1995), no que tange à importância da densidade populacional no consumo de energia com transportes.

Variável	Importância Relativa (%)		
	Conjunto 1	Conjunto 2	Conjunto 3
<i>Aurb/Acirc</i>	14,08	11,20	10,62
<i>Dens_urb</i>	18,97	18,24	19,64
<i>Frota</i>	25,41	28,03	28,60
<i>Pop_urb</i>	29,72	26,19	23,97
<i>Vias_pav</i>	11,82	16,34	17,17

Tabela 20: Importâncias relativas das capitais de estados (sem a variável *L-O/N-S*).

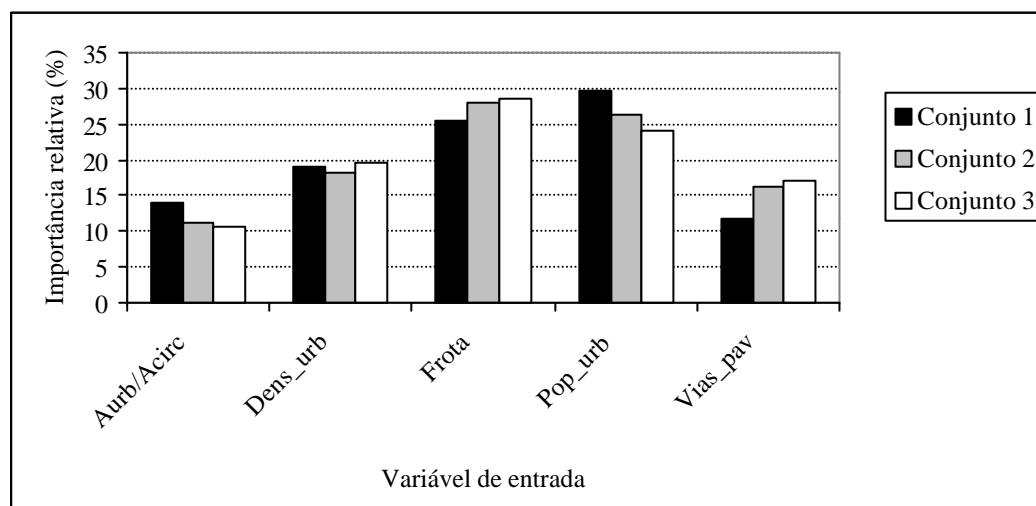


Figura 36: Importâncias relativas das variáveis de entrada (sem L-O/N-S).

6.2. Análise dos resultados

Os resultados encontrados para as cidades paulistas analisadas revelam que a população urbana, a densidade populacional e o nível de empregos no comércio foram as variáveis de maior relevância no consumo de energia com transportes, seguidas da porcentagem de vias pavimentadas e do nível de escolaridade do chefe do domicílio. Contudo, vale salientar que a variável relativa ao rendimento médio do chefe do domicílio é proveniente do ano de 1991, período anterior a uma série de mudanças econômicas - inclusive o “Plano Real”, enquanto que as demais variáveis são mais recentes (após 1996). Este fato pode ter contribuído para um desempenho aquém das expectativas desta variável, que, *a priori*, parecia ser de grande relevância no consumo de energia com transportes.

Ainda é importante frisar que se outras variáveis fossem incorporadas ao modelo das cidades paulistas, este poderia ser ainda mais completo. Fato que pode ser constatado com o bom desempenho da variável frota de veículos automotores no caso das 27 capitais brasileiras, em que o problema seria basicamente o mesmo, ou seja, identificar e classificar, por ordem de importância relativa, as variáveis que efetivamente interferem no consumo de energia com transportes.

7. CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Baseados em estudos teóricos ou observações empíricas, alguns pesquisadores de várias partes do mundo concluíram que cidades espalhadas não seriam as mais eficientes com relação ao consumo de energia com transportes, embora outros afirmem que não exista qualquer relação entre o espalhamento urbano e o gasto de energia, atribuindo neste caso toda a responsabilidade a fatores econômicos, como renda e preço de combustível, por exemplo. Nestas pesquisas, o caso dos países em desenvolvimento raramente tem sido considerado, embora o consumo de energia com transportes tenha crescido consideravelmente nestes países e apresente hoje patamares de consumo relativamente elevados. Este trabalho procurou acrescentar novos resultados acerca deste tema, analisando o impacto de variáveis relativas à forma urbana e sócio-econômicas no consumo de energia com transportes. Para isto foram analisadas as cidades do estado de São Paulo com população superior a 50 mil habitantes, excetuando-se a região conurbada da capital.

