

VICTOR FRAZÃO BARRETO ALVES

Explorando Técnicas para a Localização e Identificação de Potenciais Usuários de Transporte Público Urbano

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: Planejamento e Operações de Transportes.

Orientador: Prof. Assoc. Antônio Néelson Rodrigues da Silva

SÃO CARLOS

2011

FOLHA DE JULGAMENTO

Candidato: **Engenheiro Civil Victor Frazão Barreto Alves**

Título da tese: **EXPLORANDO TÉCNICAS PARA A LOCALIZAÇÃO E IDENTIFICAÇÃO DE POTENCIAIS USUÁRIOS DE TRANSPORTE PÚBLICO URBANO**

Data da defesa: 10/05/2011:

Comissão Julgadora:

Resultado:

Prof. Associado **Antônio Nelson Rodrigues da Silva (Orientador)**
(Escola de Engenharia de São Carlos/EESC) APROVADO

Prof^a. Dr^a. **Suely da Penha Sanches**
(Universidade Federal de São Carlos) APROVADO

Prof^a. Dr^a. **Cira Souza Pitombo**
(Universidade Federal da Bahia) APROVADO

Coordenador do Programa de Pós-Graduação em Engenharia de Transportes:
Prof. Associado **Paulo Cesar Lima Segantine**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Paulo Cesar Lima Segantine**

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica preparada pela Seção de Tratamento da Informação do Serviço de Biblioteca – EESC/USP

A474e Alves, Vítor Frazão Barreto
Explorando técnicas para a localização e identificação de potenciais usuários de transporte público urbano / Vítor Frazão Barreto Alves ; orientador Antônio Néilson Rodrigues da Silva. -- São Carlos, 2011.

Dissertação (Mestrado-Programa de Pós-Graduação em Engenharia de Transportes e Área de Concentração em Planejamento e Operação de Sistemas de Transportes -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2011.

1. Transporte público. 2. Mapas potenciais. 3. Potencial de utilização. 4. Marketing do transporte público. 5. Modelos de escolha discreta. 6. Redes neurais artificiais. I. Título.

A meus pais, Jorge e Vera,
por todo amor e apoio.

AGRADECIMENTOS

Ao Prof. Dr. Antônio Néelson Rodrigues da Silva, pela confiança no meu potencial e dedicação durante a realização desse trabalho.

Aos meus irmãos, Vinícius e Rachel, pelo apoio incondicional.

A Hellem, por todo amor e carinho essenciais em tornar os momentos difíceis deste trabalho mais toleráveis.

Aos amigos, tanto os de Salvador quanto os feitos no STT, responsáveis pelos momentos de descontração que deram o ânimo necessário para prosseguir trabalhando. Em especial, a Gustavo, Mateus, Marcelo e Mário, que ainda contribuíram diretamente com o trabalho.

A Hélio Moreira e família, por todo o apoio, sempre que estive em São Paulo.

Aos professores do Departamento de Transportes, por todo conhecimento compartilhado durante as disciplinas ministradas.

Aos funcionários do STT, sempre solícitos, por todos os serviços prestados.

A Peter van der Waerden, pela cessão de dados e, principalmente, pelas dúvidas solucionadas e sugestões dadas ao trabalho.

À Prefeitura Municipal de São Carlos, pelos dados cedidos que contribuíram com a realização desse trabalho.

Ao CNPQ pelo apoio financeiro prestado ao longo do programa de mestrado.

À FAPESP, pelos recursos para obtenção dos dados da Pesquisa Origem-Destino de São Carlos.

A todos que contribuíram indiretamente com a realização deste trabalho.

SUMÁRIO

SUMÁRIO	I
LISTA DE FIGURAS	III
LISTA DE TABELAS	V
RESUMO	VII
ABSTRACT	IX
1 INTRODUÇÃO	1
1.1 CONTEXTUALIZAÇÃO.....	1
1.2 JUSTIFICATIVA.....	3
1.3 OBJETIVO.....	4
1.4 ESTRUTURA DO TRABALHO.....	4
2 MODELOS DE ESCOLHA DISCRETA	7
2.1 INTRODUÇÃO.....	7
2.2 HISTÓRICO.....	8
2.3 MODELOS DE ESCOLHA DISCRETA.....	10
2.4 MODELO LOGIT MULTINOMIAL.....	12
2.4.1 Avaliação da qualidade do modelo calibrado.....	13
3 REDES NEURAIS ARTIFICIAIS	15
3.1 INTRODUÇÃO.....	15
3.1.1 Breve histórico.....	16
3.1.2 Vantagens e desvantagens das Redes Neurais Artificiais.....	18
3.2 O NEURÔNIO ARTIFICIAL.....	19
3.3 REDES MULTILAYER PERCEPTRON.....	22
3.4 PREVISÃO DA ESCOLHA MODAL E REDES NEURAIS ARTIFICIAIS.....	25
4 MAPAS POTENCIAIS DE UTILIZAÇÃO DO TRANSPORTE PÚBLICO	27
4.1 ESTUDO DOS POTENCIAIS USUÁRIOS.....	27
4.2 MAPAS POTENCIAIS DE UTILIZAÇÃO DO TRANSPORTE PÚBLICO.....	32
5 METODOLOGIA	35
5.1 FORMATAÇÃO E TRATAMENTO DOS DADOS.....	35

5.2	COMPARAÇÃO ENTRE OS MODELOS LOGIT AJUSTADOS PARA SÃO CARLOS E WAGENINGEN.....	41
5.3	MELHORIAS NO MODELO LOGIT AJUSTADO PARA SÃO CARLOS	45
5.4	MODELO DE REDES NEURAIIS PARA SÃO CARLOS	45
5.5	EXEMPLO DE EMPREGO DOS MAPAS POTENCIAIS	46
5.6	ATIVIDADES DESENVOLVIDAS.....	47
6	RESULTADOS.....	51
6.1	MODELOS LOGIT PARA SÃO CARLOS E WAGENINGEN	51
6.1.1	<i>Disponibilidade de automóvel</i>	<i>53</i>
6.1.2	<i>Nível de instrução.....</i>	<i>54</i>
6.1.3	<i>Número de linhas a 350 metros</i>	<i>54</i>
6.1.4	<i>Densidade</i>	<i>54</i>
6.2	MELHORIAS NO MODELO LOGIT PARA SÃO CARLOS	55
6.3	MODELO DE REDES NEURAIIS	58
6.4	COMPARAÇÃO ENTRE MODELOS - LOGIT X REDES NEURAIIS	60
6.4.1	<i>Distância ao centro da cidade</i>	<i>61</i>
6.4.2	<i>Densidade</i>	<i>62</i>
6.4.3	<i>Status social</i>	<i>63</i>
6.4.4	<i>Distância à rodovia.....</i>	<i>64</i>
6.4.5	<i>Tipo de família.....</i>	<i>66</i>
6.4.6	<i>Número de linhas de ônibus a 350 metros.....</i>	<i>68</i>
6.4.7	<i>Nível de instrução.....</i>	<i>70</i>
6.4.8	<i>Razão do tempo de viagem entre ônibus e carro</i>	<i>72</i>
6.4.9	<i>Número de pessoas por domicílio.....</i>	<i>73</i>
6.4.10	<i>Disponibilidade do carro.....</i>	<i>74</i>
6.4.11	<i>Avaliação do comportamento das variáveis.....</i>	<i>74</i>
6.5	ELABORAÇÃO DOS MAPAS POTENCIAIS.....	75
7	CONSIDERAÇÕES FINAIS.....	79
7.1	CONCLUSÕES	79
7.2	RECOMENDAÇÕES PARA TRABALHOS FUTUROS	82
8	REFERÊNCIAS.....	85
	ANEXOS	93
	ANEXO A - RESULTADO DO MODELO DE SÃO CARLOS.....	95
	ANEXO B - RESULTADO DO MODELO DE WAGENINGEN.....	97
	ANEXO C - MODELO DE SÃO CARLOS PARA COMPARAÇÃO.....	99
	ANEXO D - RESULTADO DO MODELO DE SÃO CARLOS, AJUSTADO COM NOVAS CLASSES.....	101

LISTA DE FIGURAS

FIGURA 3.1 CAMADAS DE UM PERCEPTRON (SMITH, 1996)	17
FIGURA 3.2 MODELO NÃO-LINEAR DE UM NEURÔNIO; ADAPTADO DE HAYKIN (1994)	20
FIGURA 3.3 TOPOLOGIA DE UMA REDE MLP COM 2 CAMADAS INTERMEDIÁRIAS	23
FIGURA 5.1 DISTRIBUIÇÃO ETÁRIA RELATIVA NAS CIDADES DE WAGENINGEN E SÃO CARLOS	36
FIGURA 5.2 MAPA DE WAGENINGEN COM ZONAS QUE CONTÉM INFORMAÇÕES PARA O ESTUDO	37
FIGURA 5.3 MAPA DE SÃO CARLOS COM DISTRIBUIÇÃO DOS DOMICÍLIOS PESQUISADOS	38
FIGURA 5.4 TRECHO DA PESQUISA DE OPINIÃO REALIZADA EM SÃO CARLOS	40
FIGURA 5.5 DIVISÃO DOS USUÁRIOS SEGUNDO O MODO DE PREFERÊNCIA	42
FIGURA 5.6 MAPA DE SÃO CARLOS COM ZONAS PESQUISADAS	43
FIGURA 6.1 SELEÇÃO DA MELHOR REDE NEURAL	59
FIGURA 6.2 IMPORTÂNCIA DAS VARIÁVEIS	60
FIGURA 6.3 POTENCIAL DE TPU X DISTÂNCIA AO CENTRO DA CIDADE	61
FIGURA 6.4 POTENCIAL DE TPU X DENSIDADE	62
FIGURA 6.5 POTENCIAL DE TPU X STATUS SOCIAL	63
FIGURA 6.6 POTENCIAL DE TPU X DISTÂNCIA À RODOVIA	64
FIGURA 6.7 MAPA DA DISTRIBUIÇÃO ESPACIAL DOS USUÁRIOS DE ACORDO COM A DISTÂNCIA À RODOVIA	65
FIGURA 6.8 POTENCIAL DE TPU X MÉDIA DE IDADE	67
FIGURA 6.9 POTENCIAL DE TPU X IDADE MÍNIMA	67
FIGURA 6.10 POTENCIAL DE TPU X NÚMERO DE LINHAS A 350 M	68
FIGURA 6.11 MAPA COM DISTRIBUIÇÃO ESPACIAL DO NÚMERO DE LINHAS DISPONÍVEIS PARA CADA USUÁRIO	69
FIGURA 6.12 POTENCIAL DE TPU X NÍVEL DE INSTRUÇÃO	70
FIGURA 6.13 MAPA COM DISTRIBUIÇÃO ESPACIAL DO NÍVEL INSTRUÇÃO DE CADA USUÁRIO	71
FIGURA 6.14 POTENCIAL DE TPU X RAZÃO DO TEMPO DE VIAGEM	72
FIGURA 6.15 POTENCIAL DE TPU X NÚMERO DE PESSOAS POR DOMICÍLIO	73
FIGURA 6.16 POTENCIAL DE TPU X DISPONIBILIDADE DE CARRO	74
FIGURA 6.17 MAPA DE ALTA DENSIDADE PARA O MODELO LOGIT	76
FIGURA 6.18 MAPA DE ALTA DENSIDADE PARA A SIMULAÇÃO POR REDES NEURAIS	77
FIGURA 6.19 MAPA COM ÁREAS DE POTENCIAL POSITIVO COINCIDENTES ENTRE OS DOIS MODELOS ..	78

LISTA DE TABELAS

TABELA 5.1 DIVISÃO ETÁRIA NAS CIDADES DE WAGENINGEN E SÃO CARLOS.....	36
TABELA 5.2 PORCENTAGEM DOS DADOS POR INTERVALO, CODIFICAÇÃO E CLASSES DAS VARIÁVEIS UTILIZADAS	41
TABELA 5.3 TAMANHO DAS ÁREAS DE ESTUDO	42
TABELA 6.1 RESULTADO DOS MODELOS LOGIT DE SÃO CARLOS E WAGENINGEN	52
TABELA 6.2 PROBABILIDADE DE SUBSTITUIÇÃO DE AUTOMÓVEL POR ÔNIBUS PARA AS CIDADES DE SÃO CARLOS E WAGENINGEN	53
TABELA 6.3 EVOLUÇÃO DOS MODELOS LOGIT PARA SÃO CARLOS.....	57
TABELA 6.4 PROBABILIDADE DE USUÁRIOS QUE TROCARIAM O AUTOMÓVEL PELO ÔNIBUS PARA SÃO CARLOS (MODELO APRIMORADO)	58
TABELA 6.5 PORCENTAGEM DE ACERTO DOS MODELOS	60
TABELA 6.6 AVALIAÇÃO DO RESULTADO DO COMPORTAMENTO DAS VARIÁVEIS.....	75

RESUMO

ALVES, V. F. B., (2011). Explorando Técnicas para a Localização e Identificação de Potenciais Usuários de Transporte Público Urbano. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2011.

Um dos objetivos dos projetos e estudos na área de transporte público é atrair o maior número possível de viagens. Um primeiro passo para estimular uma maior utilização do transporte público pode ser a captação de pessoas que já têm predisposição para utilizá-lo, mas que não o fazem por alguma deficiência específica no serviço. Este é o contexto no qual mapas que representam o potencial de utilização dos transportes públicos podem desempenhar um papel importante, como discutido neste estudo. A pesquisa tem como objetivo principal a aplicação e avaliação de duas técnicas destinadas a identificar potenciais usuários de transporte público e como estes se distribuem geograficamente em uma cidade brasileira selecionada para o estudo. Nas técnicas aqui exploradas, o município em análise é dividido em áreas em função do código de endereçamento postal. Estas áreas são caracterizadas pelos atributos socioeconômicos da sua população e do sistema de transporte. Diante da hipótese de melhoria na qualidade do transporte público, dois segmentos de usuários de automóvel foram determinados: usuários que trocariam para ônibus e usuários que ainda preferem o carro. Com isso, foi construído um modelo capaz de representar o comportamento de escolha dos usuários de cada área. A metodologia proposta envolve quatro passos: i) comparação de modelos Logit elaborados com dados de São Carlos (Brasil) e Wageningen (Holanda), ii) ajustes no modelo de São Carlos, iii) elaboração de um modelo de escolha modal por redes neurais artificiais e iv) elaboração dos mapas potenciais. As duas últimas etapas foram concebidas tanto para análises independentes, como também para comparação com o modelo Logit. Assim, a construção de cenários futuros permitiu identificar e localizar espacialmente os potenciais usuários de transporte público. Foi possível verificar também qual a influência de alguns atributos sobre a escolha do modo de transporte urbano. Por exemplo, usuários de domicílios com três ou quatro pessoas têm menor probabilidade de vir a utilizar o ônibus regularmente. Por fim, um cenário futuro tornou possível destacar áreas onde é esperado um aumento do potencial de uso do transporte público devido a mudanças nos valores de densidade populacional.

Palavras-chave: transporte público, mapas potenciais, marketing do transporte público, modelos de escolha discreta, redes neurais artificiais.

ABSTRACT

ALVES, V. F. B., (2011). Exploring Techniques for the Location and Identification of Potential Users of Urban Public Transportation. M.Sc. Dissertation - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2011.

One of the objectives of projects and studies on public transport is to attract the largest possible number of trips. A first step for increasing transit ridership may be the attraction of those individuals who already have a predisposition to use the service, but do not use it because of any specific inadequacies. This is the context in which maps displaying the potential use of public transport may play an important role, as discussed in this study. The research aims at the application and evaluation of two techniques used to identify potential users of public transport and to show how they are geographically distributed in a Brazilian city selected for the study. In the techniques discussed here, the municipality under analysis is divided into areas according to the postal codes of the streets. These areas are characterized by socioeconomic attributes of the population and of the transport system. Two segments of automobile users were determined, under the assumption that the quality of public transport would be improved: users who would switch to buses and users who still prefer the car. Based on that, a model designed to represent the choice behavior of users in each urban area was built. The proposed methodology involved four steps: i) the comparison of Logit models built with data of São Carlos (Brazil) and Wageningen (The Netherlands), ii) adjustments in the model of São Carlos, iii) the development of a mode choice model based on artificial neural networks, and iv) construction of potential maps. The third and fourth steps were meant for both independent analysis, and also for comparison with the Logit model. Thus, the construction of future scenarios allowed the identification and spatial location of potential users of public transport. It was also possible to learn about the influence of some attributes on urban transportation choice. For example, users living in households with three or four persons are less likely to become bus riders. Finally, a future scenario was able to highlight the areas where the potential for public transport could be increased due to changes in population density values.

Keywords: public transportation, potential maps, public transportation marketing, discrete choice models, artificial neural networks.

1 INTRODUÇÃO

Este capítulo contém uma breve contextualização do problema central tratado, que consiste basicamente em encontrar potenciais usuários de transporte público. É apresentada também uma justificativa para a aplicação das técnicas exploradas, seguida do objetivo e da estrutura do trabalho.

1.1 CONTEXTUALIZAÇÃO

As razões que levam um usuário a escolher o modo de transporte preferencial para seus deslocamentos são bastante complexas. São consequência, em parte, do modo como a cidade planeja (ou deixa de planejar) a organização e mobilidade das pessoas no seu território. Questões como o uso do solo, infraestrutura de transportes e características ligadas ao cidadão e ao local em que este fixa residência se inter-relacionam. Políticas que não analisam estas questões em conjunto, geralmente interferem negativamente na garantia de um direito básico da população: a sua necessidade de ir e vir. Diante desse contexto, se inserem dois personagens que são parte do conjunto que forma o sistema de transporte predominante na maioria das cidades: o usuário de transporte público e o usuário de automóvel.

Vasconcellos (1982) destaca que enquanto o primeiro necessita de um transporte público eficiente, seguro e barato, o que significa tratamento prioritário (em termos de investimentos, facilidades de circulação etc.) para os transportes coletivos, o segundo deseja o máximo de mobilidade possível dentro do seu veículo, o que significa investimentos na ampliação do sistema viário para facilitar a circulação dos automóveis. Esse cenário, inevitavelmente, gera um conflito de prioridades, não apenas social, no que tange aos investimentos do Estado, mas técnico-operacional, no sentido do espaço de circulação dentro do sistema viário que é dedicado a cada modo de transporte.

Os motivos que levaram à cultura do automóvel no Brasil se misturam à própria história. Impulsionado pelo incentivo econômico da motorização da cidade, o poder público, em seus diversos âmbitos (Federal, Estadual, Municipal) priorizou os investimentos relacionados aos carros e ao sistema viário.

Aproveitando-se da notabilidade que a chegada do asfalto dava a uma região em processo de urbanização, muitos políticos ignoraram o plano diretor para garantir um eleitorado que associou a presença de vias pavimentadas ao desenvolvimento, mesmo na ausência de infraestrutura básica, como saneamento e drenagem urbana (MARICATO, 2008). Atraídos pelo status, privacidade e conforto, além da maior flexibilidade na escolha de horários, os cidadãos deixam de usar transporte público tão logo alcançam situação financeira mínima para dispor de um automóvel.

Em contrapartida, o desenvolvimento do transporte coletivo, ainda mais dependente da iniciativa pública, não teve o tratamento igual ao modo individual e, mesmo com investimentos significativos, sempre ficou em segundo plano em relação ao automóvel.

Entretanto, essa priorização trouxe consequências negativas também para a própria mobilidade, que é a principal vantagem vendida pelas indústrias automobilísticas. A utilização massiva do carro causa congestionamentos que provocam baixa velocidade de circulação (FERRAZ e TORRES, 2004). Infelizmente, por ser realizado juntamente com o trânsito geral, o transporte público também é afetado, tornando-o ainda menos atraente.

Para garantir uma cidade mais sustentável, políticas de priorização do transporte público são necessárias no sentido de garantir uma circulação mais eficiente (maior taxa de ocupação dos veículos). Aparentemente, a medida mais efetiva de se promover isso é atrair mais usuários para o ônibus, através de investimentos na qualidade do serviço de transporte coletivo, aliados a desincentivos na utilização do automóvel.

Melhorar a qualidade e a eficiência do transporte público é importante no sentido de alterar os hábitos diários dos viajantes. O primeiro passo para maior utilização do transporte público pode ser a captação de pessoas que já têm predisposição para utilizá-lo, mas que não o fazem por alguma deficiência específica (falta de qualidade/confiabilidade) no serviço.

1.2 JUSTIFICATIVA

O incentivo para atrair usuários para o transporte público passa diretamente pela compreensão de que o serviço de transporte por ônibus é um produto (serviço). Como em outros segmentos de marketing e venda, esse produto compete com outros pela preferência do cliente. Para o caso do serviço de transporte, existem diversas formas alternativas de transporte em relação ao ônibus como bicicleta, caminhada e o principal concorrente: o automóvel.

No contexto brasileiro, o lucro do segmento privado que opera o transporte público é garantido. Assim, um sistema de transporte público com um grande número de usuários garante maior faturamento para melhoria da qualidade do serviço e diminui a necessidade de subsídio por parte dos órgãos públicos.

No contexto do transporte público holandês, cabe aos gestores em conjunto com os empresários captar clientes para garantir a eficiência do sistema, já que o custo-benefício desse segmento é dependente do número de pessoas e da quantidade de vezes que o utilizam. Essa visão de marketing para transporte público tem sido uma nova forma de operar e fazer negócios. No passado, o transporte público era essencialmente voltado ao conceito de igualdade social, o que implicava em garantir um serviço com maior cobertura territorial possível, ignorando os custos operacionais (WAERDEN *et al.*, 2008).

Também é papel dos gestores manter o sistema de transporte coletivo em evidência através de projetos de racionalização e modernização do transporte público, desenvolvidos com o intuito de melhorar a qualidade e a eficiência do serviço. Para planejar o sistema de transporte, a coleta de dados e informações sobre as condições existentes e futuras se torna necessária para fundamentar projetos, bem como construir modelos de avaliação dos diversos planos (VUCHIC, 2005).

Os estudos realizados por Bérénos *et al.* (2001) sugerem que, através da relação direta do comportamento de viagem com as características de cada área de divisão da cidade, é possível identificar uma demanda potencial por transporte público. Bérénos *et al.* (2001) e Waerden *et al.* (2005) propõem a utilização de mapas potenciais, com base em um modelo Logit, como ferramenta para encontrar e localizar esses potenciais usuários do transporte público. A principal vantagem oferecida por essa

técnica é a possibilidade de testar mudanças antes de implementá-las e verificar a sua repercussão na atratividade de usuários para o transporte público

A aplicação da metodologia de mapas potenciais em uma cidade brasileira será de interesse para o contexto nacional, pois permitirá a análise comparativa do comportamento na escolha de transporte entre Brasil e Holanda. Permitirá também a análise dessa nova ferramenta para utilização pelos gestores municipais, que tem poucos instrumentos de controle do planejamento de transporte. Além disso, abre precedente para aprofundar o estudo através da aplicação da metodologia em outras cidades do Brasil.

1.3 OBJETIVO

A pesquisa tem como objetivo principal a aplicação e avaliação de duas técnicas, modelos de escolha discreta e redes neurais artificiais, destinadas a identificar potenciais usuários de transporte público e como estes se distribuem geograficamente em uma cidade brasileira selecionada para o estudo. São objetivos secundários: a comparação de modelos Logit em uma cidade brasileira e uma cidade holandesa e a análise das relações entre os atributos de caracterização das subdivisões do município com o potencial de utilização do transporte público.

1.4 ESTRUTURA DO TRABALHO

Este documento é composto por oito capítulos, sendo este o primeiro deles. Uma revisão preliminar da bibliografia é apresentada nos três capítulos subsequentes, sendo que o primeiro destes trata dos modelos de escolha discreta e uma das suas variações mais utilizadas: o modelo Logit. O capítulo seguinte constitui uma introdução às Redes Neurais Artificiais, também utilizadas nesse estudo para comparação com o modelo Logit. O quarto capítulo descreve diversas aplicações de metodologias investigativas sobre o potencial usuário de transporte público, em especial a técnica de mapas potenciais empregada nessa dissertação.

Posteriormente, a metodologia adotada para identificação dos potenciais usuários é detalhada no quinto capítulo. Os resultados alcançados nesse estudo, descritos no sexto capítulo, são apresentados tanto no âmbito das técnicas quanto na identificação da influência das características na escolha do modo de transporte.

Por fim, as principais conclusões são apresentadas, seguidas pelas recomendações futuras para o desenvolvimento da técnica estudada e para possíveis políticas a adotar na cidade.

2 MODELOS DE ESCOLHA DISCRETA

Este capítulo apresenta, primeiramente, uma introdução e um breve histórico da utilização de modelos de escolha discreta. Depois, os conceitos básicos são apresentados, seguidos pelo esclarecimento mais detalhado do modelo utilizado nesse estudo: o Logit Multinomial.

2.1 INTRODUÇÃO

A abordagem básica para teorias matemáticas de preferências individuais é baseada na teoria microeconômica do consumidor. O objetivo dessa teoria é fornecer meios para a transformação do desejo do consumidor em funções de demanda expressas pela ação dos consumidores de acordo com determinadas circunstâncias. (BEN-AKIVA e LERMAN, 1985).

A teoria que melhor define os critérios que motivam um consumidor a escolher um produto em detrimento de outro é descrita pelo estudo realizado por Lancaster (LANCASTER, 1966, apud CUNHA, 2005). A teoria de abordagem de características é sustentada pela ideia de que um indivíduo não é capaz de associar valor a um produto, mas sim a um conjunto de atributos que compõem esse produto. De forma análoga, a opção por um determinado serviço também pode ser analisada através da combinação de seus atributos.

Entretanto, do ponto de vista da multiplicidade de fatores, o “consumo” de um serviço de transporte constitui um ato decisório mais complexo do que a aquisição de produtos e bens duráveis (NOVAES, 1986). Ele é composto de uma série de decisões em cascata, que não pode ser encarado de forma concentrada em nenhum momento. Porém é possível fazer análises específicas como, por exemplo, o processo de deslocamento.

2.2 HISTÓRICO

Os modelos de escolha discreta surgiram na primeira parte do século passado e têm origem nos modelos probabilísticos utilizados em experiências biológicas de escolha binária. Na época, a distribuição Normal era geralmente a mais utilizada (modelo Probit). A primeira aplicação na área econômica surgiu na década de 1950 e deveu-se a Farrell (1954), que utilizou os modelos Probit e os Logit Binomiais. Os modelos Probit tinham maior credibilidade teórica que os modelos Logit porque estes últimos estavam associados a uma distribuição cumulativa ainda pouco explorada, a função Logística.

Só no final da década de 1960 e início dos anos 1970 foram alcançados progressos quanto à consistência teórica dos Logit. O primeiro passo foi dado por Theil (1969) que generalizou o Logit Binomial em Multinomial e abriu caminho a novas teorias e aplicações deste tipo de modelos. Logo em seguida, McFadden (1974) desenvolveu uma base teórica e bem explicada do modelo Logit, demonstrando as suas propriedades, aplicações e limitações e tornando-o mais popular na teoria das escolhas discretas e da maximização da Utilidade. No final da década de 1970, Gaudry e Dagenais (1977) desenvolveram o Dogit, um modelo que era uma generalização do Logit e que permite adicionar uma “catividade” dos indivíduos às diferentes alternativas do modelo.

O fato dos modelos Probit estarem associados a problemas de estimação que aumentam com o número de alternativas do conjunto de hipóteses do modelo, e dos modelos Logit conseguirem contornar essas dificuldades, foi fator relevante para que os últimos passassem a ser mais frequentemente utilizados em aplicações práticas. Assim, os Logit Multinomial e Logit Sequencial, apesar de serem restritivos (por implicarem na adoção de erros independentes e identicamente distribuídos), passaram a ser muito utilizados, em contraste com os modelos Probit, para os quais eram necessários métodos de simulação computacionalmente muito complicados e demorados (SILVA, 2004).

Para a classe de modelos Mistos e de Valor Extremo Generalizado (GEV), com distribuições paramétricas associadas aos parâmetros ou à componente aleatória do modelo (modelos estudados a partir da década de 1970), também existiam grandes

dificuldades na estimação. Os passos seguintes vieram associados à evolução dos métodos de simulação, de onde se destacam a Máxima Verossimilhança Simulada e o Método dos Momentos Simulado, que permitiram a estimação de modelos mais complexos. A abordagem de Train (2009) explica mais detalhadamente estes métodos.

De um modo geral, apesar da grande utilização do modelo Logit, pode-se afirmar que, para cada situação existe um modelo de escolha discreta que se adapta melhor. Muitos estudos vêm sendo desenvolvidos com o intuito de juntar as qualidades dos modelos mais utilizados.

Entre os mais recentes artigos encontram-se McFadden e Train (2000), que demonstram a propriedade dos Logit Mistos conseguirem aproximar qualquer Modelo de Utilidade Aleatória (RUM) em uma aplicação para demanda de veículos alternativos ao modo convencional (do ponto de vista do consumo energético); Ben-Akiva *et al.* (2001) que apresentam uma bibliografia do Logit Kernel, um modelo que combina as vantagens do Logit com as do Probit e ainda apresentam um modelo para escolha do tipo de serviço telefônico; Chesher e Santos Silva (2002), que descrevem o modelo Logit com Heterogeneidade Ajustada (HAL), um Logit que inclui parâmetros associados à existência de heterogeneidade entre alternativas e nas alternativas, sem recorrer a distribuições paramétricas, verificando variações imprevistas na preferência de escolha; Bhat e Guo (2004) que desenvolvem o Logit Misto Espacialmente Correlacionado (MSCL) para reproduzir o comportamento de escolha da residência, consolidando vantagens dos modelos GEV com as do Logit Multinomial. Esse modelo demonstrou que houve a presença significativa de correlação espacial entre zonas adjacentes e variáveis obtidas nas respostas dadas pelas famílias (por exemplo 75% das famílias de Dallas, no estado americano do Texas, preferem moradias próximas ao local de trabalho.

Segundo Silva (2004), a desmistificação dos modelos Logit e a evolução dos métodos de simulação tornaram os modelos Logit Mistos mais atrativos na teoria da maximização da Utilidade de escolha e, atualmente, as principais inovações têm sido associadas a estes. Desta forma, acredita-se que existem ainda muitas teorias a desenvolver e vários modelos por explorar, com outras formas de aplicações práticas e que se ajustem melhor a amostras mais diversificadas.

Para esse estudo, foi adotado o modelo Logit Binomial (que é uma simplificação do Multinomial), por sua ampla utilização e facilidade em obter as probabilidades de escolha dos modos de transporte analisados.

2.3 MODELOS DE ESCOLHA DISCRETA

Modelos de escolha discreta fazem parte de um conjunto maior de padrões que analisam as características socioeconômicas: os modelos comportamentais. Os modelos comportamentais estabelecem relações de causa e efeito quando os atributos que constituem uma cadeia de transportes sofrem algum tipo de alteração, isto é, relacionam as motivações básicas dos usuários dos transportes com estas alterações. Estes modelos são chamados comportamentais e podem ser Agregados ou de Escolha Discreta.

Modelos Agregados são modelos que utilizam como informação dados que representam a média de dezenas ou centenas de observações, isto é, se baseiam em informações zonais e interzonais, enquanto que Modelos de Escolha Discreta (ou Desagregados) são modelos baseados em dados individuais.

Segundo Spear (1977, apud Ortúzar e Willumsen, 1994), os modelos de escolha discreta apresentam algumas propriedades:

- a) Os modelos de demanda desagregados são baseados em teorias comportamentais e não constituem analogia física de nenhum tipo. Existe uma vantagem potencial importante sobre os modelos convencionais, pois existe uma maior probabilidade de serem estáveis no tempo e no espaço.
- b) Os modelos desagregados são estimados usando dados individuais, o que pode representar serem mais eficientes que os convencionais. Nos modelos convencionais cada dado utilizado como informação representa a média de muitas observações. Outra consideração importante sobre os modelos desagregados é que existe uma probabilidade menor de sofrer desvios devido à correlação, como pode ocorrer com unidades agregadas.
- c) Os modelos desagregados são probabilísticos. Eles produzem a probabilidade de escolha de cada alternativa.

d) As variáveis de serviço incluídas no modelo podem ter seus coeficientes estimados. Os coeficientes das variáveis de serviço têm uma interpretação de utilidade marginal, isto é, eles refletem a importância relativa de cada atributo. Entende-se por utilidade marginal a utilidade extra que pode ser obtida quando uma unidade é acrescentada em um dos atributos da função utilidade.

Segundo Train (2009), modelos de escolha discreta descrevem as opções dos tomadores de decisão entre alternativas. Tomadores de decisão podem ser pessoas, famílias, empresas, ou qualquer outro grupo de tomada de decisão. Já as alternativas podem representar produtos concorrentes, trajetos, modos de transporte ou quaisquer outras opções ou itens sobre os quais escolhas devem ser feitas. Para caber dentro de um quadro de escolha discreta, o conjunto de alternativas, chamado o conjunto de escolhas, precisa apresentar três características. Em primeiro lugar, as alternativas devem ser mutuamente excludentes do ponto de vista do decisor. A escolha de uma alternativa necessariamente implica em não escolher qualquer uma das outras alternativas. O tomador de decisão escolhe apenas uma das alternativas do conjunto de escolha. Em segundo lugar, o conjunto de escolha deve ser exaustivo, na medida em que todas as alternativas possíveis estão incluídos. O tomador de decisão, necessariamente, escolhe uma das alternativas. Em terceiro lugar, o número de alternativas deve ser finito.

O paradigma para a geração de modelos de escolha discreta mais consistente com a teoria de escolha do consumidor é o da Teoria da Utilidade Aleatória. Os principais postulados da teoria são, segundo Ortúzar e Willumsen (1994):

- Indivíduos pertencem a uma população Q homogênea, que age racionalmente e possui informação suficiente, escolhendo uma opção que maximize sua utilidade pessoal;
- Existe um conjunto de escolha A de alternativas disponíveis e um conjunto X de vetores de atributos medidos dos indivíduos e suas alternativas. Um indivíduo q está exposto a um conjunto $x \in X$ e um subconjunto de escolha $A(q) \in A$;
- Cada opção $A_j \in A$ tem associada uma utilidade U_{jq} para um indivíduo q . O modelador, que não tem completa informação sobre todos os elementos considerados na escolha, assume que a U_{jq} é composta de dois componentes: uma parte sistemática e mensurável, V_{jq} , e uma parte aleatória, que reflete

idiosincrasias e gostos particulares, além de erros inerentes à modelagem, conforme equação a seguir:

$$U_{jq} = V_{jq} + \varepsilon_{jq}$$

- A parte sistemática mensurável V_{jq} é função dos atributos x , que podem representar tanto os atributos k que caracterizam as alternativas quanto às características pessoais do indivíduo. Os coeficientes β podem ser específicos da alternativa ou genéricos (coeficiente j).

$$V_{jq} = \sum \beta_{kj} \cdot x_{kjq}$$

- O indivíduo seleciona a alternativa de maior utilidade, ou seja, seleciona A_j , se e somente se:

$$U_{jq} \geq U_{iq}, \forall A \in A(q)$$

- Então temos que a probabilidade de um indivíduo escolher A_j é:

$$P_{jq} = Prob \{ \varepsilon_{jq} \leq \varepsilon_{iq} + (V_{jq} - V_{iq}), \forall A_i \in A(q) \}$$

De acordo com Ortúzar e Willumsen (1994) e Train (2009), a distribuição dessa parte aleatória não é conhecida. O que se sabe é que os resíduos são variáveis ocasionais com certa distribuição denotada por $f(\varepsilon) = (\varepsilon_1, \dots, \varepsilon_n)$. Entre as classes mais importantes de modelos de utilidade aleatória, assume-se que suas funções de utilidade são derivadas sob a hipótese de que a parte não observada da utilidade (ε) são valores independentes e identicamente distribuídos (Logit) ou valor extremo generalizado (GEV).

2.4 MODELO LOGIT MULTINOMIAL

Modelos Logit Multinomiais são utilizados para modelar relações entre uma variável de resposta politômica e um conjunto de variáveis dependentes. Esse modelo é empregado quando a análise da escolha de um produto ou de um serviço que está sendo estudado envolve mais de uma opção (ou mais de um modo). É o caso da análise, por exemplo, da escolha de um aparelho de telefone móvel, onde cada

indivíduo irá relacionar a importância dos atributos que caracterizam o produto desejado e selecionar aquele que lhe proporciona mais vantagens. No contexto de transportes, outro exemplo seria o serviço de transporte de passageiros em que são dadas opções dos modos trem, ônibus e avião, cada um com suas respectivas características. O emprego deste modelo é a prática mais comum e mais simples entre os modelos de Escolha Discreta.

O modelo Logit Multinomial satisfaz o axioma da independência em relação a alternativas, que postula: "quando duas alternativas quaisquer tiverem probabilidade não nula de serem escolhidas, a relação entre a probabilidade de uma sobre a outra é afetada pela ausência ou presença de qualquer alternativa adicional ao conjunto escolhido" (BEN-AKIVA E LERMAN, 1985).

O modelo Logit Multinomial é aplicado aos casos com número de opções maior do que dois. Quando o número de modos (opções) é dois, tem-se o Modelo Logit Binomial, que é um caso particular do primeiro.

Admitindo-se que a parcela aleatória é regida por uma distribuição de Weibull, e que se baseia no pressuposto de que os erros são independentes e identicamente distribuídos sobre as opções, o modelo Logit Multinomial é dado pela expressão:

$$P_i = \frac{e^{(U_i)}}{\sum_j e^{(U_j)}}$$

P_i = probabilidade do usuário escolher o modo i .

2.4.1 Avaliação da qualidade do modelo calibrado

Dois parâmetros estatísticos são utilizados para avaliar a qualidade do modelo ajustado: o teste da razão da verossimilhança e o teste χ^2 .

O teste da razão da verossimilhança (LR), demonstrado na equação a seguir, tem distribuição de chi-quadrado (χ^2) com r graus de liberdade, onde r é o número de restrições lineares (parâmetros β). Testa a hipótese de nulidade de todos os parâmetros simultaneamente. Adotando-se um nível de significância (por exemplo, 95 %), calcula-se o valor crítico (r , 95 %). Caso o valor LR seja maior que o valor de χ^2 , então, rejeita-se a hipótese de nulidade de todos os parâmetros simultaneamente.

$$LR = -2\{L(0) - L(\beta)\}$$

Onde:

$L(0)$ = valor da função de verossimilhança com todos os parâmetros iguais a zero;

$L(\beta)$ = valor da função de verossimilhança com os valores estimados para os parâmetros.

O teste da estatística ρ^2 , ou pseudo coeficiente de determinação, tem como função avaliar o ajuste do modelo.

Mais precisamente, essa estatística indica o quão bom é um modelo, com seus parâmetros estimados, em relação a um modelo com todos os parâmetros iguais a zero (conhecido como modelo nulo). A estatística ρ^2 tem seu valor teórico também limitado entre 0 e 1, mas um valor acima de 0,2 e próximo a 0,4 indica um ajuste considerado excelente para o modelo Logit Multinomial (ORTÚZAR e WILLUMSEN, 1994).

3 REDES NEURAIS ARTIFICIAIS

Este capítulo descreve os conceitos básicos relacionados às Redes Neurais Artificiais (RNAs) e um breve histórico de sua utilização, acompanhado de vantagens e desvantagens da sua utilização. A seguir, o funcionamento do neurônio artificial é comentado de forma sucinta. Por fim, são apresentadas também a definição e noções gerais das Redes *Multilayer Perceptron* e o seu algoritmo de aprendizado.

3.1 INTRODUÇÃO

As RNAs são técnicas computacionais que apresentam um modelo matemático inspirado nas funções das redes biológicas, buscando programar seu comportamento básico e sua dinâmica. Consistem em um método para solucionar problemas de Inteligência Artificial (IA), construindo um sistema com circuitos que procuram, de alguma forma, replicar o funcionamento do cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. AS RNAs fazem parte de um ramo da IA correspondente à classe de aprendizagem mecânica (GALVÃO e VALENÇA, 1999).

A estrutura de funcionamento das RNAs é baseada em sistemas de equações em que o resultado de uma equação é o valor de entrada para várias outras da rede. As RNAs conseguem reproduzir o comportamento de qualquer função matemática; por esta razão, rapidamente se popularizaram como uma ferramenta do tipo *black box*, para modelar relações entre variáveis. (SILVA *et al.*, 2008). Pode-se afirmar que RNAs são sistemas paralelos distribuídos, compostos por unidades de processamento simples (nós) que calculam determinadas funções matemáticas (normalmente não-lineares). Essas unidades geralmente são conectadas por canais de comunicação associados a determinados pesos. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas por suas conexões. O comportamento “inteligente” de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede (BRAGA *et al.*, 1998).

As RNAs podem ser utilizadas na solução de uma grande quantidade de problemas, encontrados nas mais diversas áreas de aplicação: classificação, diagnóstico, análise de sinais e de imagens, otimização e controle. As redes têm se mostrado de fácil

implementação, robusta no tratamento de dados com ruídos. São eficientes, particularmente, na resolução de problemas em que: não se tem uma formulação analítica, não se tem conhecimento explícito acessível, os dados estão contaminados por ruído, ou o próprio problema modifica-se com o passar do tempo (RAIA Jr., 2000, apud OLIVEIRA, 2000).

Bocanegra (2002) afirma que, dependendo do tipo de problema ao qual são submetidas, as RNAs têm apresentado um desempenho considerado superior aos métodos estatísticos utilizados para o mesmo fim. Cita ainda o exemplo de Subramanian *et al.* (1993), que desenvolveram uma pesquisa onde compararam as Redes Neurais com determinados métodos estatísticos de classificação (modelos clássicos, tais como análise discriminante linear e quadrática). Diante dos resultados alcançados, concluíram que, mesmo para pequenos tamanhos de amostras e funções de maior complexidade, as RNAs apresentaram melhores soluções.

3.1.1 Breve histórico

Entender o comportamento de seu cérebro sempre foi um desejo do ser humano. Logo surgiu a ideia de que esse comportamento podia ser explicado e reproduzido. Com o advento e avanço da tecnologia, não demorou para que os estudos com o intuito de reproduzir o comportamento do cérebro humano passassem a ser introduzidos em estruturas computacionais para acelerar o processamento de informações. Diante desse cenário, surgiram as primeiras aplicações que levaram à criação de concentração de estudos nessa área: a Inteligência Artificial.

Em 1943, McCulloch e Pitts propuseram um modelo simplificado de neurônios biológicos. O modelo tratava de entradas excitatórias e inibitórias presentes no neurônio que, em dado tempo, eram capazes de mantê-lo ativo ou inativo (MCCULLOCH e PITTS, 1943). Um pouco depois, Hebb (1949) introduziu o modelo básico de auto-organização, onde o aprendizado dos neurônios biológicos é fundamentado no reforço de ligações sinápticas entre os neurônios excitados.

Segundo Barreto (2002), o primeiro esforço conjunto para estudar Inteligência Artificial foi o encontro no *Dartmouth College*, em 1956, evento que teve a participação de grandes pesquisadores como John McCarthy, Marvin Minsky, Herbert Simon e Allen Newell. No livro publicado a partir desse encontro, com o título de *Automata Studies*, o primeiro artigo tratava de Redes Neurais Artificiais como um paradigma da arquitetura

computacional. Pode-se dizer que aí nasceram simultaneamente os dois paradigmas da inteligência artificial: simbólica e conexionista.

A Inteligência Artificial Simbólica (IAS) tenta simular o comportamento inteligente humano desconsiderando os mecanismos responsáveis por tal. Já a Inteligência Artificial Conexionista (IAC) acredita que, construindo-se um sistema que simule a estrutura do cérebro, este sistema apresentará inteligência, ou seja, será capaz de aprender, assimilar, errar e aprender com seus erros. As conexões entre os neurônios determinam o procedimento da rede e como ele pode mudar ao longo do tempo. Só posteriormente, o estudo originalmente chamado de “conexionismo” passou a ser conhecido como Redes Neurais Artificiais. (SILVA *et al.*, 2008)

Alguns anos mais tarde, Rosenblatt (1958) desenvolveu várias ideias a respeito dos conceitos de neurônios utilizados por McCulloch e Pitts. Sua mais importante iniciativa foi incluir um algoritmo para treinar a rede, de modo a executar determinados tipos de funções. O *Perceptron*, modelo desenvolvido por Rosenblatt, Wightman e outros para reconhecer padrões, em sua concepção mais simples (**Figura 3.1**), era composto por unidades de entrada, por um nível intermediário formado pelas unidades de associação e por um nível de saída formado pela unidade de resposta (SILVA *et al.*, 2001).

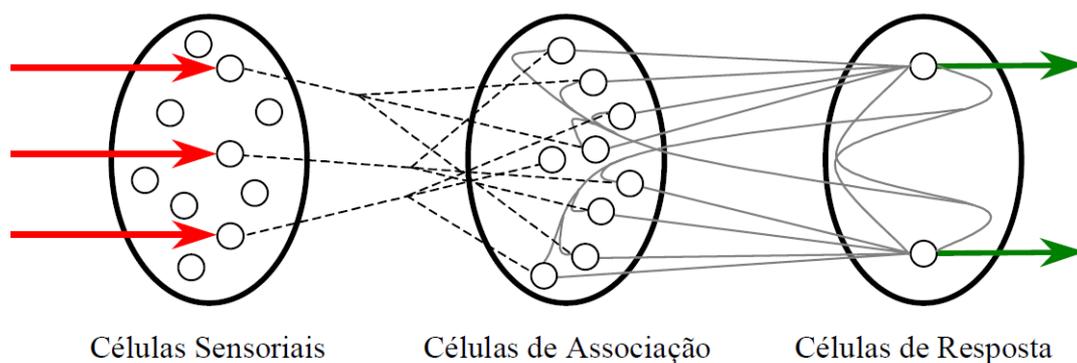


Figura 3.1 Camadas de um *Perceptron* (Smith, 1996)

De acordo com Bocanegra (2002), Widrow e Hoff desenvolveram o ADALINE (*ADaptive LINear Element*) e o MADALINE (*Many ADALINE*) *Perceptron* como dispositivos práticos para resolver tarefas de reconhecimento de padrões. O ADALINE/MADALINE usou saídas analógicas ao invés das binárias originalmente propostas por McCulloch e Pitts. No entanto, Minsky e Papert (1969) chamaram a atenção para algumas tarefas que o *Perceptron* não era capaz de executar, já que

este só resolve problemas linearmente separáveis. A repercussão desse estudo foi um dos motivos da separação entre a IAS e a IAC (BARRETO, 2002) e provocou uma estagnação na abordagem das Redes Neurais durante a década de 1970.

Na década de 1980, o estudo das Redes Neurais foi reimpulsionado pelas soluções às críticas descritas por Minsky e Papert com a utilização de novos modelos. Os principais estudos responsáveis pela volta do interesse nas RNAs foram os de John Hopfield (1982), que utilizou redes simétricas para otimização, e o de Rumelhart, Hinton e Williams (1986), que introduziram o método de *backpropagation* (retropropagação) para redes *Perceptron* de várias camadas de neurônios, com entradas e saídas analógicas.

Atualmente, o desenvolvimento de estudos das Redes Neurais Artificiais permanece aquecido. Entre alguns trabalhos da última década, é possível citar Raia Jr (2000), Bocanegra (2002), Akamine (2005) e Silva *et al.* (2008). Estudos de diversas aplicações das Redes Neurais Artificiais relacionados à engenharia de transportes podem ser encontrados no estudo de Corrêa (2008), tanto no Brasil quanto no exterior.

3.1.2 Vantagens e desvantagens das Redes Neurais Artificiais

Algumas vantagens na utilização de Redes Neurais Artificiais:

- As redes podem, em alguns casos, permitir análises superiores às conseguidas com técnicas estatísticas convencionais (FALAS, 1995);
- Não necessitam de conhecimentos de especialistas para tomar decisões, pois baseiam-se unicamente nos exemplos históricos que lhe são fornecidos;
- O tempo necessário para se implementar uma rede é menor que o utilizado para a construção de um sistema especialista equivalente;
- Como as unidades da rede operam em paralelo, a destruição ou “defeito” em um de seus nós não torna a rede inoperante;
- As redes têm habilidade em tratar com ruídos. Elas são tolerantes às falhas e podem apresentar degradação atual, ou seja, apesar de existir alguma falha no sistema, elas continuam oferecendo respostas por um período significativo de tempo (TUBB, 1993);

- Podem ser utilizadas como filtro de dados (AKAMINE, 2005);
- Se as condições de trabalho variam, pode-se fazer uso da capacidade das RNAs para adaptar-se a essas mudanças, voltando a treinar o sistema com novos exemplos (BRIO e MOLINA, 2001);

Desvantagens:

- As redes podem chegar a conclusões que contrariem as regras e teorias estabelecidas;
- O treinamento de uma rede, dependendo de sua aplicação, pode ser demorado;
- Uma vez treinada uma rede neural, pode ser difícil interpretar o seu funcionamento. Trata-se de um tipo de funcionamento denominado de 'caixa preta' (BRIO e MOLINA, 2001);
- Para uma rede aprender corretamente pode chegar a necessitar de dados históricos; nestes casos, a carência de dados passados relevantes em quantidade suficiente torna a rede inaplicável (SILVA *et al.*, 2001).

3.2 O NEURÔNIO ARTIFICIAL

Um neurônio artificial pode ser entendido como uma unidade de processamento matematicamente simples, constituída por uma função de combinação e outra de transferência. A função de combinação é responsável por compor a informação de entrada do neurônio, que, no caso de ser linear, passa a representar a soma das entradas, ponderada pelos respectivos pesos. Esses pesos, muitas vezes chamados de pesos sinápticos, em analogia com o neurônio biológico, representam a importância de cada informação em relação a dado neurônio (SILVA *et al.*, 2008).