Com relação ao levantamento de dados, buscou-se coletar grande parte das variáveis consideradas relevantes pela literatura, uma vez que a maioria dos institutos, agências e órgãos oficiais tiveram seus bancos de dados consultados e aquilo que estava disponível e era pertinente foi incorporado ao modelo. Vale ressaltar, no entanto, as dificuldades de aquisição de dados relativos aos municípios paulistas, já que a grande maioria das estatísticas disponíveis no Brasil é referente ao estado como um todo, ou no máximo, às capitais dos

estados. Este fator, sem nenhuma dúvida, acabou limitando as informações do banco de dados e a investigação de outros aspectos que poderiam afetar o consumo de energia com transportes, tais como: frota de automóveis, extensão da rede viária, velocidade média do tráfego, nível de serviço do transporte público e preço de combustível, por exemplo.

A revisão bibliográfica procurou ser bastante abrangente, buscando informações principalmente em trabalhos internacionais, em virtude da pouca quantidade de material acerca deste tema no Brasil. No exterior, por outro lado, este assunto tem sido objeto de grande interesse e diversos trabalhos tem surgido no cenário internacional, o que viabilizou uma revisão de literatura bem completa, inclusive com um confronto de resultados e opiniões de vários autores.

A técnica de análise através das Redes Neurais Artificiais exige um treinamento de uma série de configurações de rede diferentes, em busca de uma solução mais refinada. Desta forma, foram testadas inúmeras configurações, variando o número de camadas escondidas, o número de neurônios em cada camada, a taxa de aprendizado e o *momentum*. Dentre as diversas redes investigadas, escolheu-se uma delas como sendo a mais representativa, por possuir menor erro quadrático médio. No entanto, esta solução não pode ser considerada ideal e novas configurações podem ser averiguadas em uma outra ocasião, com o intuito de melhorar ainda mais os parâmetros de avaliação da rede.

Em geral, os resultados encontrados nas análises aqui conduzidas confirmam a influência da densidade populacional no consumo de energia com transportes, não deixando de lado, porém, a relevância de algumas variáveis sócio-econômicas. Entre as variáveis que apresentaram maior importância relativa, no caso do estado de São Paulo, pode-se citar: a população urbana, a densidade populacional e o nível de empregos no comércio; contudo, não deixando de lado a porcentagem de vias pavimentadas e o nível de escolaridade. No estudo desenvolvido com as capitais de estados brasileiros, observou-se que a frota de veículos automotores, a população urbana e a densidade populacional destacaram-se entre as demais. É importante reforçar a questão dos vazios urbanos internos não contemplados na relação $Aurb/Acirc$, porém indiretamente considerados na densidade populacional.

Mudanças na estrutura física urbana podem ser vistas como uma solução, a longo prazo, para reduzir o consumo de energia com transportes. Recomenda-se algumas alterações nos padrões de desenvolvimento das cidades, no sentido de seguir a filosofia de cidades compactas, as quais já se mostraram, em diversos estudos, como as mais eficientes energeticamente. Restringir o espalhamento urbano, juntamente com alternativas de substituir o uso exagerado de automóvel pelo transporte público e modos não motorizados, além de melhor planejar o uso do solo, enquadram-se nesta proposta.

Estatísticas recentes alertam para a importância de se buscar soluções que amenizem o elevado consumo de energia com transportes nas cidades brasileiras. Dados oficiais apontam um expressivo aumento da frota de veículos automotores no Brasil, e, conseqüentemente, do consumo de combustível, além de um crescimento ainda acelerado da população urbana. Como resultados deste crescimento descontrolado e da desorganização dos sistemas de transporte urbano surgem maiores distâncias de transporte e grandes deseconomias urbanas, tais como: congestionamentos, poluição ambiental, consumo exagerado de combustíveis e uso inadequado do espaço viário. Neste contexto, quaisquer iniciativas que visem reverter esta situação, para que o país possa desfrutar de uma melhor qualidade de vida para seus habitantes e melhorar o desempenho da sua economia, são relevantes e oportunas.

Desta forma, uma sugestão para trabalho futuro é no sentido de ampliar e aprofundar os estudos anteriores no país, direcionando às cidades de maiores fluxos urbanos do Brasil. De acordo com um estudo coordenado pelo Instituto de Pesquisa Econômica Aplicada (IPEA, 1999), intitulado de “Caracterização e Tendências da Rede Urbana do Brasil”, foram identificados 111 centros urbanos que estruturam a teia municipal do país. A importância destes centros urbanos pode ser medida pelo peso que têm na população nacional. Eles são apenas 2% dos municípios brasileiros, mas, juntos, somavam quase 87 milhões de habitantes em 1996, ou 55% da população total do país. Estes centros urbanos funcionam como os nós da rede urbana do Brasil, polarizando o fluxo de bens, pessoas e serviços entre as cidades brasileiras.