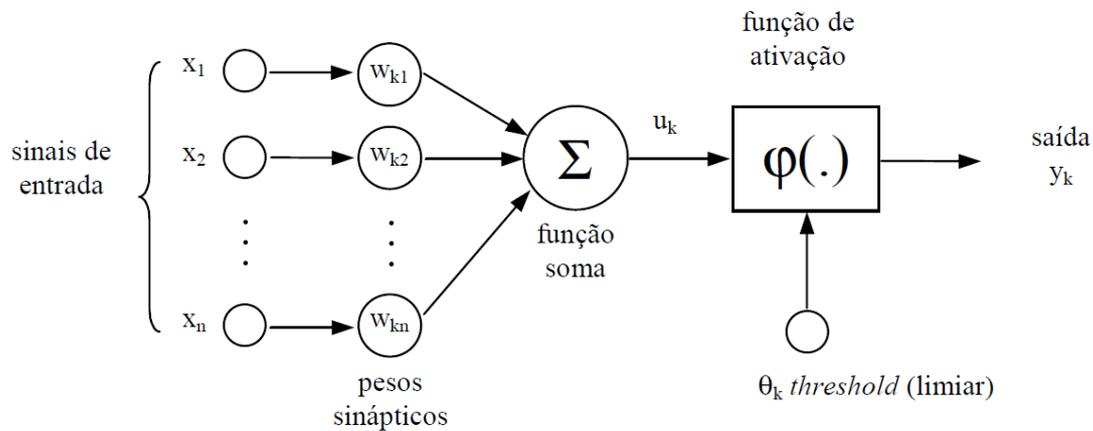


Figura 3.2 Modelo não-linear de um neurônio; adaptado de Haykin (1994)

O esquema de um neurônio artificial apresentado na **Figura 3.2** pode ser dividido nas seguintes elementos:

- Sinapses - caracterizadas por um peso (w), que pode representa a sua intensidade. O papel do peso w_{kj} é multiplicar o sinal x_j na entrada da sinapse j , conectada a um neurônio k . O peso w_{kj} é positivo se a sinapse associada é excitatória e negativo se a sinapse associada é inibitória;
- Somatório - adiciona as entradas ponderadas pelos seus pesos respectivos, ou seja,

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

- Limiar (*threshold*), θ_k , - tem um papel 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;
- Função de ativação, $\varphi(\cdot)$ - funciona como um limitante à amplitude de saída do neurônio, ou seja, a entrada é normalizada dentro de um intervalo fechado, comumente $[0,1]$ ou $[-1,1]$;
- Saída - do neurônio, y_k , onde:

$$y_k = \varphi(u_k - \theta_k)$$

Onde φ é a função de ativação.

Geralmente, o valor do limiar é aplicado com a inclusão de uma entrada x_0 igual a -1 e um peso w_{k0} igual ao valor de θ_k . Dessa forma, a nova entrada da função de ativação, já incluindo o limiar, é dada por:

$$v_k = \sum_{j=1}^n w_{kj}x_j - \theta_k$$

Segundo Haykin (1994), a função de ativação denotada $\varphi(\cdot)$ define a saída de um neurônio de acordo com o nível de atividade da sua entrada. Dentre as funções mais comuns, se enquadram as seguintes:

- função linear: $\varphi_1(t+1) = v_1(t)$
- função limiar: $\varphi_1(t+1) = \begin{cases} 1, & \text{se } v_i(t) \geq \theta \\ 0, & \text{se } v_i(t) < \theta \end{cases}$
- função sigmóide logística: $\varphi_1(t+1) = 1/(1 + e^{-v_i(t)})$
- função tangente hiperbólica: $\varphi_1(t+1) = (1 - e^{-v_i(t)})/(1 + e^{-v_i(t)})$
- função linear por partes: $\varphi_1(t+1) = \begin{cases} +1, & \text{se } v_i(t) > \theta \\ -1, & \text{se } v_i(t) < \theta \\ v_i(t), & \text{em outra parte} \end{cases}$

A disposição com que os neurônios são organizados é chamada de topologia da rede. A topologia afeta diretamente o desempenho da rede, assim como as aplicações para as quais ela é desejada, e sua estrutura está intimamente ligada ao algoritmo de aprendizado usado para a 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).

Dentre as topologias, pode-se citar a *Multilayer Perceptron*, 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 camada de saída, onde cada neurônio está conectado a todos os seus vizinhos. Na rede de *Hopfield*, não existem neurônios de entrada ou saída. A conexão de entrada de um neurônio é a saída de outros, assim como sua conexão de saída já é 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. Para este estudo foi escolhida a rede

Multilayer Perceptron, devido ao fato desta ser mais adequada para fazer classificações deste tipo, além de ser a mais conhecida e utilizada (BRONDINO, 1999).

Para que a RNA realize o cálculo e solucione uma tarefa, ela precisa passar por um processo de aprendizado. A rede extrai informações relevantes dos exemplos a ela apresentados, criando assim uma representação própria para o problema. Denomina-se algoritmo de aprendizagem a um conjunto de regras bem definidas para que uma rede “aprenda” determinada função. Estes algoritmos são processos iterativos que ajustam parâmetros da rede, de modo a que esta se ajuste à tarefa proposta (SILVA *et al.*, 2008). Ainda segundo Brondino (1999), existem três principais paradigmas de aprendizado: supervisionado, não supervisionado e híbrido.

Para o aprendizado supervisionado, apresenta-se à rede, na fase de treinamento, um conjunto de entradas acompanhadas de suas respectivas saídas. O objetivo é minimizar o sinal de erro, que é uma função da diferença entre a saída desejada e aquela fornecida pela rede. Esta minimização se dá pelo ajuste dos pesos da rede.

No aprendizado não supervisionado, a rede aprende sozinha, sem uma mensagem de erro externa, ou seja, não há supervisão externa. É necessário que entradas parecidas sejam apresentadas à rede, para que esta possa extrair características estatisticamente relevantes e criar classes de maneira automática.

O aprendizado híbrido, por sua vez, consiste de uma combinação dos aprendizados supervisionado e não supervisionado. Um exemplo é aprendizado por reforço, onde a rede aprende de seu próprio ambiente, a partir dos dados de entrada. A única informação externa que a rede recebe é a indicação de que a resposta fornecida está correta ou não.

3.3 REDES MULTILAYER PERCEPTRON

As Redes *Multilayer Perceptron* (MLP) apresentam um poder computacional muito maior que aquele apresentado pelas redes sem camadas intermediárias. As redes MLP têm sido utilizadas com sucesso para a solução de vários problemas envolvendo altos graus de não-linearidade (BOCANEGA, 2002). A **Figura 3.3** apresenta uma estrutura básica de uma MLP com duas camadas intermediárias.

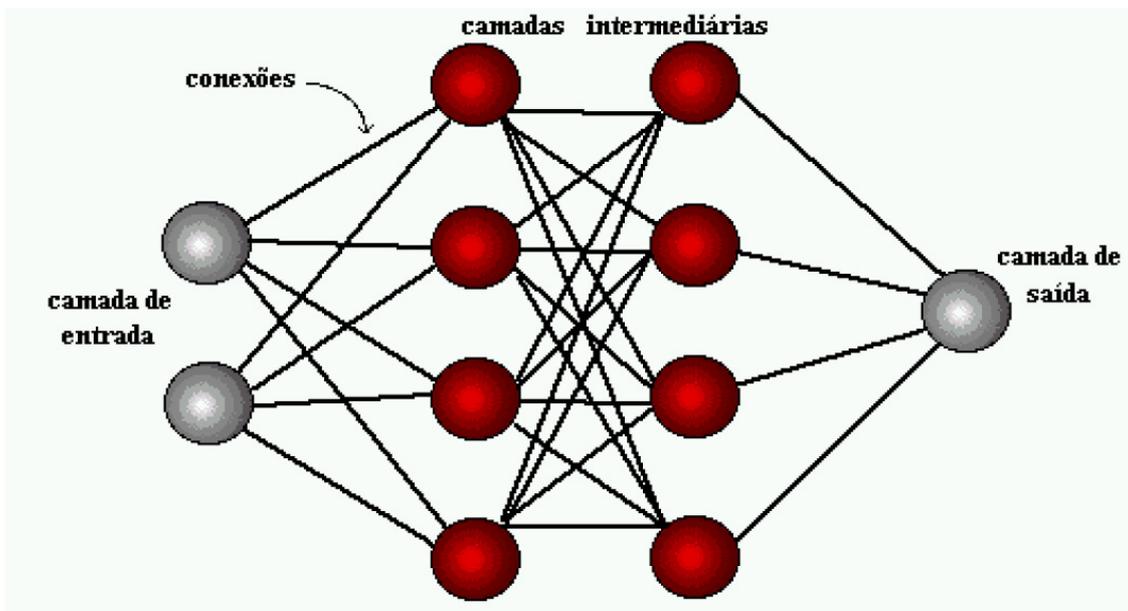


Figura 3.3 Topologia de uma rede MLP com 2 camadas intermediárias

Tipicamente, esta arquitetura consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias (ou escondidas) de unidades computacionais e uma camada de saída. Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para a saída. Seu treinamento é do tipo supervisionado e utiliza um algoritmo chamado retropropagação do erro (*error backpropagation*). Este algoritmo é baseado numa regra de aprendizagem que “corrige” o erro durante o treinamento (HAYKIN, 1994).

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 intenção do trabalho de treinamento é buscar cada vez mais diminuir o valor deste erro. Para tal intuito, o valor dos pesos deve ser ajustado a cada nova iteração. A regra *backpropagation* proporciona que os pesos da camada de saída sejam os primeiros a serem ajustados e, posteriormente, os pesos das demais camadas, de trás pra frente.

O número adequado de nós na camada intermediária, geralmente definido empiricamente, depende fortemente da distribuição dos padrões de treinamento e validação da rede. Segundo Silva *et al.* (2008), entre os vários fatores particulares que influenciam este número estão:

- Número de exemplos de treinamento;
- Quantidade de ruído presente nos exemplos;

- Complexidade da função a ser aprendida;
- Distribuição estatística dos dados de treinamento.

Em síntese, nas etapas de ajuste deve-se sempre procurar obter uma topologia de rede que modele com precisão os dados do conjunto de treinamento, mas que também resulte numa aproximação com boa capacidade de generalização.

Seja E_p , a função erro para o padrão p , d_{pj} o valor da saída desejado para o padrão p no neurônio j , o_{pj} o valor obtido e w_{ij} o peso da ligação do neurônio j . Então, a função E_p é dada por:

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

Portanto, o objetivo é minimizar esta função de erro. Se esta função 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 se dá pela adição de um termo de variação a eles (Δw_{ij}), ou seja, para um peso w_{ij} (o peso do nó i para o nó j), o seu peso atualizado vai ser dado por:

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

onde:

$$\Delta w_{ij} = \eta x_i o_j (1 - o_j) \delta_j$$

$$\delta_j = (d_j - o_j), \text{ para a última camada;}$$

$$\delta_j = \sum w_{jk} \delta_k, \text{ para camadas intermediárias;}$$

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

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

$$\Delta w_{ij}(t + 1) = \eta x_i o_j (1 - o_j) \delta_j + \alpha (w_{ij}(t) - w_{ij}(t - 1))$$

A atualização de pesos pode se dar por 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 depende da aplicação. Se o conjunto de dados é grande e redundante (poucos padrões e muitas entradas, por exemplo), a primeira é melhor. Caso contrário, quando o conjunto apresenta muitos padrões a serem classificados, é melhor utilizar a atualização por ciclo.

O algoritmo *backpropagation* apresenta algumas dificuldades de aprendizagem. Em superfícies muito complexas, o treinamento é muito lento e existe o risco de a rede cair em um mínimo local. Além disso, pode ocorrer *overfitting*, fenômeno que pode ocorrer depois de certo tempo de treinamento, quando a rede memoriza um determinado padrão apresentado e o processo de classificação piora sensivelmente (RAIA Jr., 2000). Para evitar esses tipos de problemas, Braga *et al.* (2000) recomendam que seja colocado na rede um número de neurônios intermediários suficiente para a solução do problema de reconhecimento de padrões, tendo também atenção para não utilizar neurônios em número reduzido, o que pode levar a rede a despender tempo em excesso para encontrar uma representação ótima.

3.4 PREVISÃO DA ESCOLHA MODAL E REDES NEURAS ARTIFICIAIS

Diversos trabalhos mostraram que é possível conseguir bons desempenhos com a utilização de RNAs para prever a escolha do modo de transporte. O estudo de Sanches e Ferreira (2007) apresentou uma comparação entre redes neurais artificiais e um modelo Logit Binomial para a previsão entre a escolha modal de universitários de São Carlos entre o automóvel e o modo a pé. O resultado mostrou que a RNA teve desempenho um pouco superior ao modelo de escolha discreta. De modo semelhante, Hensher e Ton (2000) compararam três métodos de RNAs e modelos Logit aninhados para representar a escolha modal nas cidades de Sidney, Melbourne e as duas cidades agrupadas. Os modos utilizados incluíam carro como motorista, carro como

caronista, ônibus, trem. Ambas as abordagens tiveram resultados bons, entretanto não houve nenhuma indicação clara de que método é superior. Shmueli *et al.* (1996) estudaram a aplicação de RNAs para prever a escolha modal em Israel tomando como base de comparação (e complementação) um modelo de árvores de decisão. Novamente, os resultados foram consistentes. Esse estudo enfatiza ainda que o bom desempenho do modelo de RNA é dependente da alta qualidade dos dados.

Em contrapartida, alguns trabalhos também não obtiveram avanços na utilização das redes neurais artificiais. Nijkamp *et al.* (1996) encontraram dificuldades em representar o comportamento de escolha modal entre os modos ferroviários e rodoviários na Itália. Entre os problemas encontrados encontravam-se *overfitting* e muito tempo despendido para avaliar a qualidade dos parâmetros, destacando ainda a característica da RNA de não prover uma análise da significância dos atributos para o resultado da escolha do modo. Mozolin *et al.* (1999) concluíram em seu estudo que as redes neurais artificiais não forneceram uma modelagem adequada para a distribuição de viagens na Área Metropolitana de Atlanta, com características geralmente utilizadas para predição (número de moradores, número de trabalhadores, distância de viagens pendulares). Como comparação foi utilizado o modelo com dupla restrição com estimação pelo método da máxima verossimilhança, que teve desempenho consistente.

4 MAPAS POTENCIAIS DE UTILIZAÇÃO DO TRANSPORTE PÚBLICO

Este capítulo apresenta, primeiramente, um breve resumo de diversos tipos de estudos relacionados com a busca por potenciais usuários de transporte público. Em seguida, dá ênfase à técnica adotada neste estudo de identificar potenciais usuários por meio de mapas.

4.1 ESTUDO DOS POTENCIAIS USUÁRIOS

Entender o comportamento do usuário e as razões pelas quais ele escolhe um modo de transporte é uma premissa básica para resolver a questão da mobilidade nas cidades. Interferências no custo de uma viagem, no horário ou ainda no motivo de deslocamento podem alterar a escolha por diferentes modos de transporte.

Andreassen (1995) destaca que é importante perceber que segmentos diferentes de usuários avaliam a qualidade de um mesmo serviço de modo diferente e sua satisfação é influenciada pelos atributos que o caracterizam. A identificação dos perfis de usuários, de um modo geral, nada mais procura do que as melhorias que podem ser aplicadas para aumentar as condições de competitividade do ônibus na decisão de escolha modal do usuário.

A necessidade da busca por tornar o transporte público mais atrativo incentivou uma grande quantidade de estudos, como os de Beirão e Cabral (2007) e Dell’Olio *et al.* (2011), que analisaram os diferentes aspectos que os usuários de ônibus e potenciais usuários valorizam na qualidade do serviço de transporte público. Assim, foram capazes de identificar vantagens e desvantagens que cada modo de transporte proporciona e recomendar políticas públicas que estimulassem o aumento da utilização de modos coletivos. Entretanto, as políticas propostas consideravam apenas melhorias na cidade como um todo, visto que a investigação dos potenciais usuários não estava relacionada à localização geográfica.

Em paralelo, muitos especialistas passaram a incluir a análise espacial como ferramenta para verificar a relação da distribuição geográfica da mobilidade e características dos usuários e do sistema de transporte público.

Henrique *et al.* (2004) concentraram esforços na identificação do padrão de distribuição espacial da mobilidade relacionada aos usuários cativos de ônibus, assim como de outras variáveis correlacionadas, tais como uso do solo residencial, renda da população e acessibilidade provida pela rede de transporte. Estas são candidatas a explicarem o fenômeno da autocorrelação espacial da quantidade de deslocamentos realizados diariamente neste sistema. Essa etapa serviu como base para um modelo de análise confirmatória da correlação espacial entre mobilidade urbana (através da quantidade de deslocamentos realizados por transporte público) e suas variáveis explicativas. As ferramentas de análise espacial exploratória em áreas, nesse caso os índices de autocorrelação global e local de Moran, identificaram regiões de padrões semelhantes que foram explicadas, em sua maioria, ou pela renda média dos domicílios ou pela acessibilidade aos principais polos geradores de empregos.

Já Cunha (2005) focou o seu trabalho na visão do transporte coletivo como um produto e analisou seus atributos. Através da identificação das características das áreas urbanas que se relacionam com o sistema de transporte, ele avaliou o efeito da influência do tipo de linha sobre parâmetros de desempenho do sistema, como tempo de viagem, custo operacional e forma da malha viária, entre outros. Assim, foi possível estabelecer critérios para escolha de tipos de linha mais adequados levando em conta a quantidade de pontos positivos para cada característica do sistema, como por exemplo, que linhas circulares são as que têm o maior desempenho em áreas setorizadas.

O estudo de Puebla *et al.* (2008) apresentou a análise do poder de atração do transporte público numa escala menor: a partir das entradas das estações de metrô de Madri. A ferramenta visou analisar o atributo da distância como principal fator na decisão de escolha pelo transporte público. Através de um modelo de regressão linear múltipla com ponderação pela distância, percebeu-se que há uma subestimação da demanda atraída por esse modo de transporte para a cidade de Madrid.

Por outro lado, há investigações mais relacionadas à eficiência e à eficácia do transporte público, incluindo a análise de variáveis relacionadas ao conforto, custo,

frequência e tempo de viagem. O foco desses estudos foi a utilização de modelos de escolha discreta, principalmente o modelo Logit, para representar o comportamento dos usuários e estudar qual a possibilidade de atrair mais usuários diante da implantação de uma política específica. Os estudos de Ferronato (2002), Espino *et al.* (2006) e Vedagiri e Arasan (2009) propuseram alterações em uma determinada característica que as pessoas valorizam no transporte coletivo e identificaram sua capacidade de estimular um aumento do número de usuários. Assim, buscaram avaliar como era o perfil dos usuários que aceitavam mudar sua opção de transporte para o ônibus.

Ferronato (2002) analisou o potencial de medidas de gerenciamento da demanda no transporte coletivo por ônibus urbano, com foco na tarifa diferenciada por hora do dia. Foram elaborados modelos comportamentais com variações na antecipação ou postergação da realização da viagem em relação à hora de pico para usuários pagantes e usuários isentos. O estudo revelou que, através da utilização de técnicas de preferência declarada e modelos Logit Multinomiais, foi possível analisar a resposta da demanda do período de pico a políticas de diferenciação tarifária por hora do dia. Entre os resultados, foi possível afirmar que há uma maior aceitação da antecipação de viagens, comparada à postergação; a influência da idade do usuário em sua decisão; e a significativa redução de custos de oferta do serviço que pode ser obtida através da implementação de diferenciação tarifária por hora do dia.

Espino *et al.* (2006) analisaram que a disposição do usuário em pagar por mais comodidade no transporte coletivo aumenta quanto maior for o tempo de viagem. A partir da criação de diversos cenários, foi possível concluir que a demanda era mais sensível a aumentos no custo de estacionamento que a reduções de tarifa, sugerindo que esta última política pode ser mais efetiva na influência do uso de transporte público nas Ilhas Canárias.

Já o estudo de Vedagiri e Arasan (2009) tratou da estimação da probabilidade de usuários de carro trocarem o meio de transporte para ônibus devido a um acréscimo no nível de serviço decorrente da implantação de uma linha exclusiva para ônibus em ruas anteriormente com tráfego misto. O valor do crescimento foi determinado através de um modelo de simulação de fluxo de tráfego. Através de uma pesquisa de preferência declarada, foram coletadas variáveis para, com a utilização de um modelo Logit Binomial, tentar explicar o comportamento de quem muda de modo de transporte.

Outros pesquisadores perceberam que também era possível alterar características mais direcionadas à disposição geográfica e avaliar em que isso afetava na decisão dos usuários. Para desenvolver planos estratégicos para futuras alternativas de rotas para *ferry* na baía de São Francisco (EUA), Outwater *et al.* (2003) se basearam em dados obtidos em pesquisas de marketing para segmentar os usuários em oito classes, de acordo com o seu comportamento em relação ao modo de transporte. Através de um modelo de equação estrutural, utilizando informações socioeconômicas e pesquisa de preferência declarada, foi possível fazer previsões de utilização de modos de transporte para uma possibilidade de expansão da rede aquaviária da baía.

Baseando-se no mesmo preceito de que uma política direcionada relacionada ao posicionamento geográfico interfere no comportamento dos usuários, Sugiki *et al.* (2001) elaboraram um modelo para prever demanda futura de viagens por domicílio. Uma potencial demanda de tráfego e uma demanda por mudança de localização de residência para moradores do subúrbio foram analisadas do ponto de vista da fase familiar, diante de uma política de estímulo de mudança para o centro da cidade. Foi possível avaliar uma previsão futura de envelhecimento das famílias, levando-se em conta uma maior necessidade por serviço público de transporte através de um modelo Logit Binomial, que utilizou duas características relacionadas ao domicílio: idade do chefe da família e tipo de família, além de utilizar a taxa de serviço do transporte público na zona (serviços/hora). Como resultado da aplicação do modelo de geração de demanda futura, foi demonstrado que, para famílias mais jovens, a relação entre o potencial de mudança para o centro e a redução da mobilidade foi proporcional. Já o potencial de tráfego das famílias mais antigas deve aumentar, porém sem a mesma proporção de mudanças para moradias no centro. Diante dessa constatação, o estudo conclui que alguma política habitacional deve ser desenhada para evitar isso.

Em seu trabalho, Waerden *et al.* (2010a) foram mais abrangentes e entrevistaram usuários de carro e bicicleta para descobrir, entre 16 políticas relacionadas a melhorias no transporte público, quais teriam maior efeito na troca de modo para o ônibus. Foi ainda utilizado o interesse da viagem (lazer, trabalho ou compras). Um modelo de regressão ordinal foi estimado e possibilitou a identificação da relação entre cada política, cada motivo de viagem e cada categoria socioeconômica. Com uma caracterização detalhada, foi possível avaliar qual política é mais valorizada por cada tipo de potencial usuário.

Outra abordagem para a identificação de potenciais usuários foi a análise espacial da mobilidade em função de características socioeconômicas e, novamente, identificação da divisão modal com a utilização de modelo Logit. De forma geral, o avanço desse tipo de pesquisa indicou que, trabalhando com uma setorização da cidade, é possível caracterizar geograficamente os locais com maior potencial de atração de usuários.

Zhou *et al.* (2004) desenvolveram um estudo que identifica o *market share* (divisão de mercado) do transporte público para cada área da cidade. Primeiro, para descobrir por que as pessoas usam transporte público, onde elas moram e como elas o utilizam, além de identificar os segmentos de mercado com base em três fatores que englobam 'valor de tempo', 'restrições de compromissos', e 'sensibilidade à privacidade e ao conforto'. Em seguida, foi calculada a divisão modal para cada um dos oito tipos de segmentos de mercado adotados e para cada área com o auxílio de um modelo Logit. Por fim, calculou-se a divisão de mercado do transporte público por área. Essa divisão de mercado, entretanto, não estava diretamente relacionada às características do sistema de transporte.

Casello (2007) analisou, em seu estudo, o potencial e os possíveis impactos do aumento do percentual de usuários de ônibus na divisão modal existente na região metropolitana da Filadélfia. Um modelo de alocação de tráfego multimodal foi criado e o custo de viagem de carro e de transporte coletivo, com base em dados atualizados, foi quantificado. Em seguida, foram introduzidas, como variações desse modelo, medidas de incentivo ao uso do ônibus (redução de taxas e de tempo de viagem) e estímulos à redução de uso de automóveis (aumento do custo percebido), com o propósito de quantificar seus impactos na escolha modal.

Nota-se que, cada vez mais, os estudos têm se preocupado com a eficiência do transporte e isso tem tornado as investigações ainda mais específicas. Em sua pesquisa, Thompson *et al.* (2011) analisam a relação das viagens por transporte público de acordo com sua origem e destino e a atratividade de zonas de TODs - *Transit Oriented Developments* (ocupação do espaço urbano orientado para o transporte público). Os resultados da aplicação dessa metodologia, que utilizou um modelo de regressão binomial negativa, indicam o tempo de viagem entre zonas como principal fator de aumento do uso do ônibus. Sugerem também que, para atrair usuários, pode ser mais interessante investir em políticas para áreas mais dispersas do que para aquelas que concentram atualmente a maior concentração de oferta de

transporte. Nesse caso, mapas eram utilizados apenas como referência para análise de áreas com maior concentração de viagens recebidas.

Os estudos elaborados por Béréños *et al.* (2001) e Waerden *et al.* (2005) propuseram a identificação dos potenciais usuários por meio de mapas. Diferentemente da maioria das demais pesquisas, a intenção do estudo era abranger a maior quantidade de áreas possíveis da cidade. Justamente por isso, era possível testar o efeito de políticas de melhorias para o transporte público no potencial de atração de usuários. Esse estudo foi escolhido para a aplicação pelo seu diferencial em relação a outras ferramentas. O modo como essa técnica foi utilizada é descrito no subitem a seguir.

4.2 MAPAS POTENCIAIS DE UTILIZAÇÃO DO TRANSPORTE PÚBLICO

A grande vantagem apresentada pela abordagem de Béréños *et al.* (2001) e Waerden *et al.* (2005) é a facilidade com que os resultados podem ser apresentados a gestores e empresas de transporte público. A visualização espacial dos pontos de maior concentração de potenciais usuários pode indicar que áreas justificam políticas específicas sem ter de realizar pesquisas caras e de longa duração.

O estudo de Béréños *et al.* (2001) consistia na ideia de encontrar o potencial de transporte público de cada área da cidade baseando-se nas suas características. Segmentos de marketing, caracterizados por suas áreas e seus padrões de viagem, puderam ser definidos com base em dados de viagens e, portanto, puderam ser diretamente relacionados ao comportamento do usuário.

O estudo de Waerden *et al.* (2005) sugere a subdivisão da cidade estudada em função dos seis primeiros dígitos do código de endereçamento postal. Estas áreas foram caracterizadas a partir do comportamento predominante de seus usuários e de suas habitações.

A caracterização dessas áreas pode ser feita baseada em atributos geográficos, sócio-demográficos e econômicos. Mais especificamente, os autores apresentaram estudos que relacionam estes atributos com a escolha modal de transporte. Waerden *et al.* (2005) dividiram as características das áreas em dois grupos: socioeconômicas e físicas. As características socioeconômicas (idade, renda, estilo de vida e posse de carro) estão relacionadas aos indivíduos e famílias de uma região, enquanto que as

características físicas (tipo de habitação, tempo de viagem, paradas de ônibus e frequência de ônibus) estão diretamente relacionadas à região.

O comportamento de decisão pelo modo de viagem dos usuários foi representado através de um modelo Logit Multinomial, considerando cinco modos alternativos: carro não substituível, carro substituível por ônibus, ônibus, bicicleta não substituível e bicicleta substituível por ônibus. Desta maneira, o uso potencial de transporte público pode ser identificado através das áreas com maior concentração de usuários de ônibus e também de usuários de carro ou de bicicleta que eventualmente estejam dispostos a trocá-los pelo modo ônibus.

O cálculo das probabilidades das alternativas consideradas possibilita a identificação do *market share* da escolha modal de transporte. Waerden *et al.* (2008) definem potencial de transporte público como a soma das probabilidades dos modos ônibus, bicicleta substituível por ônibus e carro substituível por ônibus.

Desta forma, os resultados da modelagem podem ser utilizados para identificar onde estão concentradas as pessoas que estariam dispostas a utilizar o transporte público caso haja melhorias no serviço. A visualização espacial dessas áreas permite uma tomada de decisão mais abrangente, englobando o problema de um modo mais completo.

É possível ainda fazer uma análise crítica dos parâmetros utilizados, congregando as características de influência significativa na escolha modal. Através da codificação das variáveis é possível analisar a influência de cada atributo detalhadamente.

Possíveis cenários futuros podem ser desenvolvidos com a previsão de alterações que influenciem diretamente sobre as características. A análise conjunta de cenários é capaz de revelar as áreas que tiveram maior variação (acréscimo ou decréscimo) no potencial de transporte público, que é o objetivo principal dessa ferramenta. Por exemplo, uma possível aplicação pode ser usada para avaliar diferentes sistemas de rotas de ônibus (Waerden *et al.*, 2008).

5 METODOLOGIA

Este capítulo descreve o método proposto para a identificação dos potenciais usuários de transporte público através de mapas. A primeira etapa de desenvolvimento desta pesquisa é a formatação e tratamento de dados utilizados. Assim, um modelo Logit Binomial foi elaborado para a cidade de São Carlos e comparado a um modelo semelhante para Wageningen, cidade onde já houve aplicação da técnica. A terceira etapa consistiu na busca de um aperfeiçoamento do modelo Logit da cidade brasileira. Em seguida, um modelo de simulação por redes neurais foi criado também para tentar prever a escolha modal em São Carlos e seus resultados comparados com o modelo Logit. Por fim, segue a etapa de apresentação dos resultados na forma de mapas potenciais.

5.1 FORMATAÇÃO E TRATAMENTO DOS DADOS

A cidade de Wageningen, assim como a cidade de São Carlos, tem uma população flutuante devido a um grande número de estudantes de outras cidades que se deslocam por causa da universidade presente no município. Wageningen tem atualmente uma população de 37.414 habitantes cuja divisão etária pode ser verificada na **Tabela 5.1** e na **Figura 5.1**. Com uma área de 32,35 km², a extensão de vias na cidade é de 182 km, há cerca de 12.343 automóveis, sendo 767 motocicletas (equivalente a 6 %).

São Carlos é uma cidade maior que Wageningen, tem população de 221.396 habitantes. No gráfico da **Figura 5.1**, elaborado a partir da **Tabela 5.1**, é possível perceber que São Carlos tem uma população mais jovem que Wageningen, com cerca de 34 % da população abaixo dos 20 anos, enquanto que Wageningen tem 13 % da população acima de 65 anos. Entretanto, a faixa etária média tem porcentagens semelhantes nas duas cidades nas faixas de 20 a 24 e de 25 a 44 anos. São Carlos tem uma área de 67,25 km², pouco mais que o dobro maior que Wageningen, e tem uma extensão de vias de 835 km. Tem ainda uma frota de 112.781 veículos, entre automóveis e outras conduções motorizadas, dentre as quais 23.703 são motocicletas (21 %). As cidades também apresentam diferenças quanto ao índice de motorização:

São Carlos tem 509 veículos / 1.000 habitantes enquanto que Wageningen tem aproximadamente 330 veículos / 1.000 habitantes.

Tabela 5.1 Divisão etária nas cidades de Wageningen e São Carlos

Faixa etária	Wageningen		São Carlos	
	Pop. Absoluta (hab.)	Pop. Relativa (%)	Pop. Absoluta (hab.)	Pop. Relativa (%)
0 a 4	1727	4,9	14597	7,6
5 a 9	1698	4,8	15198	7,9
10 a 14	1680	4,8	16650	8,6
15 a 19	2224	6,3	18476	9,6
20 a 24	3988	11,3	18400	9,5
25 a 44	11644	33,0	61579	31,9
45 a 64	7795	22,1	33877	17,6
65 a 79	3122	8,8	11598	6,0
80 ou mais	1437	4,1	2574	1,3

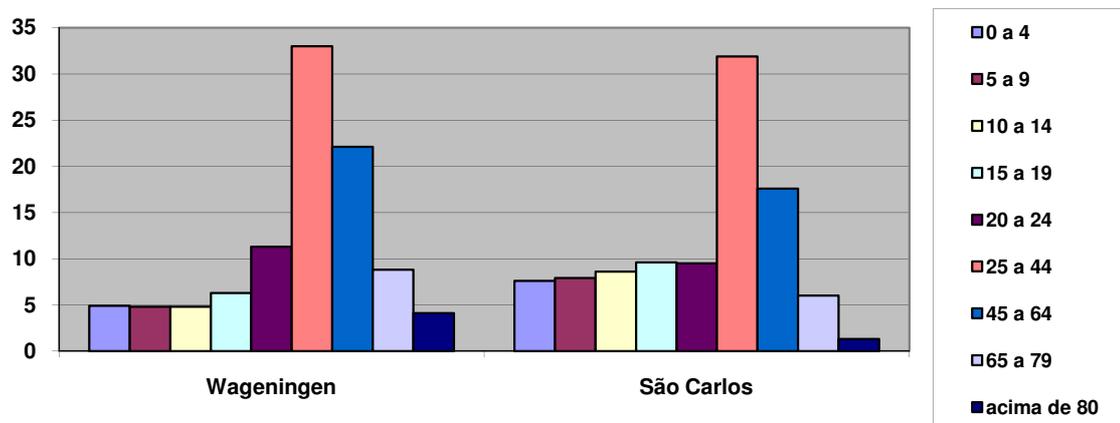


Figura 5.1 Distribuição etária relativa nas cidades de Wageningen e São Carlos

Os dados da cidade de Wageningen para este estudo são provenientes da pesquisa de Dommeck e Lodewijks (2004). O questionário elaborado para esse estudo consistia de questões sobre o comportamento em relação a viagens, características pessoais e do domicílio. Os dados agruparam informações sobre 826 usuários distribuídos em 206 zonas baseadas em códigos postais. A **Figura 5.2** exibe as áreas onde há informação na cidade de Wageningen.

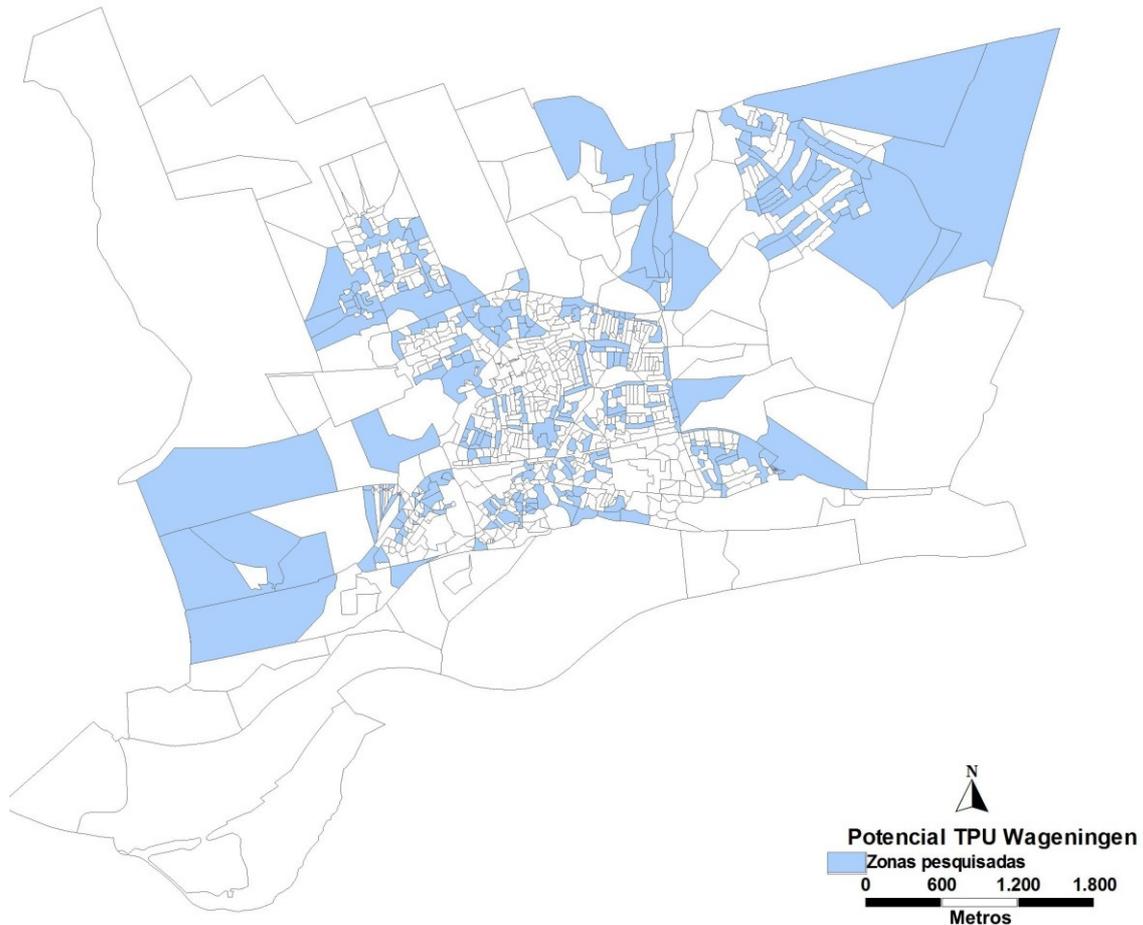


Figura 5.2 Mapa de Wageningen com zonas que contém informações para o estudo

Como se trata da primeira análise desta metodologia em São Carlos, os dados tiveram de ser formatados para adequá-los à proposta do estudo. Foram utilizados os códigos de endereçamento postal (CEP), definidos pela Empresa Brasileira de Correios e Telégrafos, dados socioeconômicos da pesquisa Origem-Destino (O-D) realizada em 2007/2008, e dados sobre a utilização do transporte público da pesquisa de opinião realizada em conjunto com a pesquisa O-D. Foram ainda utilizadas a base de dados geográficos dos domicílios, da rede viária e do sistema de transporte público de São Carlos. A **Figura 5.3** apresenta a rede viária da cidade e as coordenadas geográficas da localização dos domicílios para os quais se dispunha de resultados da pesquisa de opinião.



Figura 5.3 Mapa de São Carlos com distribuição dos domicílios pesquisados

Em seguida, foi necessário obter o máximo de variáveis para comparação com Wageningen. O levantamento e categorização das variáveis tomou como base as características utilizadas no modelo holandês, bem como o modo que foram obtidas. Variáveis socioeconômicas foram obtidas da pesquisa O-D, enquanto que variáveis físicas foram obtidas através de operações de um software de sistema de informações geográficas (SIG), utilizando as bases de dados geográficas disponíveis. O software empregado nesse estudo foi o *TransCAD* 4.8. A obtenção de cada variável é descrita a seguir:

- a) **DISPONIBILIDADE DE AUTOMÓVEL:** medido pela razão entre automóveis e indivíduos no domicílio multiplicada por 100. Uma disponibilidade igual ou

- superior a 100 % indica que os indivíduos têm possibilidade de sempre usar o carro para se locomover;
- b) NÍVEL DE INSTRUÇÃO - obedece a codificação a seguir: 1 - não alfabetizado, 2 - pré-escola, 3 - fundamental incompleto, 4 - fundamental completo, 5 - médio incompleto, 6 - médio completo, 7 - superior incompleto e 8 - superior completo. Foi adotado como nível de instrução alto um valor acima de 4;
 - c) TAMANHO DA FAMÍLIA: é dada pelo número de pessoas da família.
 - d) STATUS SOCIAL: é dado pela renda em salários mínimos por pessoa do domicílio. O nível alto de renda adotado para esse modelo foi acima de 1 salário mínimo.
 - e) TIPO DA FAMÍLIA: é dado pelo tipo predominante da família. Quando o morador mais jovem tem 18 anos ou menos, a família é considerada *Família com Criança*. Quando a média de idade é superior a 60 anos, é considerada *Família com Idosos*. O restante é considerado *Família de Jovens*.
 - f) DISTÂNCIA AO CENTRO: distância, pela rede viária, do domicílio ao centro da cidade (tomando como referência central a Catedral de São Carlos Borromeu).
 - g) DISTÂNCIA À RODOVIA: distância, pela rede viária, do domicílio à rodovia Washington Luis, adotada por se tratar da principal conexão rodoviária com o município.
 - h) NÚMERO DE LINHAS DE ÔNIBUS: é o número de linhas de ônibus que se encontram a até 350 metros do domicílio (mesma distância adotada em Wageningen). Foi obtido no SIG-T, da seguinte forma: o sistema de rotas de ônibus foi transformado em arquivo geográfico e, através do comando *Fill - Aggregate*, foram levantados os números de linhas dentro da distância adotada como aceitável para a caminhada (350 m).
 - i) DENSIDADE: cálculo do número de domicílios por área (hectare). Foi obtido no SIG através da criação de uma banda (*buffer*) de 30 m para cada lado do eixo das vias. Depois de contados os domicílios, estes valores foram divididos pelas respectivas áreas, com as devidas correções de unidade.
 - j) RAZÃO DO TEMPO DE VIAGEM ÔNIBUS-CARRO: foi obtido no SIG-T (SIG aplicado a transportes) através de matrizes com o tempo de viagem de ônibus e carro, a partir de todos os domicílios, mas para destinos selecionados. As velocidades

para os automóveis e para os ônibus foram adotadas de acordo com o conhecimento prático da hierarquia das vias e observações em campo. Em seguida, foi calculada a média da razão do tempo de viagem entre ônibus e automóvel para cada domicílio.

As informações sobre a opinião dos usuários em relação à opção de substituir o veículo particular pelo transporte público foram retiradas da pesquisa de opinião realizada em conjunto com a pesquisa O-D. A **Figura 5.4** mostra um trecho do questionário respondido pelos usuários que assinalaram que utilizam o automóvel como modo de transporte. Diante disso, de acordo com a questão 7 do questionário, foram divididos dois tipos de usuários de carro: os que trocariam o carro por ônibus e os que não o trocariam nos seus deslocamentos diários, caso a qualidade do serviço de transporte coletivo melhorasse. Vale ressaltar que apenas um morador por domicílio foi entrevistado nessa pesquisa de opinião.

Utiliza **AUTOMÓVEL**

7. Se a qualidade do serviço de transporte coletivo melhorasse, você deixaria de utilizar o carro para usar ônibus / microônibus nos seus deslocamentos diários?
 1. Sim () 2. Não ()

8. Se você respondeu sim à pergunta anterior:
Enumere, de 1 a 5, os itens abaixo de acordo com suas prioridades para o transporte coletivo. Inicie com o número 1 para o item que você considera mais importante.

a. Rapidez ()	d. Itinerário adequado às necessidades ()
b. Segurança nos ônibus ()	e. Horário adequado às necessidades ()
c. Conforto ()	

9. Enumere, de 1 a 3, os itens abaixo correspondentes a problemas para deslocamentos por automóvel. Inicie com o número 1 para o problema que você mais observa.

a. Congestionamento ()	b. Falta de estacionamento ()	c. Custo elevado ()
-------------------------	--------------------------------	----------------------

Figura 5.4 Trecho da Pesquisa de Opinião realizada em São Carlos

Por fim, o código postal foi adicionado às informações dos domicílios na base de dados geográficos correspondente, através do SIG. Essa informação foi adicionada para um posterior agrupamento dos dados, assim como no modelo holandês. Em seguida, foi formatada uma planilha com todos os usuários entrevistados e suas respectivas informações sobre as características físicas e socioeconômicas, o código postal e o comportamento quanto à escolha do modo de transporte.

5.2 COMPARAÇÃO ENTRE OS MODELOS LOGIT AJUSTADOS PARA SÃO CARLOS E WAGENINGEN

Após o levantamento e formatação inicial dos dados a serem utilizados, chegou-se a um total de 1292 entrevistas de usuários de carro. Primeiramente, foi atribuída uma classificação em categorias para transformar cada característica socioeconômica ou física em variáveis para o modelo Logit. As classes e codificação utilizadas são as mesmas propostas por Waerden *et al.* (2005) e estão resumidas na **Tabela 5.2**.

Tabela 5.2 Porcentagem dos dados por intervalo, codificação e classes das variáveis utilizadas

Características	Classes	Códigos		Divisão dos dados (%)
Tipo de família	Família de jovens	-1	-1	34
	Família com crianças	1	0	45
	Família de idosos	0	1	21
Nível de instrução	Alto	1		54
	Outro	-1		46
Tamanho da família	Menos de 2 pessoas	-1	-1	9
	2 a 3 pessoas	1	0	50
	Mais de 3 pessoas	0	1	41
Densidade	30 moradias ou menos por hectare	-1	-1	31
	Entre 31 e 60 moradias por hectare	1	0	46
	Mais de 60 moradias por hectare	0	1	23
Distância ao centro da cidade	Menos de 1 km	-1	-1	10
	1 a 2 km	1	0	21
	mais de 2 km	0	1	69
Disponibilidade de automóvel	Menos de 100%	-1		95
	100% ou mais	1		5
Status social	Acima da média	1		21
	Outro	-1		79
Distância à rodovia	Menos de 6 quilômetros	-1		100
	6 quilômetros ou mais	1		0
Razão do tempo de viagem ônibus-carro	Menos de 1,5	-1	-1	0
	Entre 1,5 e 2,5	1	0	0
	Mais de 2,5	0	1	100
Número de linhas de ônibus a 350 m	0 linhas de ônibus	-1	-1	8
	1 ou 2 linhas de ônibus	1	0	18
	Mais de 2 linhas de ônibus	0	1	74

Esses dados foram agregados em função do CEP com o auxílio de uma planilha dinâmica. Assim, as informações referentes ao comportamento de escolha foram apresentadas por porcentagem de cada tipo de usuário (os que trocariam ou não o automóvel pelo ônibus). A **Figura 5.5** exhibe a preferência de modo do conjunto de dados utilizado. Em relação aos atributos físicos e socioeconômicos, a área com base

no código postal foi caracterizada com o comportamento predominante. Em seguida, as áreas receberam o código referente à classe pertencente, exibida na **Tabela 5.2**.

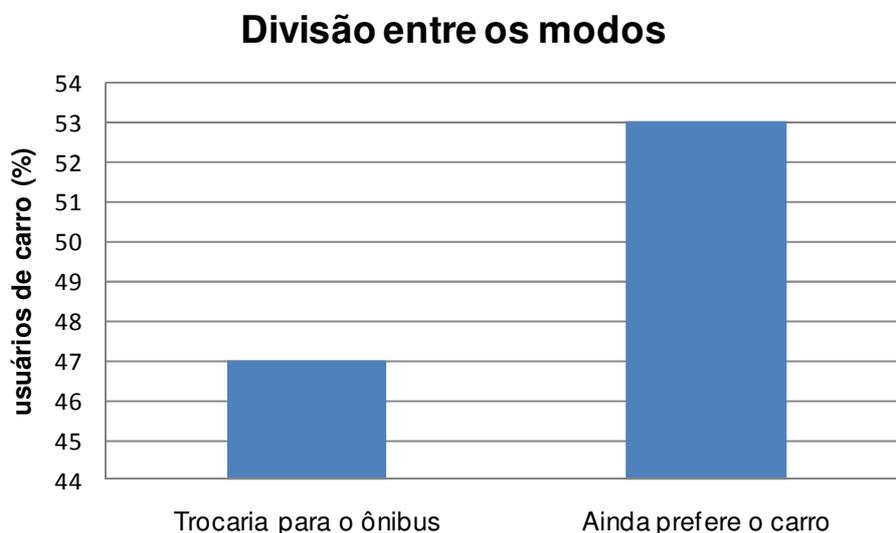


Figura 5.5 Divisão dos usuários segundo o modo de preferência

Assim, para a representação espacial, áreas foram criadas ao redor das vias, envolvendo uma distância de 30 metros do eixo da rua. A **Tabela 5.3** mostra a distribuição das áreas de acordo com o tamanho. O conjunto de dados resultou em informações distribuídas em 544 áreas baseadas no CEP, de um total de 1378 códigos postais para a cidade de São Carlos. O mapa da **Figura 5.6** mostra as áreas consideradas neste estudo.

Tabela 5.3 Tamanho das áreas de estudo

Área (ha.)	Freqüência	Frequência (em %)
Menos de 1	8	1,5
Entre 1 e 4	171	31,4
Entre 4 e 10	202	37,1
Entre 10 e 20	111	20,4
Entre 20 e 30	28	5,1
Entre 30 e 40	17	3,1
Mais de 40	7	1,3



Figura 5.6 Mapa de São Carlos com zonas pesquisadas

A forma de elaboração do modelo Logit Binomial utilizada nesse estudo para avaliar a probabilidade de troca do automóvel pelo transporte público é exibido na equação a seguir. Como se trata de um modelo categorizado, as variáveis recebem códigos correspondentes ao código exibido na **Tabela 5.2**. Além disso, tomou-se como referência o modo *usuários que não deixariam de utilizar o carro*, fazendo sua utilidade igual a zero.

$$P_{troca} = \frac{e^{(U_{troca})}}{e^{(U_{troca})} + e^{(U_{carro})}}$$

Onde:

P_{troca} = probabilidade de escolha pela troca para o ônibus, em caso de melhoria na qualidade

U_{carro} = utilidade do modo preferência por carro = 0

U_{troca} = utilidade da troca por ônibus = $Const + jcava \times Dispauto + jedlev \times N.instr + jhsiz1 \times Tamfamília1 + jhsiz2 \times Tamfamília2 + jsoc \times Status\ social + jfam1 \times Tipofamília1 + jfam2 \times Tipofamília2 + jdcent1 \times Distcentro1 + jdcent2 \times Distcentro2 + jdhigh \times Distrodovia + jblin1 \times Lin1 + jblin2 \times Lin2 + jdens1 \times Densidade1 + jdens2 \times Densidade2 + jtrat1 \times Rtempo\ oc1 + jtrat2 \times Rtempo\ oc2$

Dispauto = código da disponibilidade de automóvel;

N.instr = código do nível de instrução;

Tamfamília1 = primeiro código do tamanho da família;

Tamfamília2 = segundo código do tamanho da família;

Status social = código do status social;

Tipofamília1 = primeiro código do tipo de família;

Tipofamília2 = segundo código do tipo de família;

Distcentro1 = primeiro código da distância ao centro;

Distcentro2 = segundo código da distância ao centro;

Distrodovia = código da distância à rodovia;

Lin1 = primeiro código do número de linhas de ônibus a 350 m;

Lin2 = segundo código do número de linhas de ônibus a 350 m;

Densidade1 = primeiro código da densidade;

Densidade2 = segundo código da densidade;

Rtempo oc1 = primeiro código da razão do tempo de viagem;

Rtempo oc2 = segundo código da razão do tempo de viagem;

Const = constante;

jcava, jedlev, jhsiz1, jhsiz2, jsoc, jfam1, jfam2, jdcent1, jdcent2, jdhigh, jblin1,

jblin2, jdens1, jdens2, jtrat1, jtrat2 = coeficientes do modelo.