Considerando que toda alternativa para aperfeiçoar a coleta de dados é importante, a abordagem aqui utilizada, que aproveita os recursos de um Sistema de Informações Geográficas para obtenção dos dados espaciais (de forma) das zonas urbanizadas, reúne outras informações sócio-econômicas e os analisa através das Redes Neurais Artificiais é uma combinação de técnicas com potencial para estender o estudo até aqui conduzido.

REFERÊNCIAS BIBLIOGRÁFICAS

Beale, R.; Jackson, T. (1990). *Neural computing: an introduction*. Bristol, Adam Hilger, 240 p.

Braga, A. P.; Ludermir, T. B.; Carvalho, A. C. P. L. F. (2000). *Redes Neurais Artificiais, Teoria e Aplicações*. Livros Técnicos e Científicos Editora S. A., Rio de Janeiro, 262 p.

Brega, J. R. F. (1996). *A utilização de Redes Neurais Artificiais em um sistema de gerência de pavimentos*. Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, 234 p.

Brondino, N. C. M. (1999). *Estudo da influência da acessibilidade no valor de lotes urbanos através do uso de redes neurais*. Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, 146 p.

Coutinho Neto, B. (2000). *Redes Neurais Artificiais como procedimento para retroanálise de pavimentos flexíveis*. Dissertação de Mestrado, Escola de Engenharia de São Carlos, Universidade de São Paulo, 119 p.

- Coutinho Neto, B.; Rodgher, S. F.; Fabbri, G. T. P. (1999) Retroanálise de pavimentos flexíveis através de redes neurais artificiais. *Anais do XIII Congresso de Pesquisa e Ensino em Transportes*, ANPET, São Carlos, v. 1, p. 395-405.
- Dougherthy, M. (1995). *A review of neural networks applied to transport*. *Transportation Research Part C*, v. 3, n.4, p. 247-260.
- Ferraz, A. C. P. (1990). *Sobre a eficiência e a eficácia do transporte público nas cidades médias*. Tese de Livre-Docência em Transportes, Escola de Engenharia de São Carlos, Universidade de São Paulo, 157 p.
- Fouchier, V. (1997). *Urban Density and Mobility: What do we know? What can we do? The case of Paris' region*. Apresentado no *Second Symposium on Urban Planning and Environment*, Groningen, Holanda, 15 p.
- Frank, L. D. (1996). *An analysis of relationships between urban form (density, mix, and jobs: housing balance) and travel behavior (mode choice, trip generation, trip length and travel time)*. *Transportation Research Part A*, v. 30, n.1, p. 76-77.
- Furtado, A. N. D. (1998). *Uma nova abordagem na avaliação de projetos de transporte: o uso das redes neurais artificiais como técnica para avaliar e ordenar alternativas*. Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, 249 p.
- Galvão, C. O.; Valença, M. J. S. (1999). *Sistemas inteligentes: aplicações a recursos hídricos e sistemas ambientais*. Editora da Universidade, Universidade Federal do Rio Grande do Sul, Porto Alegre, 246 p.
- GEIPOT (2001). Anuário Estatístico dos Transportes de 2000. Página na Internet: <http://www.geipot.gov.br/anoario2000/rodoviario/tabelas/574.xls>.

- Gordon, P.; Kumar, A.; Richardson, H. W. (1988). *Beyond the journey to work*. Transportation Research Part A, v. 22A, n. 6, p. 419-426.
- Gordon, P.; Richardson, H. W. (1989). *Gasoline Consumption and Cities: A Reply*. Journal of the American Planning Association, v. 55, n. 3, p. 342-346.
- Greene, R. P. (1997). *The farmland conversion process in a polynucleated metropolis*. Landscape and Urban Planning, v. 36, n. 4, p. 291-300.
- Haykin, S. (1994). *Neural Networks: a comprehensive foundation*. Prentice-Hall, New Jersey, 696 p.
- IBGE (1997). *Base de informações municipais*. Em CD-ROM
- IBGE (2001). *O Brasil, município por município*. Página na Internet: <http://www1.ibge.gov.br/cidades/index2.htm>.
- IPEA (1999). *Caracterização e Tendências da Rede Urbana do Brasil*. Instituto de Economia, Universidade de Campinas, 2 v.
- Kenworthy, J. R.; Laube, F. B. (1999). *Patterns of automobile dependence in cities: an international overview of key physical and economic dimensions with some implications for urban policy*. Transportation Research Part A, n. 33, p. 691-723.
- Mclaren, D. (1992). *Compact or dispersed? Dilution is no solution*. Built Environment, v. 18, n. 4, p. 268-284.
- Newman, P. W. G. (1992). *The compact city: an australian perspective*. Built Environment, v.18, n. 4, p. 285-300.