Os resultados de saída do modelo são analisados de duas formas principais. O primeiro nível de avaliação refere-se ao desempenho do modelo e é analisado em função do valor da estatística ρ^2 . O segundo nível de avaliação está diretamente relacionado aos atributos. As variáveis significativas, para um nível de confiança de 95 %, terão seu efeito analisado de acordo com a codificação utilizada na **Tabela 5.2** e uma análise da probabilidade de troca do automóvel pelo ônibus pode ser conduzida. Por fim, o comportamento da variável será confrontado com as informações disponíveis sobre a cidade.

5.3 MELHORIAS NO MODELO LOGIT AJUSTADO PARA SÃO CARLOS

A busca de um modelo aprimorado para São Carlos é aprofundada nesta etapa do estudo, já que as classes estipuladas para as variáveis na aplicação de Waerden *et al.* (2005) talvez não sejam condizentes com a realidade de uma cidade brasileira de médio porte. Diante disso, é realizada uma análise de sensibilidade dos dados para identificar classes mais adequadas para as variáveis em São Carlos. Entretanto, pretende-se continuar utilizando o modelo Logit com categorias, bem como o número original de classes de cada variável para manter alguma comparação da técnica. Os resultados encontrados são avaliados da mesma forma que aqueles dos modelos discutidos na seção anterior.

5.4 MODELO DE REDES NEURAIS PARA SÃO CARLOS

Um modelo de simulação por meio de redes neurais artificiais foi também elaborado, para fins de comparação com o modelo Logit. O objetivo desse modelo foi representar a opinião dos usuários em relação à possibilidade de trocar o automóvel pelo ônibus, de posse de um conjunto de características capazes de explicar a sua escolha. Essas características são as mesmas utilizadas para elaborar as variáveis do modelo Logit.

São construídas redes com base em variações de *momentum*, *learning rates* e distribuição e quantidade de nós nas camadas intermediárias. Uma vez treinadas, podem ser selecionadas as redes que melhor representam os dados individualizados. Isto é feito a partir da porcentagem de acertos, verificada primeiramente para os dados de validação e depois para os dados de teste.

O modelo de redes neurais não explica exatamente o procedimento de escolha discreta, só tenta replicar resultados de saída observados a partir de dados de entrada conhecidos. Portanto, para se obter um resultado capaz de ser comparado com o modelo Logit, serão feitas variações em cada classe para analisar a interferência da variável no processo de escolha. Para facilitar o uso dessa técnica, foram utilizados dados de forma individual (ou seja, de cada domicílio).

Por fim, os resultados do modelo Logit são comparados com os resultados da simulação por redes neurais. Entretanto a análise comparativa é feita em função da tendência geral da escolha dos usuários, já que uma das técnicas utiliza os dados agrupados e a outra é construída com base em dados individualizados. Apesar dessa diferença, ainda é possível avaliar os resultados e encontrar compatibilidades e diferenças entre as estimativas dos modelos.

5.5 EXEMPLO DE EMPREGO DOS MAPAS POTENCIAIS

Para a análise gráfica, é necessário criar uma hipótese futura que será utilizada para identificar alterações no comportamento dos usuários. A mudança de uma característica para todos os domicílios pode ser capaz de revelar o efeito da mudança de comportamento. Essa mudança é medida pela diferença entre a porcentagem atual dos usuários que trocariam o automóvel pelo ônibus e a mesma porcentagem após a alteração da característica.

A variação verificada entre o valor atual e o potencial futuro pode ser exibida através de mapas temáticos, identificando espacialmente onde estão as áreas em que pode haver maior utilização do ônibus. A criação de mapas com variações iguais nas características para os modelos Logit e de redes neurais permite comparações.

Para a elaboração desses mapas com a representação do potencial de utilização do transporte coletivo, os dados utilizados pelas redes neurais devem ser agrupados em função do código postal assim como feito originalmente para o modelo Logit.

5.6 ATIVIDADES DESENVOLVIDAS

Nesta seção é apresentada uma síntese das atividades realizadas no estudo de identificação dos potenciais usuários de transporte público. A descrição detalhada dos procedimentos realizados em cada etapa visa facilitar a compreensão para trabalhos futuros.

ETAPA 1 - REFERENCIAL TEÓRICO, OBTENÇÃO E PREPARAÇÃO DOS DADOS

1. Revisão bibliográfica sobre assuntos relacionados ao projeto, como pesquisas sobre potenciais usuários de transporte público, modelos Logit e redes neurais artificiais;
2. Obtenção da base de dados geográficos da rede viária de São Carlos, atualizada até 2006;
3. Obtenção da base de dados geográficos de localização dos domicílios de São Carlos, atualizada até 2006;
4. Obtenção do cadastro de códigos de endereçamentos postais (CEPs) de São Carlos, utilizado pela Empresa de Correios e Telégrafos, atualizado até 2010;
5. Obtenção dos dados domiciliares da Pesquisa Origem-Destino (O-D) realizada em São Carlos em 2007-2008;
6. Obtenção de dados da Pesquisa de Opinião realizada no Município de São Carlos em 2007-2008;
7. Seleção dos dados comuns à pesquisa de Opinião e à pesquisa O-D;
8. Lançamento dos dados de CEPs no SIG, a partir da base de dados da rede viária de São Carlos;
9. Obtenção da base de dados geográficos do sistema de rotas do transporte público de São Carlos, atualizada até 2010;
10. Obtenção das variáveis socioeconômicas, a partir dos dados domiciliares da pesquisa O-D;
11. Obtenção das variáveis físicas, a partir de ferramentas do SIG;
12. Obtenção das opções de escolha modal, a partir da pesquisa de opinião;
13. Transferência da informação do código postal da rede viária para a base de dados selecionados em ambiente SIG;

14. Formatação de planilha eletrônica com informações socioeconômicas, físicas e opções de escolha modal para os dados selecionados;

ETAPA 2 - MODELO DE ESCOLHA DISCRETA - COMPARAÇÃO ENTRE OS MODELOS LOGIT AJUSTADOS PARA SÃO CARLOS E WAGENINGEN

15. Identificação das classes de cada variável para cada dado selecionado;
16. Agrupamento dos dados em função dos CEPs, através de tabela dinâmica;
17. Extração das classes predominantes para cada variável, ainda conforme agrupamento da tabela dinâmica por CEP;
18. Formatação da planilha eletrônica com dados resumidos por CEP, de acordo com os padrões exigidos para entrada no programa;
19. Obtenção da planilha formatada com dados resumidos por CEP para a cidade de Wageningen, Holanda;
20. Estimação de modelo Logit para São Carlos - Software utilizado: Nlogit 3.0;
21. Estimação de modelo Logit para Wageningen - Software utilizado: Nlogit 3.0;
22. Análise comparativa dos modelos para as duas cidades (mantidas as mesmas variáveis para os dois modelos);

ETAPA 3 - MELHORIAS NO MODELO LOGIT AJUSTADO PARA SÃO CARLOS

23. Análise de sensibilidade dos dados de São Carlos em relação às classes de categorização das variáveis propostos pelo modelo;
24. Redivisão das classes de algumas variáveis para o modelo de São Carlos;
25. Estimação do modelo Logit para o modelo com novas classes - Software utilizado: Nlogit 3.0;
26. Análise estatística dos resultados encontrados;

ETAPA 4 - MODELO DE REDE NEURAIIS PARA SÃO CARLOS

27. Formatação dos dados selecionados de acordo com os padrões exigidos para entrada no programa;
28. Seleção aleatória de 50 % dos dados para treinamento, 25 % para validação e 25 % para teste no software de redes neurais;

29. Criação de redes com diferentes combinações entre *momentum* e *learning rate* (25 combinações no total) - Software utilizado: *Easy NN Plus 9.0*;
30. Repetição dos itens 28 e 29 por mais duas vezes, criando assim três amostras;
31. Seleção das 10 melhores redes, incluindo diferentes configurações de camadas intermediárias, para comparação de resultados;
32. Avaliação das redes de melhor desempenho, com base na porcentagem de acertos;
33. Seleção da rede de melhor desempenho;
34. Criação de réplica da RNA em planilha eletrônica;
35. Análise de sensibilidade dos dados (variação dos dados de entrada um a um para avaliar grau de influência no modo escolhido - *Ceteris Paribus*);
36. Comparação entre as variáveis do modelo de redes neurais e do modelo Logit;

ETAPA 5 - APRESENTAÇÃO DOS RESULTADOS NA FORMA DE MAPAS POTENCIAIS

37. Alteração de características para análise da condição futura do modelo Logit para as variáveis selecionadas (densidade);
38. Agrupamento dos dados por CEP para as variáveis selecionadas (densidade e renda) da análise do item 35;
39. Inserção de resultados do modelo em ambiente SIG - Software utilizado: *TransCAD 4.8*;
40. Elaboração de mapa temático em função de alterações de potencial para as variáveis selecionadas, conforme item 37;
41. Elaboração de mapa temático em função de alterações de potencial para as variáveis selecionadas (densidade), conforme item 38;
42. Comparação entre os resultados gerados pelas redes neurais e pelo modelo Logit, através dos mapas em SIG;
43. Comparação entre os métodos utilizados (etapa 3 e etapa 4).

6 RESULTADOS

Nesse capítulo são apresentados os resultados da aplicação de técnicas que permitem construir Mapas Potenciais de Transporte Público. Primeiramente, são apresentados os resultados da comparação de modelos de escolha discreta estimados para São Carlos e Wageningen. Em seguida, são discutidas alterações no modelo Logit aplicado em São Carlos, com o intuito de melhorar o seu poder preditivo. Por fim, uma simulação através de redes neurais artificiais foi utilizada para comparação de métodos e resultados.

6.1 MODELOS LOGIT PARA SÃO CARLOS E WAGENINGEN

A comparação entre modelos de escolha discreta para duas cidades exige que eles sejam construídos da maneira mais semelhante possível. Em outras palavras, todo o processo realizado para se estimar a escolha do modo de transporte para um município, deve ser igualmente configurado para o outro.

Um modelo prévio foi estimado para cada localidade, seguindo a categorização indicada pelos estudos anteriores, realizados na Holanda (WAERDEN *et al.*, 2008). Para a cidade de São Carlos não puderam ser utilizadas as variáveis *distância à rodovia* e *razão do tempo de viagem ônibus-carro*, pois estas resultavam em parâmetros fixos no modelo (100 % dos dados em uma mesma categoria) Wageningen teve comportamento semelhante: teve excluídas as mesmas variáveis que São Carlos, além da variável *distância ao centro da cidade*. Entretanto, para fazer a comparação, essa última variável também teve de ser desconsiderada para a cidade brasileira. É importante frisar que não foi observada correlação entre os dados e, assim, as variáveis puderam ser utilizadas e analisadas individualmente.

Diante disso, foi possível elaborar um modelo com as mesmas características para cada cidade e assim comparar as variáveis utilizadas. Os resultados dos parâmetros obtidos através da calibração estão expostos na **Tabela 6.1**, para fins de comparação direta. Foi possível verificar que os dois modelos tiveram resultado de χ^2 inferior ao teste da razão da verossimilhança (LR). Para facilitar a visualização do efeito de cada

parâmetro sobre a escolha, o resultado foi exposto na **Tabela 6.2** em função das probabilidades de troca de modo para cada variável isoladamente (a partir da suposição de que as demais variáveis têm valor zero). Assim, é possível identificar quais características em comum têm maior influência para alterar a escolha do usuário para o ônibus.

Tabela 6.1 Resultado dos modelos Logit de São Carlos e Wageningen

Características	Classes	Cidades	
		São Carlos	Wageningen
Constantes		-0,9166	-0,6898
Disponibilidade de auto	100% ou mais	-	-
	Menos de 100%	-0,3431	-0,0695
Nível de instrução	Alto	-	-
	Outro	-0,1979	-0,0645
Status social	Acima da média	-	-
	Outro	0,0095	0,0242
Tipo de família	Jovem	-	-
	Com criança	-0,0180	-0,0017
	Idosos	-0,1232	-0,1949
Tamanho da família	Menos de 2 pessoas	-	-
	2 a 3 pessoas	0,0216	0,3913
	Mais de 3 pessoas	0,1320	-0,0174
Número de linhas a 350 m	0 linhas de ônibus	-	-
	1 ou 2 linhas de ônibus	-0,7902	-0,0657
	Mais de 2 linhas de ônibus	0,1729	0,2462
Densidade	0 a 30 moradias/ ha.	-	-
	31 a 60 moradias/ ha.	-0,1478	-0,0712
	61 ou mais moradias/ ha.	0,1971	0,1240
Qualidade do ajuste			
Máxima verossimilhança para o modelo nulo		-25431,5701	-14242,0951
Máxima verossimilhança para o modelo ótimo		-25111,85732	-13344,94909
p-quadrado		0,01257	0,06299

Em negrito: parâmetros significativos ($\alpha = 0,05$)

O símbolo '-' indica o parâmetro adotado como base

o valor de χ^2 foi inferior aos dois valores das funções de máxima verossimilhança

Tabela 6.2 Probabilidade de substituição de automóvel por ônibus para as cidades de São Carlos e Wageningen

Características	Classes	Probabilidade de troca do carro por ônibus	
		São Carlos	Wageningen
Constantes		0,29	0,33
Disponibilidade de auto	100% ou mais	0,42	0,48
	Menos de 100%	0,58	0,52
Nível de instrução	Alto	0,48	0,48
	Outro	0,52	0,52
Número de linhas a 350 m	0 linhas de ônibus	0,65	0,45
	1 ou 2 linhas de ônibus	0,31	0,48
	Mais de 2 linhas de ônibus	0,54	0,56
Densidade	0 a 30 moradias/ hectare	0,49	0,49
	31 a 60 moradias/ hectare	0,46	0,48
	61 ou mais moradias/ hectare	0,55	0,53

O alto valor para as constantes dos dois modelos indica que há uma grande influência de características não incluídas na modelagem adotada. O valor dessa constante é ainda maior para São Carlos, indicando que as variáveis do modelo têm menor capacidade explicativa sobre o comportamento de seus usuários. O valor negativo dessas constantes indica ainda que esses outros fatores diminuem significativamente a probabilidade de troca do ônibus pelo carro.

Com o nível de significância adotado de 5 %, as variáveis significativas para as duas cidades foram: *disponibilidade de automóvel, nível de educação, número de linhas de ônibus a 350 metros e densidade*. O comportamento dos usuários de carro quanto à possibilidade de alterar o modo de transporte para ônibus foi avaliado para cada característica, e é discutido nos itens a seguir.

6.1.1 Disponibilidade de automóvel

Em relação a essa característica, tanto São Carlos quanto Wageningen tiveram o comportamento esperado. As áreas com predominância de famílias com disponibilidade de carro inferior a 100 % têm maior probabilidade de trocar pelo modo ônibus caso esse seja de melhor qualidade. Entretanto, é possível perceber que São Carlos tem uma maior sensibilidade nesse quesito. O percentual de usuários dispostos a trocar o automóvel pelo ônibus chegou a 58 %.

6.1.2 Nível de instrução

A semelhança entre São Carlos e Wageningen na avaliação deste atributo é ainda maior. A probabilidade de utilização do carro substituível foi de 52 % nas áreas de baixo nível de instrução para as duas cidades. A pequena variação desse quesito nas áreas com diferentes níveis de instrução (entre 48 e 52 % para as duas cidades) sugere um comportamento muito próximo para as diferentes classes, ou seja, localidades com predomínio de alto nível de instrução (instrução acima do ensino fundamental completo) não devem ser desprezadas na definição de políticas.

6.1.3 Número de linhas a 350 metros

A diferença de valores para essa variável evidencia o comportamento de escolha modal frente a uma característica do sistema de transporte. A cidade de Wageningen teve um comportamento dentro do esperado. A probabilidade de trocar o carro por transporte público cresce conforme o número de linhas de ônibus aumenta, chegando a 56 %. Já em São Carlos, as áreas com maior porcentual de usuários que trocariam o carro por ônibus caso houvesse melhorias na qualidade são as que não possuem linhas de ônibus a uma distância de 350 metros do domicílio, o que parece contrariar o esperado.

6.1.4 Densidade

A variável densidade voltou a mostrar que Wageningen e São Carlos se comportam de maneira semelhante em relação à opção pelo transporte coletivo. Nas duas cidades, as áreas com maior potencial para atrair usuários para o transporte público são aquelas com maior densidade (61 ou mais moradias / hectare), seguido de regiões com baixa densidade (igual ou inferior a 30 domicílios / hectare). Mais uma vez, a variável se mostrou mais sensível para São Carlos, obtendo uma variação maior no potencial de utilização de ônibus entre uma classe e outra.

6.2 MELHORIAS NO MODELO LOGIT PARA SÃO CARLOS

O modelo de São Carlos, quando comparado ao de Wageningen, apresentou um baixo desempenho. Este fato, aliado à impossibilidade de utilização de duas das variáveis, devido a um comportamento uniforme para todas as áreas (parâmetros fixos no modelo), comprovam que o modelo Logit Binomial para São Carlos pode ser aprimorado. O próprio modelo original de São Carlos, acrescido da variável *distância ao centro da cidade*, pode ser utilizado para uma primeira comparação. A presença dessa característica foi capaz de fazer o modelo evoluir de um ρ^2 de 0,01257 para 0,02133 e o valor do χ^2 permaneceu inferior ao valor do teste da razão de verossimilhança (LR).

Em seguida, foi realizada uma avaliação dos intervalos de classes adotados para categorização das variáveis. Isto foi feito através de uma análise de sensibilidade com os dados individualizados (ou seja, não agregados por zonas) para entender a abrangência de cada característica, em especial para o caso das variáveis *distância à rodovia* e *razão do tempo de viagem ônibus-carro*. A análise dos dados, entretanto, não foi conclusiva quanto à melhor categorização a ser utilizada. Foram testadas diversas combinações alterando classes de algumas variáveis. Outras não foram alteradas, tendo em vista a relevância da divisão de classes original na interpretação dos resultados. Por exemplo, não houve alterações no critério de *disponibilidade de carro*, pois é importante saber se a escolha do usuário altera quando o valor de disponibilidade está acima ou abaixo de 100 %.

O objetivo do aperfeiçoamento do modelo foi não mexer na sua estrutura como um todo e tentar manter um mínimo de possibilidade de comparação com o modelo original. As variáveis que sofreram alteração foram: *distância à rodovia*, *tamanho da família*, *razão do tempo de viagem ônibus-carro* e *densidade*. As variáveis que tiveram alteração de categorias mantiveram o número de classes, como é possível observar na **Tabela 6.3**.

Tabela 6.3 Divisão dos dados das características alteradas

Características	Classes	Divisão dos dados (%)
Distância à rodovia	3 quilômetros ou mais	60
	Menos de 3 quilômetros	40
Tamanho da família	Menos de 3 pessoas	35
	3 a 4 pessoas	46
	Mais de 4 pessoas	18
Razão do tempo de viagem	4 ou menos	39
	4,1 a 5	53
	mais de 5	8
Densidade	0 a 25 moradias/ hectare	23
	25 a 45 moradias/ hectare	34
	45 ou mais moradias/ hectare	44

O resultado superior da estatística que avalia a qualidade do ajuste demonstra que o modelo evoluiu. Houve também melhorias no desempenho individual das variáveis, pois a maioria delas teve o valor do nível de significância reduzido e nenhum abaixo do nível de confiança de 95 %. Os resultados obtidos do modelo são exibidos na **Tabela 6.4**.

O resultado das probabilidades de cada variável para o modelo aprimorado manteve as mesmas classes com maior porcentual de potenciais usuários para cada categoria que o modelo utilizado para comparação com Wageningen, à exceção da característica *nível de instrução*. Essa variável inverteu o tipo de área que deve ter maior potencial de atrair usuários para transporte público, passando a ter áreas com predomínio de alto nível de instrução como foco. Esse modelo permite ainda uma análise de um maior número de características, visto que todos os parâmetros foram significativos. A **Tabela 6.5** apresenta a probabilidade para a escolha do ônibus ao invés do carro para o modelo aprimorado.

Tabela 6.3 Evolução dos Modelos Logit para São Carlos

Características	Classes originais	Comparação com Wageningen	Máximo de variáveis possíveis	Novas classes	Modelo aprimorado
Constantes		-0,9166	-0,9836		-0,5090
Disponibilidade de auto	100% ou mais	-	-	100% ou mais	-
	Menos de 100%	-0,3431	-0,3439	Menos de 100%	-0,1881
Nível de instrução	Alto	-	-	Alto	-
	Outro	-0,1179	-0,1151	Outro	0,1076
Status social	Acima da média	-	-	Acima da média	-
	Outro	0,0095	0,0168	Outro	0,0771
Tipo de família	Jovem	-	-	Jovem	-
	Com criança	-0,0180	-0,0134	Com criança	0,1339
	Idosos	-0,1232	-0,1254	Idosos	-0,1941
Distância ao centro	Menos de 1 quilômetro	excluído para comparação com Wageningen	-	Menos de 1 quilômetro	-
	Entre 1 e 2 quilômetros		-0,3358	Entre 1 e 2 quilômetros	-0,3836
	Mais de 2 quilômetros		0,2061	Mais de 2 quilômetros	0,1243
Distância à rodovia	6 quilômetros ou mais	parâmetro fixo	parâmetro fixo	3 quilômetros ou mais	-
	Menos de 6 quilômetros			Menos de 3 quilômetros	0,3365
Tamanho da família	Menos de 2 pessoas	-	-	Menos de 3 pessoas	-
	2 a 3 pessoas	0,0216	0,0267	3 a 4 pessoas	-0,4077
	Mais de 3 pessoas	0,1320	0,1069	Mais de 4 pessoas	0,3078
Número de linhas a 350 m	0 linhas de ônibus	-	-	0 linhas de ônibus	-
	1 ou 2 linhas de ônibus	-0,7902	-0,8432	1 ou 2 linhas de ônibus	-1,0892
	Mais de 2 linhas de ônibus	0,1729	0,2578	Mais de 2 linhas de ônibus	0,4363
Razão do tempo de viagem	1,4 ou menos	parâmetro fixo	parâmetro fixo	4 ou menos	-
	1,5 a 2,4			4,1 a 5	-0,0507
Densidade	0 a 30 moradias/hectare	-	-	mais de 5	-0,0813
	31 a 60 moradias/hectare	-0,1478	-0,1453	0 a 25 moradias/hectare	-
	61 ou mais moradias/hectare	0,1971	0,1907	25 a 45 moradias/hectare	-0,1614
				45 ou mais moradias/hectare	0,2825
Qualidade do ajuste					
Máxima verossimilhança para o modelo nulo		-25431,5701	-25431,5701		-25431,5701
Máxima verossimilhança para o modelo ótimo		-25111,85732	-24889,18432		-23855,08233
p-quadrado		0,01257	0,02133		0,06199

Em negrito: parâmetros significativos ($\alpha = 0,05$)

O símbolo '-' indica o parâmetro adotado como base

o valor de χ^2 foi inferior aos dois valores das funções de máxima verossimilhança

Tabela 6.4 Probabilidade de usuários que trocariam o automóvel pelo ônibus para São Carlos (modelo aprimorado)

Características	Classes	Probabilidade de troca do carro por ônibus
Constante		0,38
Disponibilidade de carro	100% ou mais	0,45
	Menos de 100%	0,55
Nível de instrução	Alto	0,53
	Outro	0,47
Status social	Acima da média	0,52
	Outro	0,48
Tipo de família	Jovem	0,52
	Com criança	0,53
	Idosos	0,45
Distância ao centro	Menos de 1 quilômetro	0,56
	Entre 1 e 2 quilômetros	0,41
	Mais de 2 quilômetros	0,53
Distância à rodovia	3 quilômetros ou mais	0,58
	Menos de 3 quilômetros	0,42
Tamanho da família	Menos de 3 pessoas	0,52
	3 a 4 pessoas	0,40
	Mais de 4 pessoas	0,58
Número de linhas a 350 m	0 linhas de ônibus	0,66
	1 ou 2 linhas de ônibus	0,25
	Mais de 2 linhas de ônibus	0,61
Razão do tempo de viagem	4 ou menos	0,53
	4,1 a 5	0,49
	mais de 5	0,48
Densidade	0 a 25 moradias/ hectare	0,47
	25 a 45 moradias/ hectare	0,46
	45 ou mais moradias/ hectare	0,57

6.3 MODELO DE REDES NEURAIAS

O primeiro passo para a simulação por meio de redes neurais foi dividir os dados de acordo com as características descritas na metodologia. Do total de 1292 dados disponíveis, foram selecionados aleatoriamente 688 dados para treinamento, 329 para validação e 275 dados para teste. Em seguida, foram treinadas redes com 5 variações de *momentum* (0,1, 0,3, 0,5, 0,7 e 0,9) e 5 de *learning rates* (também 0,1, 0,3, 0,5, 0,7 e 0,9). Em todas as redes utilizou-se apenas uma camada intermediária com 7 nós. O procedimento realizado pelo software consistiu em buscar o maior número de resultados corretos para os dados de validação.

Todo esse processo foi repetido por mais duas vezes, criando três amostras com diferentes funções (treinamento, validação e teste) para os dados em cada simulação. Tomando como base o maior número de acertos dos dados de validação, foram selecionadas as 5 melhores redes para uma segunda análise. As variações de *momentum* e *learning rates* das melhores redes foram utilizadas para criar mais 5 redes com uma maior quantidade de camadas intermediárias de nós. Assim, dentre as 10 redes restantes, foi escolhida a rede que apresentou o maior número de acertos em relação aos dados de teste, como mostra a **Figura 6.1**.

Por fim, é possível fazer uma análise da importância das variáveis para a escolha do modo de transporte. A ordem de importância, segundo o modelo de redes neurais, é exibida na **Figura 6.2**. Essa análise, entretanto, não é capaz de dizer como as variáveis influenciam na probabilidade de escolha. Para uma análise mais aprofundada das variáveis, foi criada, em planilha eletrônica, uma réplica da Rede Neural de melhor desempenho, tal como proposto por Bocanegra (2002). Assim, tornou-se mais fácil criar resultados para variações de cada característica e identificar os usuários de maior potencial. O resultado dessas variações é apresentado no item a seguir, junto à comparação com o modelo Logit.

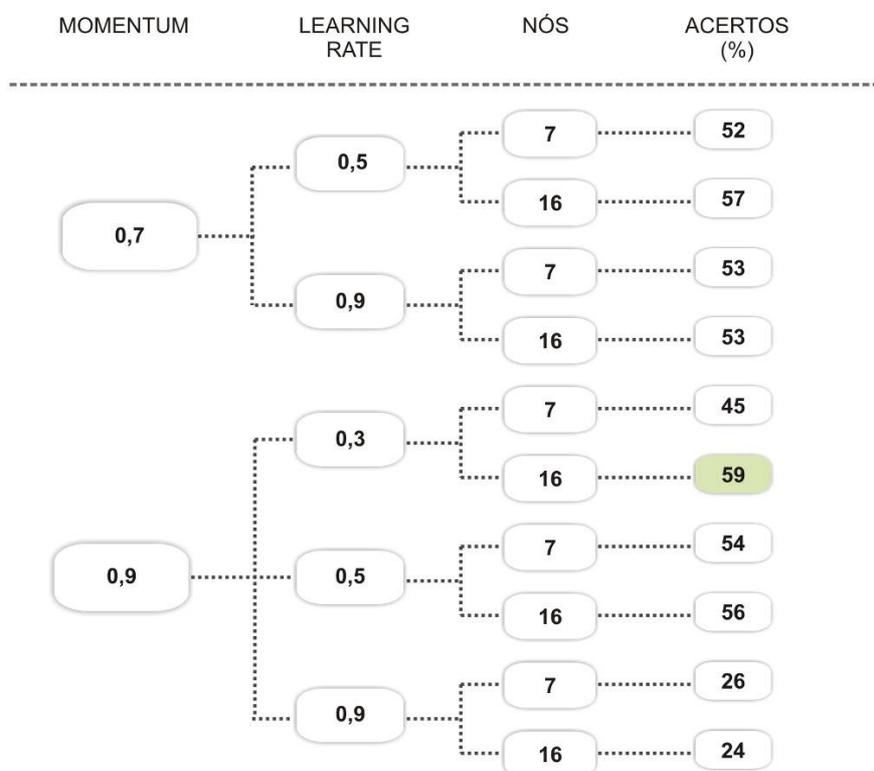


Figura 6.1 Seleção da melhor rede neural

Importância relativa



Figura 6.2 Importância das variáveis

6.4 COMPARAÇÃO ENTRE MODELOS - LOGIT X REDES NEURAIS

Para comparação dos modelos foi possível analisar a porcentagem de acertos para os dados individuais em relação à escolha do modo original. O modelo Logit utilizado teve um acerto de 51,4% dos casos, menos que o modelo de RNA, que obteve 63 %, conforme apresentado na **Tabela 6.5**. O destaque negativo fica para o acerto da escolha dos usuários que trocam o automóvel pelo ônibus que foi de apenas 26,7 % para o modelo Logit. De um modo geral, o desempenho da predição não é considerado bom.

Tabela 6.5 Porcentagem de acerto dos modelos

Modo	Viagens	RNA Acertos (%)	Logit Acertos (%)
Troca por ônibus	604	355 (58,8 %)	161 (26,7%)
Prefere o carro	688	459 (66,7%)	503 (73,1%)
Total	1292	814 (63,0 %)	664 (51,4%)

Para o modelo de RNA, a influência de cada variável utilizada foi observada através da variação em cada atributo. Assim, a análise dessa alteração teve de ser feita com base nos dados individualizados. Diante disso, a comparação teve que ser realizada entre um modelo baseado em dados agrupados e um modelo baseado em dados

individualizados. O percentual de usuários que mudaram de opinião no modelo de redes neurais, a partir de variações nos dados de entrada, foi comparado à probabilidade do potencial uso de transporte público estimado pelo modelo Logit.

6.4.1 Distância ao centro da cidade

A variável *distância ao centro da cidade* teve comportamento distinto para os dois modelos. No caso das redes neurais, o potencial de transporte público cresce conforme aumenta a distância ao centro, enquanto que no modelo Logit existe um patamar mais alto de potencial de utilização do ônibus para áreas a menos de 1 quilômetro. O menor potencial está na faixa de 1 a 2 quilômetros (**Figura 6.3**).

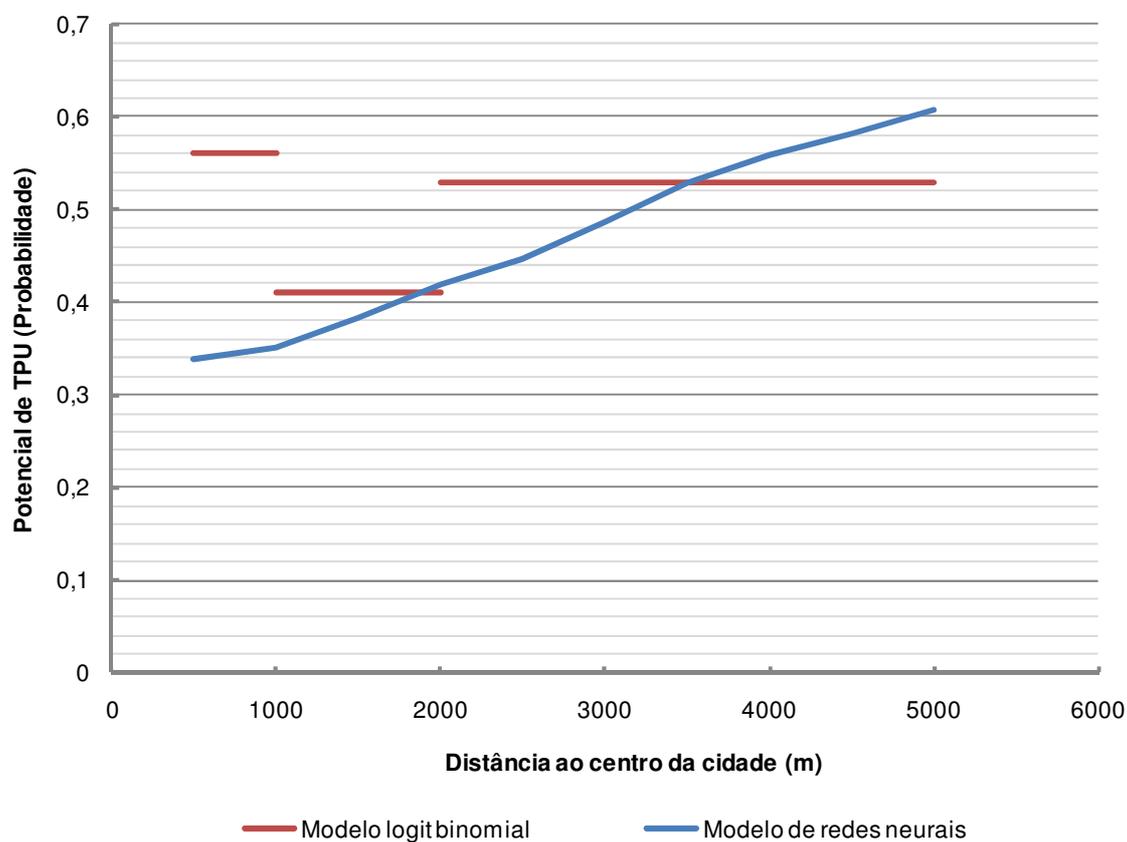


Figura 6.3 Potencial de TPU x Distância ao centro da cidade

6.4.2 Densidade

Para essa característica, os dois modelos resultaram em tendências semelhantes. Tanto o modelo Logit quanto as redes neurais têm um crescimento de potencial de uso do transporte coletivo de acordo com o aumento da densidade, apesar de uma pequena inversão nas estimativas intermediárias do modelo Logit. Entretanto, como é possível perceber na **Figura 6.4**, a avaliação do potencial pelo modelo Logit gerou sempre estimativas mais elevadas do que as redes neurais.

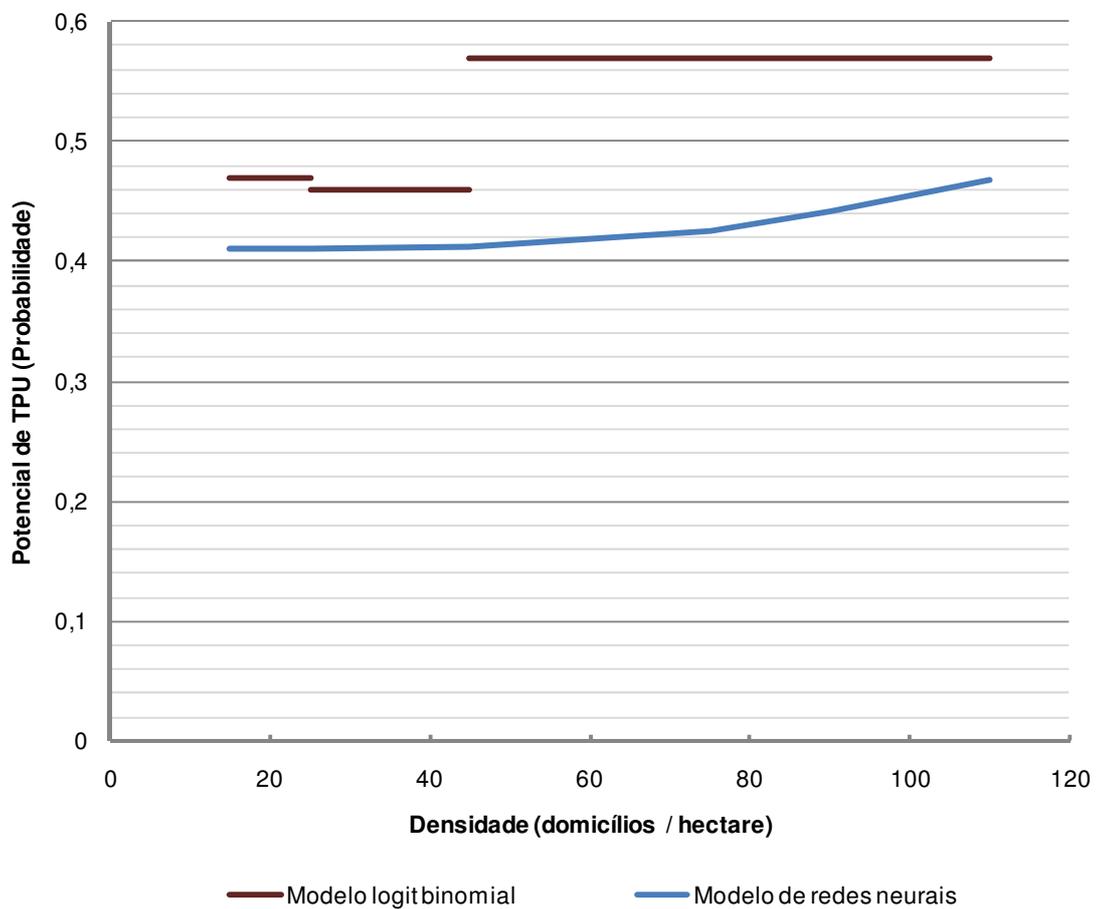


Figura 6.4 Potencial de TPU x Densidade

6.4.3 Status social

Assim como a densidade, a variável status social teve comportamento parecido para os dois modelos. À medida que aumenta a renda dos usuários, menor o potencial de troca para o transporte público (**Figura 6.5**). Apesar da diminuição de potencial, a variação em função do status social não é tão abrangente quanto se poderia imaginar a princípio.

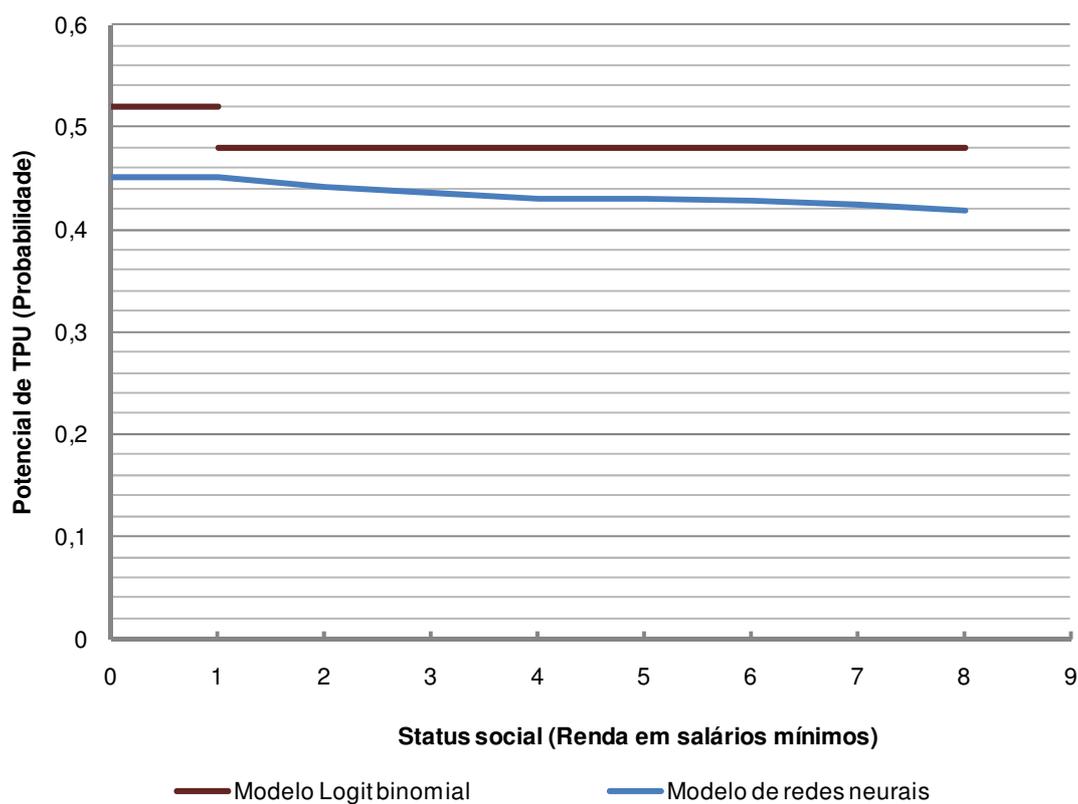


Figura 6.5 Potencial de TPU x Status social

6.4.4 Distância à rodovia

O comportamento da escolha do modo de transporte frente à variação da característica da distância à rodovia foi semelhante para ambos os modelos, como é possível observar na **Figura 6.6**. Tanto no modelo Logit quanto nas redes neurais, o potencial de transporte público aumentou à medida que aumentava a distância à rodovia. Apesar da significância desta característica, não se sabe ao certo a sua utilidade para uma cidade brasileira. O mapa da **Figura 6.7** exibe a distribuição espacial de acordo com esta característica.

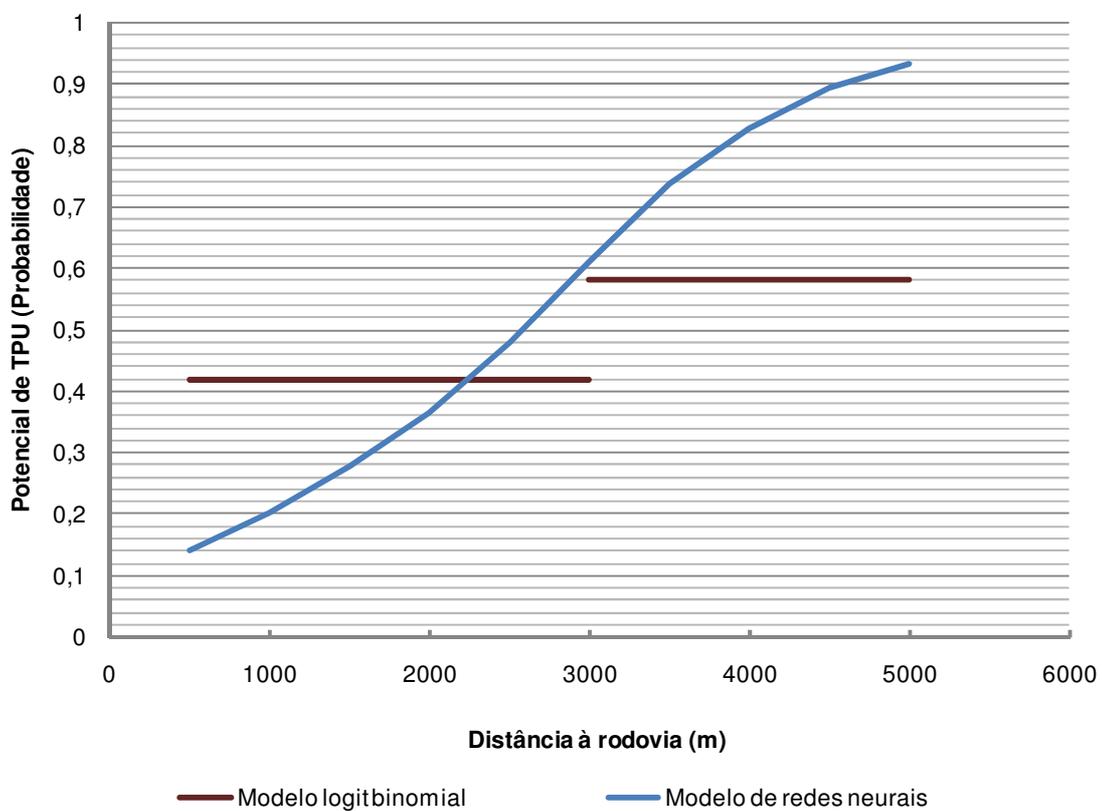


Figura 6.6 Potencial de TPU x Distância à rodovia



Figura 6.7 Mapa da distribuição espacial dos usuários de acordo com a distância à rodovia

6.4.5 Tipo de família

A construção dessa análise envolveu dados de duas naturezas. As classes criadas no modelo Logit foram criadas com base na idade mínima e na idade média das pessoas dos domicílios. Assim, foi possível dividir as categorias em *Família com crianças*, *Família de jovens* e *Família de idosos*. Os dois modelos tiveram comportamentos similares em relação a essa variável. A **Figura 6.8** mostra a análise dos dados em relação à média de idade. Tanto no Logit quanto na rede neural o potencial de utilização do ônibus decresce de acordo com o avanço da idade, mesmo para as pessoas na faixa acima de 60 anos que, por lei municipal, não são obrigadas a pagar pelo transporte coletivo. Na **Figura 6.9** pode-se verificar que não houve uma grande variação do potencial em função da idade dos membros mais jovens das famílias no modelo Logit. É possível perceber ainda que, para as redes neurais, o potencial de troca do carro pelo ônibus é sempre baixo, quando comparado a outras variáveis. Como exemplo, a variável *distância ao centro da cidade* tem variações de potencial de 30 a 60 %, enquanto que a idade mínima nunca é superior a 40 %. Essa interpretação indica que existe uma utilização maior do carro na presença deste fator de membros mais jovens no domicílio.

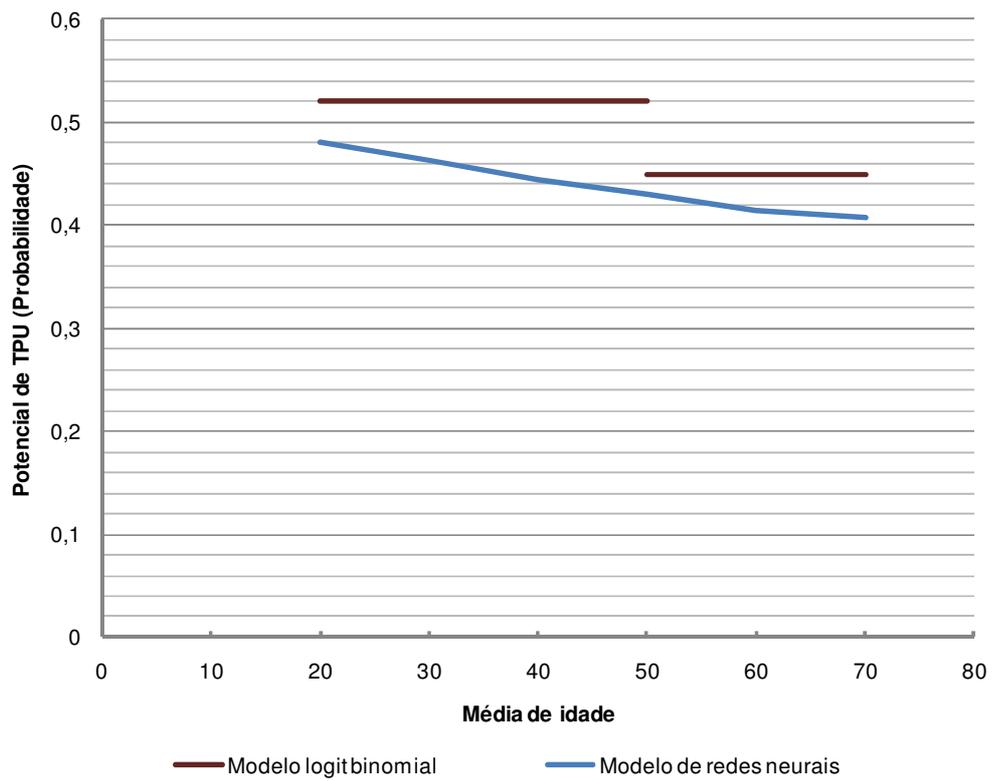


Figura 6.8 Potencial de TPU x Média de idade

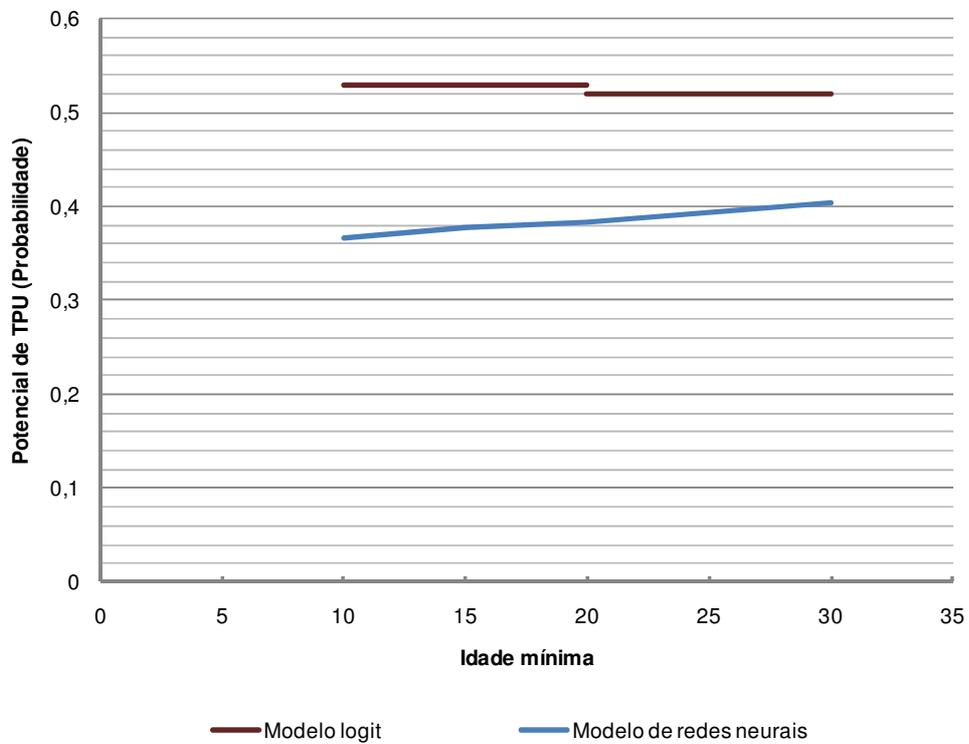


Figura 6.9 Potencial de TPU x Idade mínima

6.4.6 Número de linhas de ônibus a 350 metros

O comportamento dessa variável permitiu uma análise interessante das demais variáveis. O comportamento da escolha do modo de transporte apresenta diferenças entre os dois modelos. O gráfico da **Figura 6.10** apresenta um grande decréscimo de possível utilização do transporte público para disponibilidade de 1 ou 2 linhas de ônibus a uma distância de 350 metros, tal como estimado no modelo Logit. Já as redes neurais apontam para um decréscimo no potencial à medida que aumenta o número de linhas a 350 metros. Essa diferença no comportamento talvez seja explicada pela forma como a variável foi categorizada. O mapa da **Figura 6.11** ilustra que há uma proximidade dos domicílios de diferentes classes, o que pode indicar que, para a cidade de São Carlos, alguns usuários talvez tenham mais linhas de ônibus disponíveis com uma distância de caminhada um pouco maior que o valor adotado no estudo de 350 metros.