- Newman, P. W. G.; Hogan, T. (1981). *A review of urban density models: towards a resolution of the conflict between populace and planner*. Human Ecology, p. 269-303.
- Newman, P. W. G.; Kenworthy, J. R. (1989a). *Gasoline consumption and cities: a comparison of U.S. cities with a global survey*. Journal of the American Planning Association, v.55, n. 1, p. 24-37.
- Newman, P. W. G.; Kenworthy, J. R. (1989b). *Cities and automobile dependence: a source book*. Aldershot, England, Gower Technical, 388 p.
- Newman, P. W.G.; Kenworthy, J. R. (1999) *Sustainability and cities: overcoming automobile dependence*. Washington D.C., Island Press, 442 p.
- Newman, P.; Kenworthy, J.; Vintila, P. (1995). *Can we overcome automobile dependence? Physical planning in an age of urban cynicism*. Cities, v. 12, n. 1, p. 53-65.
- Næss, P. (1995). *Urban form and energy use for transport – a nordic experience*. Tese de Doutorado, Norwegian Institute of Technology, 327 p.
- Næss, P.; Sandberg, S. L.; Røe, P. G. (1996). *Energy use for transportation in 22 nordic towns*. Scandinavian Housing & Planning Research, v.13, p. 79-97.
- Pampolha, V. M. P. (1999). *Espalhamento urbano e consumo de energia para transportes: o caso das capitais brasileiras*. Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, 197 p.
- Raia Jr., A. A. (2000) *Acessibilidade e mobilidade na estimativa de um índice de potencial de viagens utilizando redes neurais artificiais*. Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, 202 p.

SEADE (2001). *Banco de dados dos municípios do estado de São Paulo*. Página na Internet: <http://www.seade.gov.br>.

Silva, A. N. R. (1990). *Densidades urbanas econômicas: a influência do transporte público*. Dissertação de Mestrado, Escola de Engenharia de São Carlos, Universidade de São Paulo, 103 p.

Silva, A. N. R. (1993). *O Custo do solo urbano ocioso e uma nova sistemática de tributação da propriedade*. Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, 137 p.

Silva, A. N. R.; Costa, G. C. F.; Brondino, N. C. M.; Ávalos, M. S. (2001). Urban sprawl and energy use for transportation in the largest Brazilian cities. *Anais da 7th International Conference on Computers in Urban Planning and Urban Management*, Honolulu, Havaí, EUA, em CR-ROM.

Silva, A. N. R.; Costa, G. C. F.; Pampolha, V. M. P. (s.d.). *Uma avaliação do consumo de energia por transportes nas capitais brasileiras*. Trabalho submetido para publicação em revista, ainda em fase de avaliação.

Silva, A. N. R.; Lima, R. S.; Waerden, P. V. (1999) The evaluation of urban network patterns with a global accessibility index in a GIS environment. *Anais da 6th International Conference on Computers in Urban Planning and Urban Management*, Veneza, Itália, em CD-ROM.

Silva, A. N. R.; Raia Jr., A. A.; Ferraz, A. C. P. (2000) Minimizing the negative effects of urban sprawl. In: Jenks, M. e Burgess, R. (eds.) *Compact Cities – Sustainable Urban Forms for Developing Countries*, Spon Press, Londres, Inglaterra, 356 p.

- Smith, M. (1996) *Neural networks for statistical modeling*. International Thomson Computer Press, Londres, 235 p.
- Talen, E. (2001). *Traditional Urbanism meets residential affluence: an analysis of the variability of suburban preference*. Journal of the American Planning Association, v.67, n. 2, p. 199-216.
- Wermersch, F. G.; Kawamoto, E. (1999) Uso de redes neurais artificiais para caracterização do comportamento de escolha do modo de viagem. *Anais do XIII Congresso de Pesquisa e Ensino em Transportes*, ANPET, São Carlos, v. 3, p. 31-34.
- Wolstenholme, S. (2001). Simulador de Redes Neurais Artificiais *EasyNN 7.1*. Página na Internet: <http://www.easynn.com>.