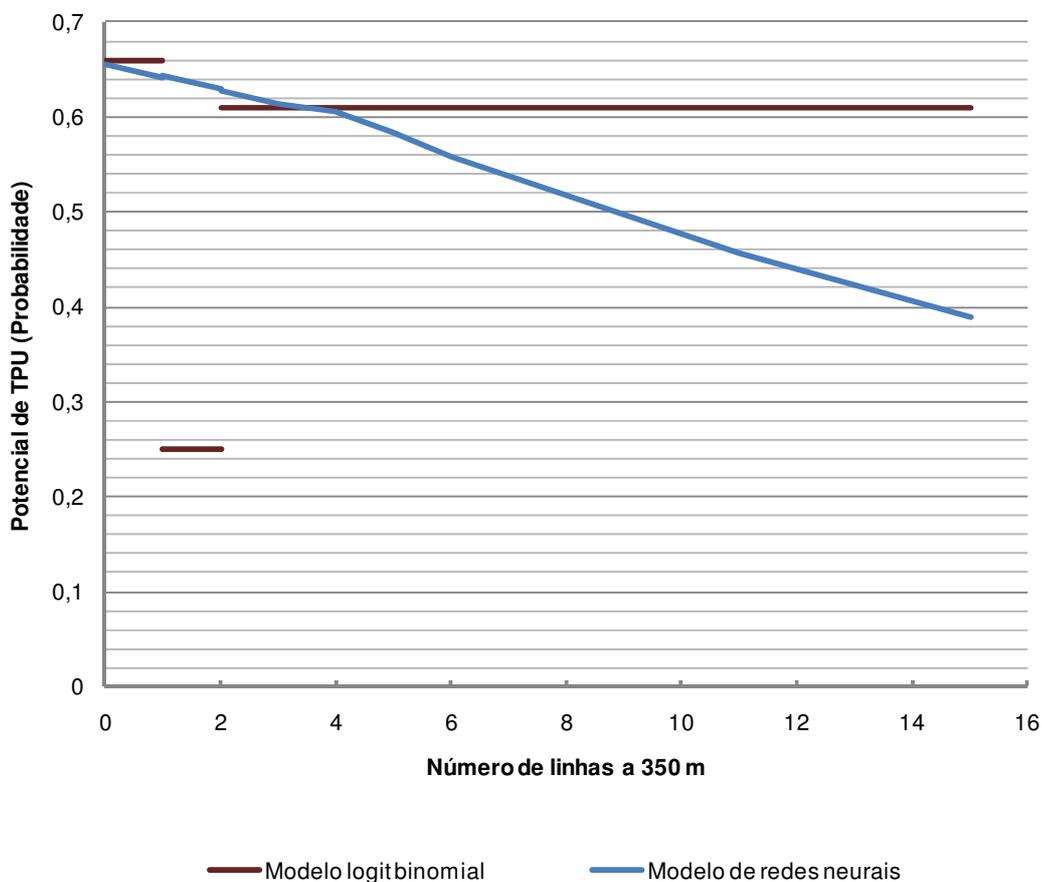


Figura 6.10 Potencial de TPU x Número de linhas a 350 m

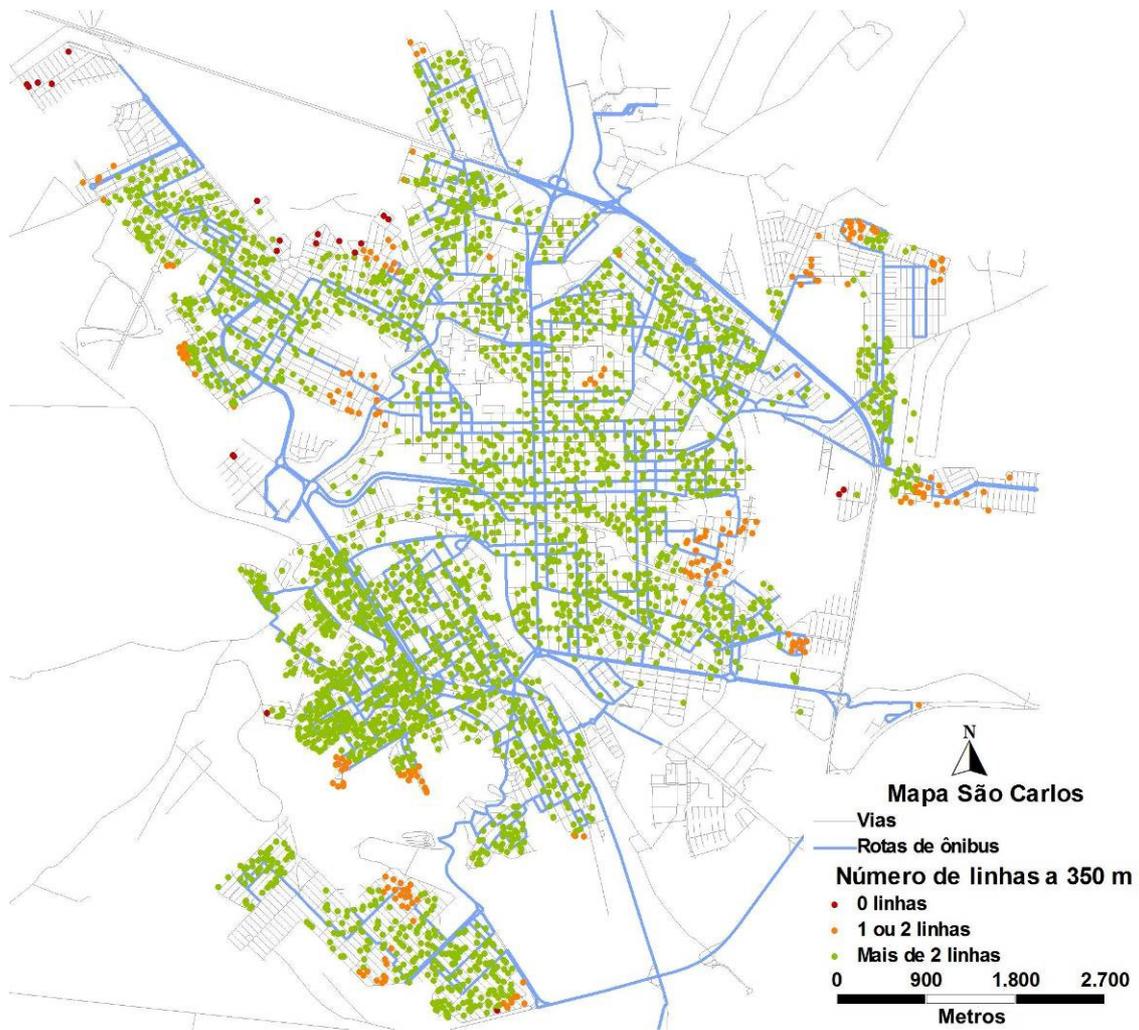


Figura 6.11 Mapa com distribuição espacial do número de linhas disponíveis para cada usuário

6.4.7 Nível de instrução

A variável nível de instrução tem comportamento, quanto à escolha modal, exatamente oposto para os dois modelos testados. Enquanto que as redes neurais indicam um decréscimo do potencial de transporte público quando aumenta o nível de escolaridade, o modelo Logit indica uma diminuição do potencial em áreas com baixo nível de instrução (**Figura 6.12**). O mapa da **Figura 6.13**, que mostra a distribuição espacial do nível de instrução dos usuários, fornece uma possível explicação para os diferentes resultados. A grande mescla, no território, entre os elementos das diferentes classes torna difícil para um modelo que analisa os dados de forma agregada, como foi o caso do Logit nessa aplicação, dissociar a influência das classes nas estimativas. Parte desse problema decorre do fato de que a definição das classes se dá a partir da identificação da maioria de elementos em uma classe. Por exemplo, em uma área com 5 domicílios pesquisados, a caracterização de 3 domicílios com alto nível de instrução contra 2 com baixo nível, levará apenas a informação de que na área predomina a característica de alto nível de escolaridade, quando a realidade mostra que a porcentagem de cada grupo é muito próxima.

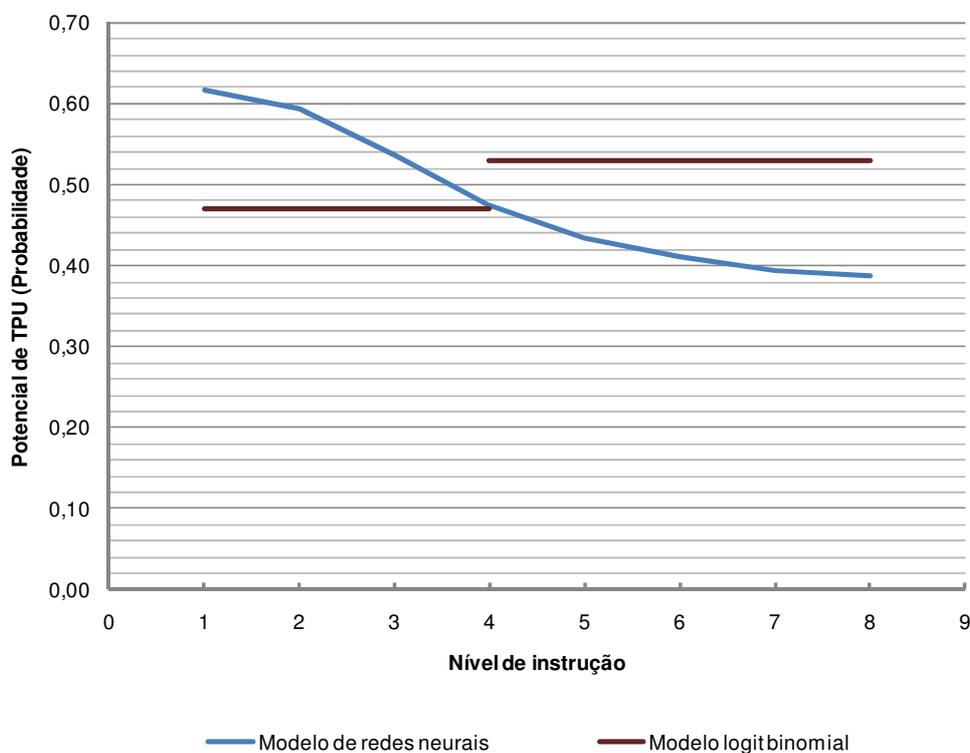


Figura 6.12 Potencial de TPU x Nível de instrução

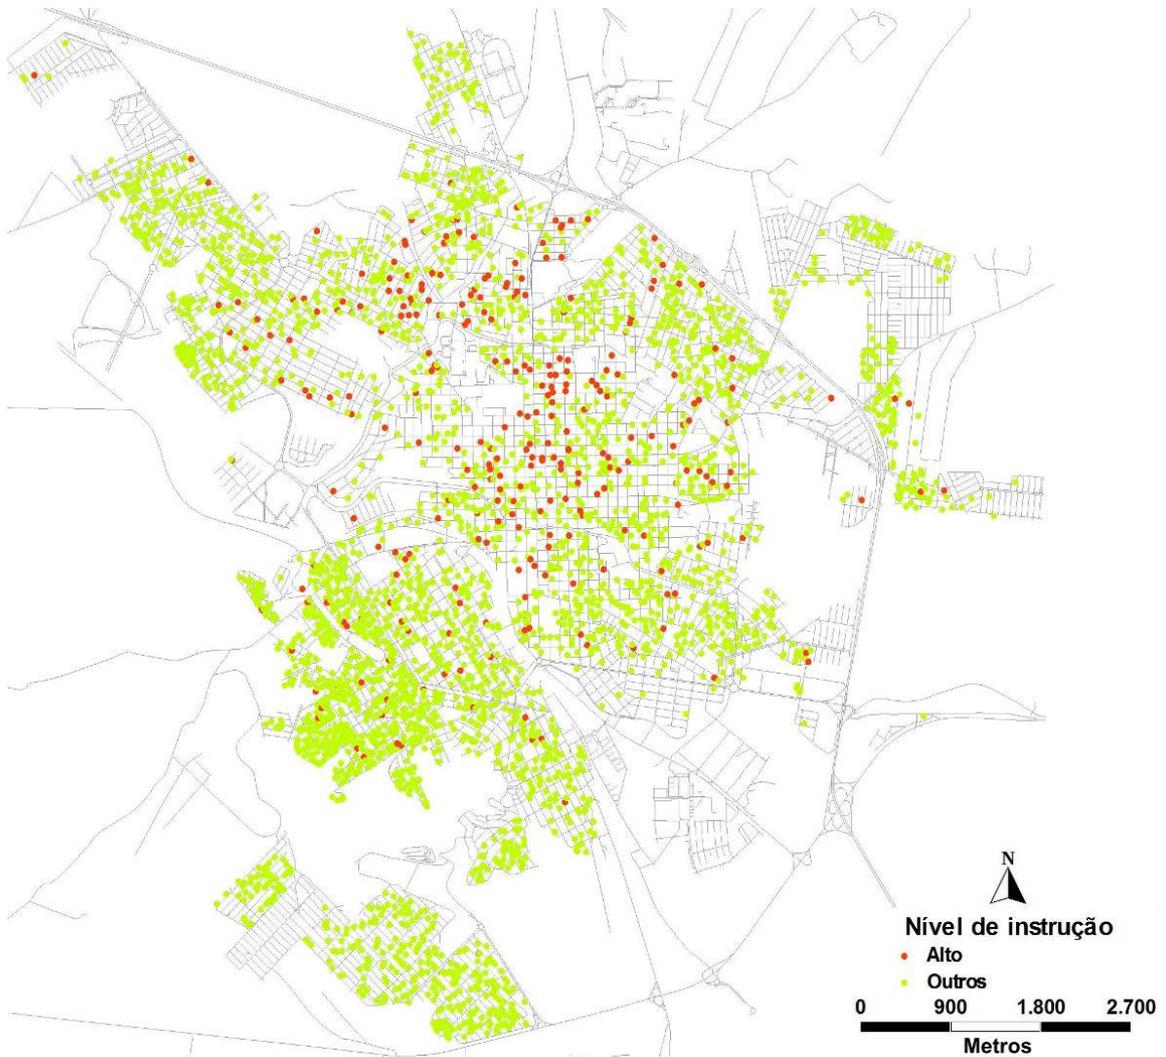


Figura 6.13 Mapa com distribuição espacial do nível instrução de cada usuário

6.4.8 Razão do tempo de viagem entre ônibus e carro

Conforme apresentado desde o primeiro modelo de São Carlos, essa característica não tem variação do potencial de uso do transporte público até a razão do tempo do ônibus três vezes maior que o tempo do carro. Como é possível observar na **Figura 6.14**, o potencial para transporte público decresce conforme aumenta a razão de tempo de viagem entre ônibus e carro para os dois modelos. A exceção está no modelo de redes neurais para os usuários que tem razão superior a 8, quando o potencial volta a aumentar. Verificou-se que, para as redes neurais, o resultado incoerente pode ter explicação na baixa disponibilidade de veículos (abaixo de 50 %) para os usuários que têm razão de viagem entre ônibus-carro acima de 7.

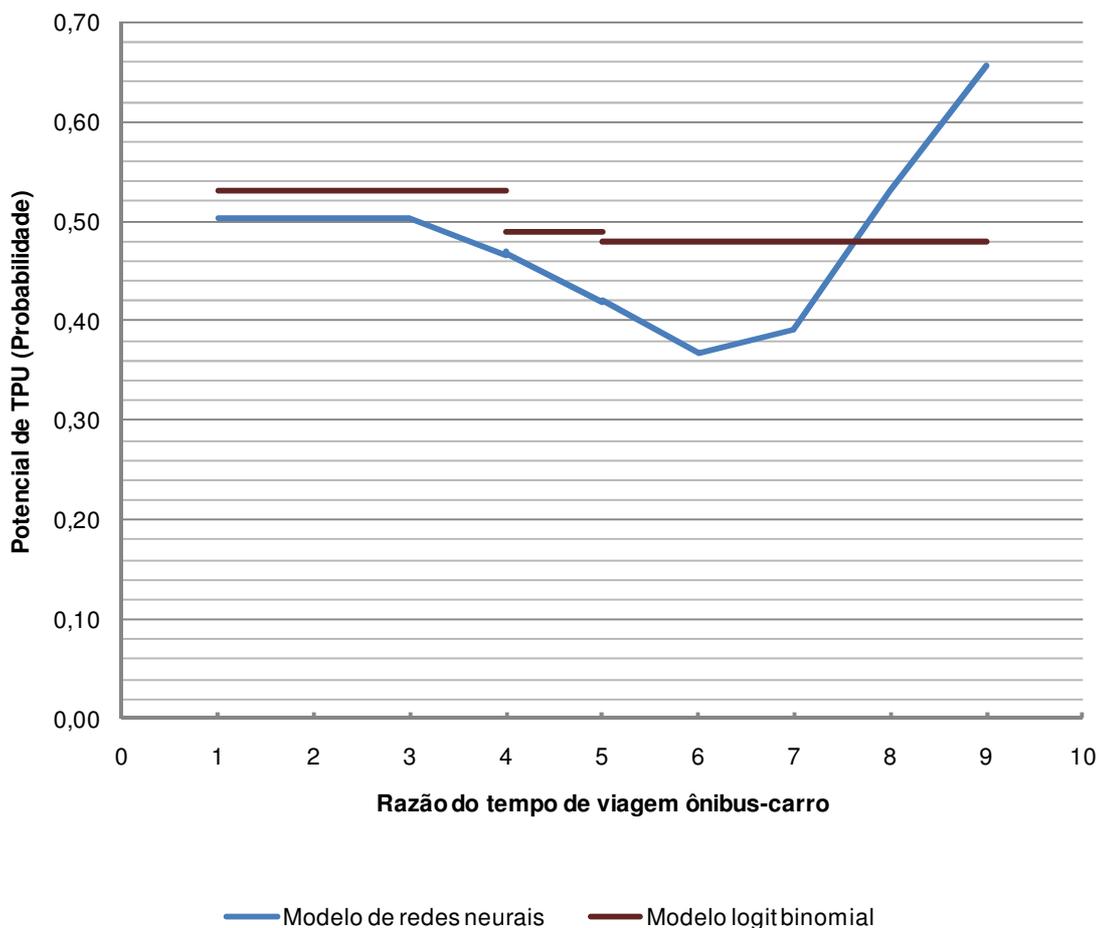


Figura 6.14 Potencial de TPU x Razão do tempo de viagem

6.4.9 Número de pessoas por domicílio

Essa variável teve comportamento muito parecido para os dois modelos. O maior potencial de transporte público parece estar nos valores extremos, seja com muitas ou poucas pessoas por domicílio. Há um potencial maior nos domicílios com mais de 4 pessoas, seguido de domicílios com até 2 pessoas. Na **Figura 6.15** é possível perceber ainda que o agrupamento dos dados para o modelo Logit evidenciou melhor as categorias com mais potencial do que as redes neurais, que se basearam em dados individuais.

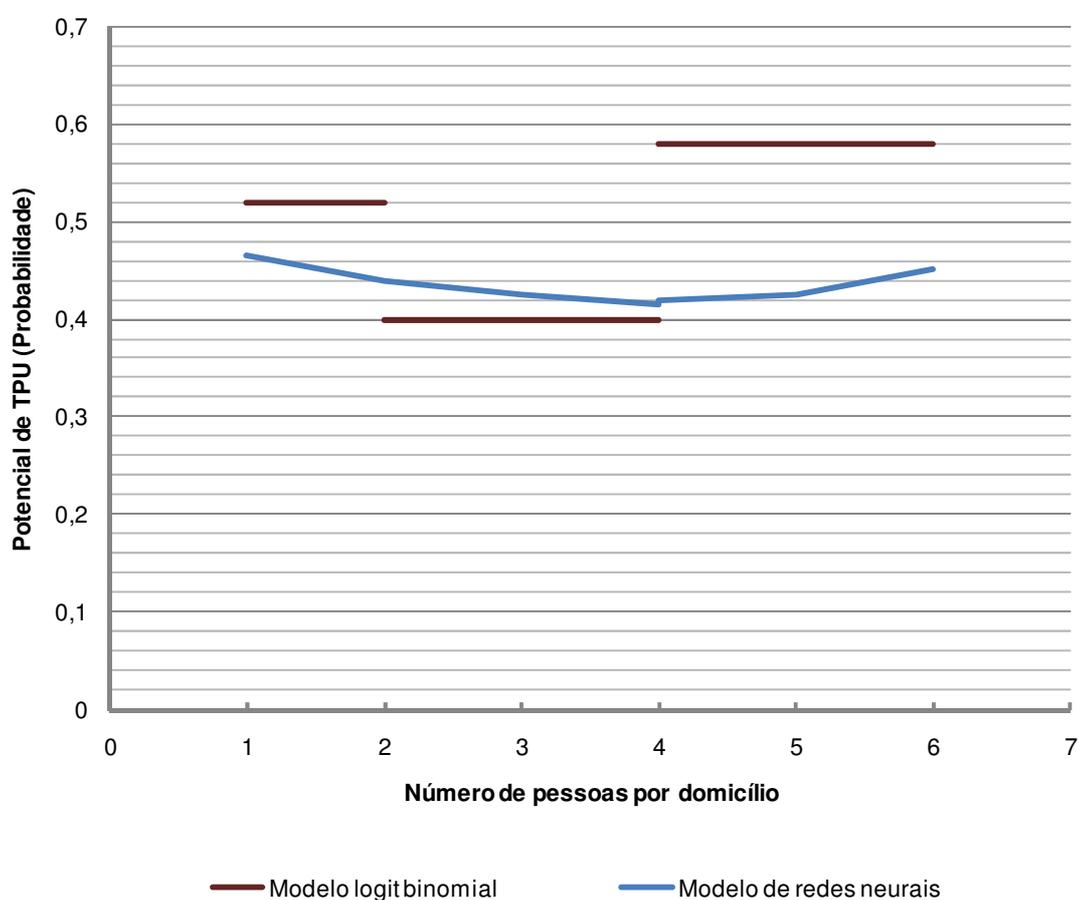


Figura 6.15 Potencial de TPU x Número de pessoas por domicílio

6.4.10 Disponibilidade do carro

O resultado dessa variável foi incoerente entre os dois modelos testados. Enquanto o modelo Logit apresentou um decréscimo no potencial conforme o aumento da disponibilidade, o modelo de redes neurais teve comportamento inverso, como mostra a **Figura 6.16**. Essa variável pode ter se comportado de maneira inesperada para o modelo individualizado devido a um número de dados insuficientes de domicílios com alta disponibilidade de automóveis. Apenas cerca de 10 % dos domicílios tem mais de 100 % de disponibilidade de automóvel.

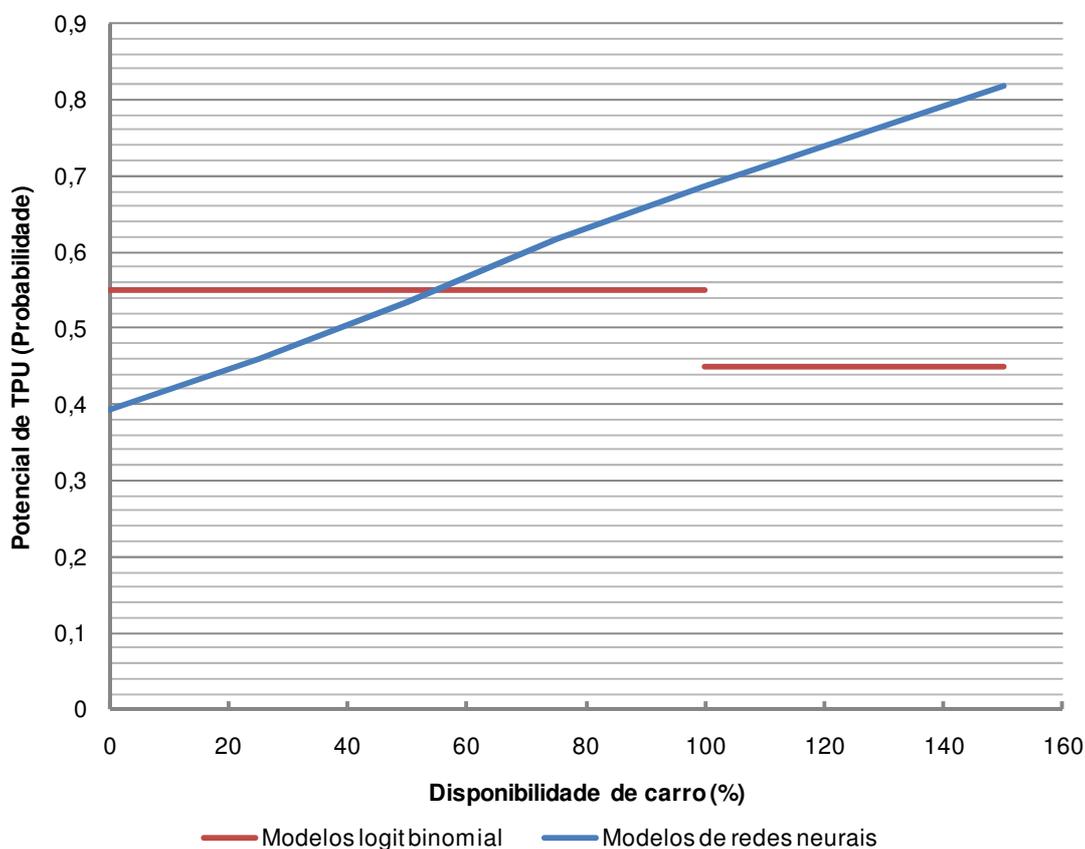


Figura 6.16 Potencial de TPU x Disponibilidade de carro

6.4.11 Avaliação do comportamento das variáveis

A **Tabela 6.6** mostra um resumo da análise do comportamento de todas as variáveis para a aplicação deste estudo. As variáveis *status social*, *tipo de família*, *distância à rodovia*, *tamanho da família* e *densidade* apresentaram comportamento aceitável tanto

para o modelo Logit quanto para as redes neurais. Já as variáveis *disponibilidade de carro* e *distância ao centro da cidade* só foram aceitáveis para o modelo Logit, enquanto que o *nível de instrução* só teve um resultado aceitável para as redes neurais. Essa avaliação pode indicar que a análise baseada em dados agrupados ou em dados individualizados beneficiou uma determinada variável de acordo com a sua distribuição espacial. Por fim, as variáveis *número de linhas a 350 m* e *razão do tempo de viagem* apresentam comportamento fora do esperado para as duas técnicas analisadas.

Tabela 6.6 Avaliação do resultado do comportamento das variáveis

Características	Logit	Redes Neurais
Disponibilidade de carro	aceitável	fora do esperado
Nível de instrução	fora do esperado	aceitável
Status social	aceitável	aceitável
Tipo de família	aceitável	aceitável
Distância ao centro	aceitável	fora do esperado
Distância à rodovia	aceitável	aceitável
Tamanho da família	aceitável	aceitável
Número de linhas a 350 m	fora do esperado	fora do esperado
Razão do tempo de viagem	fora do esperado	fora do esperado
Densidade	aceitável	aceitável

6.5 ELABORAÇÃO DOS MAPAS POTENCIAIS

A representação geográfica das informações extraídas dos modelos é o principal diferencial da aplicação da ferramenta. De posse dos mapas com as áreas onde há maior crescimento dos usuários em potencial de transporte público é possível identificar políticas relacionadas ao sistema de transporte. Com isso, espera-se que os gestores públicos, responsáveis pela garantia do direito de mobilidade do cidadão, tenham mais informações para a tomada de decisões.

Esse potencial pode ser analisado em função de uma característica ou em função de um cenário futuro sob o qual se deseja fazer a análise. A **Figura 6.17** exibe um exemplo de variação de uma característica para análise do transporte público segundo

o modelo Logit. O mapa mostra as áreas em que houve aumento de potencial de uso do ônibus de acordo com um padrão de alta densidade para toda a cidade.

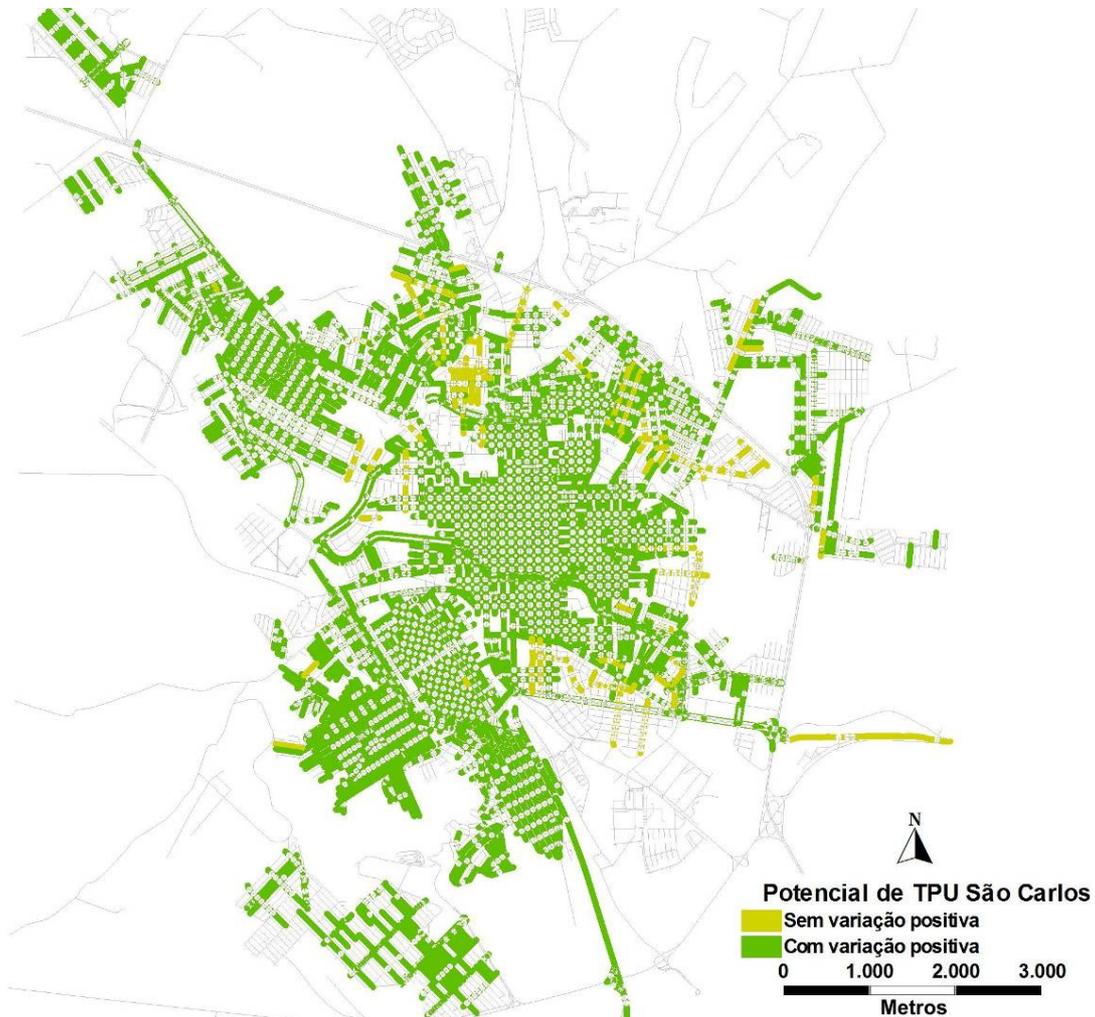


Figura 6.17 Mapa de alta densidade para o modelo Logit

Para realizar a comparação o mesmo mapa foi elaborado para as redes neurais. A **Figura 6.18** mostra que houve uma quantidade menor de áreas com aumento de potencial para esse modelo. Isso acontece porque a calibração foi feita com base em dados individuais e por isso, as áreas são menos sensíveis à alteração de apenas uma característica.

Diante disso, pode-se afirmar que o modelo Logit, por ter sido calibrado a partir de dados agrupados em áreas, tem mais chances de apresentar variações de potencial de porcentagens muito variadas, mas que não necessariamente serão significativas.



Figura 6.18 Mapa de alta densidade para a simulação por redes neurais

As características complementares reveladas pelo modelo Logit (dados agrupados) e pelo modelo de rede neural (dados individuais) levam a crer que um mapa proveniente da fusão das duas análises seja o que melhor represente geograficamente o potencial para uso de transporte público. O produto dessa análise foi o mapa da **Figura 6.19**, resultante do potencial coincidente entre os dois modelos.

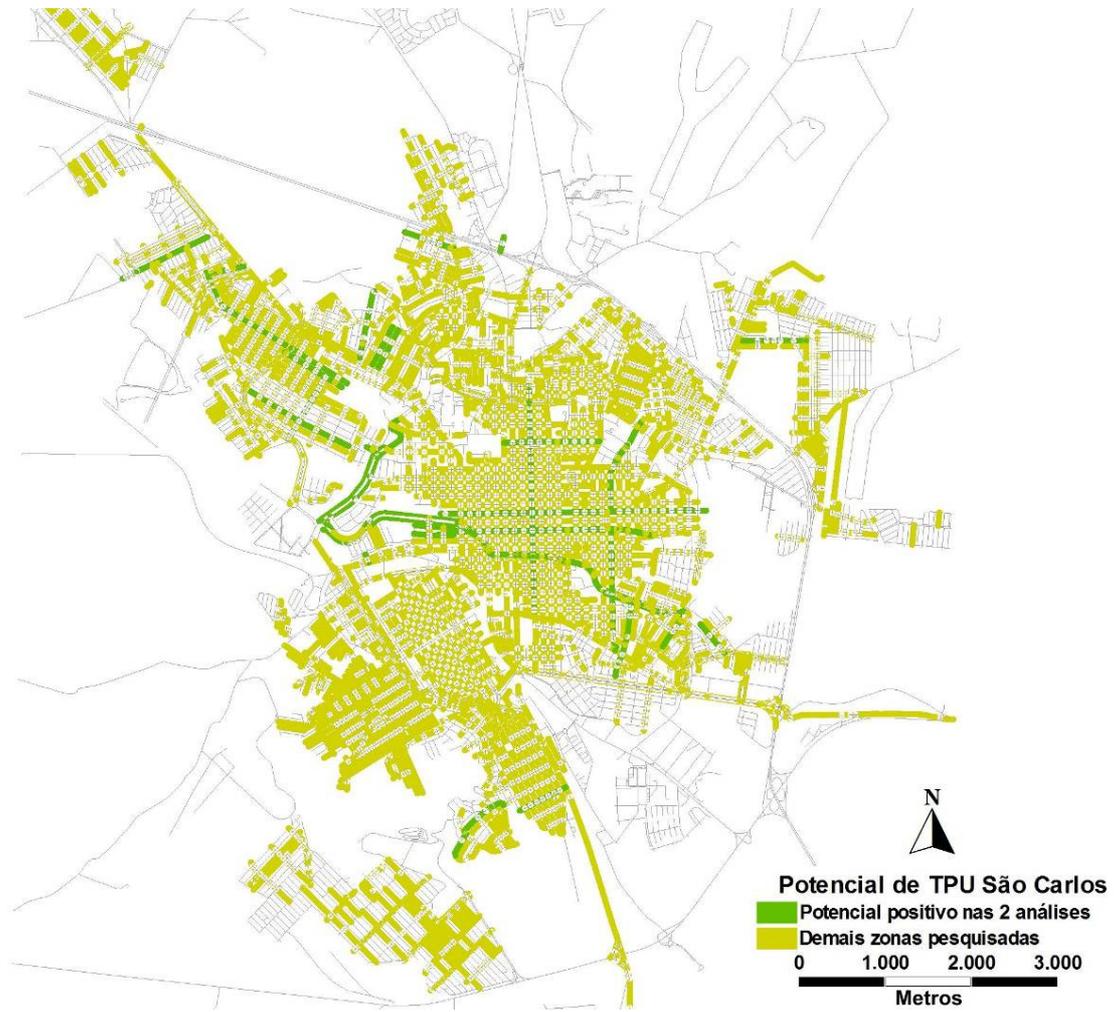


Figura 6.19 Mapa com áreas de potencial positivo coincidentes entre os dois modelos

7 CONSIDERAÇÕES FINAIS

Tendo em vista os objetivos de encontrar potenciais usuários para o transporte público e de avaliar a utilização da técnica de Mapas Potenciais e, diante dos resultados apresentados na seção anterior, foi possível chegar às conclusões descritas nesse capítulo. Por fim, são apresentadas recomendações visando à continuidade da pesquisa.

7.1 CONCLUSÕES

As conclusões aqui apresentadas seguem a mesma sequência proposta na metodologia, com cinco conjuntos de elementos: i) comparação dos modelos Logit para as cidades de São Carlos e Wageningen; ii) melhorias no modelo Logit de São Carlos; iii) comparação do modelo Logit e um modelo de redes neurais; iv) visualização e comparação dos resultados através dos mapas potenciais e v) utilidade da aplicação da técnica.

- i. Esse estudo mostrou que é possível comparar o comportamento dos potenciais usuários de ônibus entre os que utilizam automóvel de diferentes cidades através dos parâmetros calibrados do modelo. A comparação entre São Carlos e Wageningen foi capaz de revelar muitas semelhanças no comportamento dos cidadãos de cada cidade.

Ambas as cidades apresentaram resultados que sugerem que o maior potencial de atrair usuários para o transporte público está nas áreas com alta densidade (mais de 60 domicílios por hectare) e que tenham disponibilidade de automóvel menor que 100 %. Os resultados indicaram ainda que, para as duas cidades, há uma grande influência de outras variáveis não incluídas no modelo e que diminuem a probabilidade de utilização do transporte público.

Para a cidade de São Carlos, verificou-se que, de acordo com os resultados observados para a variável *número de linhas a 350 metros*, as áreas sem linhas de ônibus têm maior probabilidade de utilização de ônibus. Uma possível explicação para este resultado, que contraria o esperado a priori, pode ser uma subestimação da distância de caminhada pelos usuários de transporte público.

- ii. O desempenho superior do modelo aprimorado mostrou que as classes adotadas para as variáveis precisam ser melhor investigadas. A alteração de uma característica relacionada à população provocou uma redução do nível de significância da sua variável, o que sugere que seu resultado está mais próximo de sua representação real em relação ao modelo anterior. Ou seja, para a variável *tamanho da família*, as novas classes estipuladas representam melhor diferentes comportamentos quanto à escolha modal. As variáveis *distância à rodovia* e *razão do tempo de viagem ônibus-carro* deixaram de ter comportamento igual para todas as áreas, devido a uma maior compatibilidade das novas classes com o tamanho da cidade. A variável *densidade* também teve um desempenho superior com a nova divisão de classes.

A melhoria no desempenho dessas variáveis e do modelo em si demonstra que para cada cidade pode existir uma combinação mais representativa de classes para as características.

- iii. A comparação entre os modelos Logit e o modelo de redes neurais desenvolvidos para São Carlos também trouxe conclusões interessantes. As conclusões com base na análise das variáveis podem fornecer informações essenciais aos gestores públicos na criação de políticas de estímulo ao transporte público. Foi possível concluir que um maior crescimento na utilização do transporte coletivo está nas áreas com nível mais baixo de renda e nas regiões com domicílios com mais de 4 pessoas. Para a variável *distância à rodovia*, é possível perceber que o comportamento pode ser explicado por outros fatores. Como a rodovia considerada foi a de maior volume de tráfego (rodovia Washington Luis), as características relacionadas ao bairro podem ter influenciado nos resultados, já que os bairros mais humildes como o Cidade de Aracy estão localizados nos extremo oposto da cidade. Quanto à elaboração de políticas para o resultado da variável *densidade* deve ser estudado o seu impacto indireto na utilização das vias, já que o crescimento do uso do automóvel nessas áreas pode afetar a qualidade oferecida pelo transporte público.

Do ponto de vista do procedimento para estudo dos resultados quanto à escolha do modo de transporte, utilizar métodos de calibração com dados individualizados e dados agrupados de maneira complementar pode trazer uma

análise mais completa dos resultados obtidos. A categorização de classes para o modelo Logit Binomial pode encontrar padrões interessantes que às vezes através dos dados individualizados não é possível analisar. Por outro lado, os dados individualizados podem dar uma melhor caracterização da cidade como um todo.

Contudo, o baixo desempenho de ambos os modelos levanta o questionamento sobre a confiabilidade dos dados. Nenhum dado pode ser rejeitado, pois não houve controle sobre a segurança da opinião do entrevistado quanto à escolha do modo de transporte no momento de aplicação do questionário, de acordo com as necessidades dessa pesquisa. Um maior número de dados em quantidade e qualidade poderia beneficiar a performance do modelo.

Além disso, outro questionamento que certamente interferiu no resultado está relacionado à obtenção de dados. Por exemplo, para o cálculo da disponibilidade de automóvel, a quantidade de indivíduos do domicílio deveria envolver somente as pessoas que têm habilitação, porém isso não foi levado em consideração. Outro exemplo seria a generalização das velocidades adotadas para o transporte por ônibus e para os carros nas vias. Uma maior precisão nessa caracterização dos domicílios pode trazer benefícios ao resultado do modelo.

- iv. As regiões com variação positiva do potencial de transporte público coincidentes entre o modelo Logit e o modelo de redes neurais são as áreas que devem ter preferência para intervenção de políticas de planejamento. As regiões que obtiveram variação positiva de potencial em pelo menos um dos modelos também merecem atenção, logo após as regiões de maior prioridade. Entretanto o estágio atual dessa ferramenta não é capaz de transformar esse potencial em quantidade de usuários que passarão a utilizar ônibus.
- v. A ferramenta de Mapas Potenciais de Utilização de Transporte Público permite uma análise abrangente da utilização do transporte coletivo devido a sua característica espacial. A aplicação desta metodologia para São Carlos confirmou que a visualização geográfica das áreas com maior potencial de atração de usuários para o ônibus pode se tornar um excelente subsídio para políticas de transporte que priorizem o modo coletivo ao invés do modo individual.

Esse instrumento pode ser utilizado de duas formas: i) por meio da criação de políticas de planejamento para o transporte público baseadas no comportamento dos usuários frente a alterações das características relacionadas ao sistema de transportes de uma cidade; ii) através da elaboração de medidas preventivas a uma alteração da escolha do modo de transporte de acordo com a variação nas características socioeconômicas da população, seja esta mudança positiva ou negativa. A análise do primeiro item pode ainda incluir estudos de caso com alterações diretamente no sistema de transportes, algo que facilitaria a utilização da ferramenta pelos gestores.

A abordagem da utilização dessa metodologia também pode ser realizada de forma conjunta. Por exemplo, é possível propor, simultaneamente, uma mudança na infraestrutura de uma grande avenida e preparar-se para o crescimento da disponibilidade de automóvel em toda a cidade. Em relação a alterações nas características socioeconômicas, supõe-se que existam explicações para a alteração desse comportamento (por exemplo, o aumento da renda devido a um crescimento econômico).

7.2 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

A metodologia de Mapas Potenciais de Utilização de Transporte Público deve ser aprofundada antes do emprego como ferramenta de auxílio ao planejamento de transportes. A aplicação desse método em outras cidades pode ajudar a descobrir padrões de comportamento de acordo com o porte da cidade. Poderia ainda dar respostas mais detalhadas quanto à relação entre categorias das variáveis e características da população e do sistema de transporte.

Além disso, a elaboração de uma pesquisa direcionada à metodologia traria dados mais confiáveis à análise dos resultados. A aplicação do modelo Logit incluiu testes com os dados agrupados com base em uma quantidade menor de dígitos do código postal (6 e 7 dígitos) que retornaram quase todas as variáveis como parâmetros fixos. Foram testados ainda dados individualizados que não se mostraram suficientes para calibrar o modelo categorizado. Uma quantidade maior de entrevistas distribuídas espacialmente de acordo com o agrupamento que se deseja estudar poderia trazer resultados mais significativos.

Procedimentos complementares poderiam aprimorar a técnica utilizada e trazer conclusões mais consistentes. A alteração de classes para as variáveis de Wageningen conforme as alterações feitas para São Carlos pode confirmar um desempenho superior do modelo e traria um número maior de características de comparação. A utilização de outras variáveis, tais como número de viagens, densidade populacional, gênero e padrão de uso do solo, também poderia ser testada. Além disso, o método de levantamento das características, especialmente as físicas, também pode ter uma análise mais aprofundada, como fizeram Waerden *et al.* (2010b) com o estudo de diferentes métodos de cálculos da razão do tempo de viagem entre ônibus e carro.

A investigação também pode ser testada através de outros métodos. Uma possível análise seria um modelo de escolha discreta sem categorização. Esse modelo pode fazer uma avaliação direta do grau de importância das características e até dar alguma informação sobre que categorias usar no modelo original.

Outro ponto importante a se analisar neste estudo é a subjetividade do conceito de qualidade. Há várias maneiras de se perceber uma melhoria na qualidade do transporte público e cada indivíduo tem seu modo particular de interpretação. Deve haver, portanto, um estudo de marketing da questão, bem como uma estratégia para manter o atual usuário satisfeito com as condições do sistema de transporte coletivo. Um modo de se fazer isso seria incluir detalhes maiores no questionário para saber mais precisamente o que o usuário gostaria que melhorasse no sistema de transporte público (conforto, segurança, preço, frequência etc.). Poderia também trabalhar outras características da população, como focar em número de viagens e disponibilidade do modo para um determinado par O-D. Isso daria ainda mais subsídios para que os gestores concentrassem investimentos em medidas que assegurassem maior retorno em aumento do número de usuários de transporte público.

8 REFERÊNCIAS

AKAMINE, A., 2005. Explorando Alternativas para Construção de Modelos Neurais de Interação Espacial. Dissertação (Mestrado). Escola de Engenharia de São Carlos, USP, São Carlos.

ANDREASSEN, T.W., 1995. Dissatisfaction with public services: the case of public transportation. *Journal of Services Marketing* v. 9, n. 5, p. 30-41.

BARRETO, J. M., 2002. Introdução às Redes Neurais Artificiais. Laboratório de Conexão e Ciências Cognitivas. Universidade Federal de Santa Catarina, Florianópolis.

BEIRÃO G., J. A. S. CABRAL, 2007. Understanding Attitudes Towards Public Transport and Private Car: A Qualitative Study. *Transport Policy*, n.14, p. 478-489.

BEN-AKIVA, M., D. BOLDUC, e J. WALKER, 2001. Specification, Estimation and Identification of the Logit Kernel (or Continuous Mixed Logit) Model, Working Paper, Department of Civil Engineering, MIT.

BEN-AKIVA, M. E., S. R. LERMAN, 1985. *Discrete Choice Analysis: Theory and Application to Travel Demand*, MIT Press, 1985 - 390 p.

BÉRÉDOS, M., M. RUIGROK e P. DEELEN, 2001. The Potential Public Transport User in the Picture (em holandês), *Verkeerskunde*, v.1, n.9 p. 50-54.

BHAT, C. R. e J. Y. GUO, 2004. A Mixed Spatially Correlated Logit Model: Formulation and Application to Residential Choice Modeling, *Transportation Research, Part B*, v. 38, n. 2, p. 147-168.

BOCANEGRA, C. W. R., 2002. Procedimentos para Tornar Mais Efetivo o Uso das Redes Neurais Artificiais em Planejamento de Transportes. Dissertação (Mestrado). Escola de Engenharia de São Carlos, USP, São Carlos.

BRAGA, A. P., A. P. L. F. CARVALHO, T. B. LUDEMIR, 1998. Fundamentos de Redes Neurais Artificiais. Ed 11. Rio de Janeiro. Escola de Computação, Universidade Federal do Rio de Janeiro.

BRAGA, A. P., T. B. LUDEMIR, A. C. P. L. F. CARVALHO, 2000. Redes Neurais Artificiais, Teorias e Aplicações. Rio de Janeiro: Livros Técnicos e Científicos Editora S.A., 262 p.

BRIO, B. M., A. S. MOLINA, 2001. Redes Neuronales y Sistemas Borrosos. RaMa Editorial, Madri.

BRONDINO, N. C. M., 1999. Estudo da Influência da Acessibilidade no Valor de Lotes Urbanos Através de Redes Neurais. Tese (Doutorado), Escola de Engenharia de São Carlos, USP, São Carlos.

CASELLO, J. M., 2007. Transit Competitiveness in Polycentric Metropolitan Regions. Transportation Research, Part A, n. 41, p 19-40.

CBS - Centraal Bureau voor de Statistiek - Gemeente op Maat, 2006, Wageningen, (em holandês).

CHESHER, A., J. M. C. SANTOS SILVA, 2002, Taste Variation in Discrete Choice Models, Review of Economic Studies, v. 69, p. 147-168.

CORRÊA, F., (2008). Aplicações de Redes Neurais Artificiais no Setor de Transportes no Brasil. Dissertação (Mestrado). Universidade Federal de São Carlos, São Carlos.

CUNHA, C. A., (2005). Estudo de Relações entre Características das Cidades e das Linhas de Transporte Coletivo. Dissertação (Mestrado) - Universidade de Brasília, Brasília.

DELL'OLIO, L., A. IBEAS, P. CECIN, 2011. The Quality of Service Desired by Public Transport Users. Transport Policy v. 18, p. 217-227.

DOMMECK, S. P., J. J. B. LODEWIJKS, 2004. What the Traveler Wants... A Step Forwards to Marketing in Public Transport, Practical Report, NHTV, Breda, Holanda.

ESPINO, R., C. ROMAN, J. D. ORTUZAR, 2006. Analyzing Demand for Suburban Trips: A Mixed RP/SP Model with Latent Variables and Interaction Effects. *Transportation: Planning, Policy, Research, Practice*, v. 33, n. 3, p. 241-161.

FALAS, T., 1995. Neural Networks in Empirical Accounting Research: an Alternative to Statistical Models. *Neural Network World*, v. 5, n. 4, p. 419-432.

FARRELL, M. J., 1954, The Demand for Motor Cars in the United States, *Journal of the Royal Statistical Society, Part A*, v. 117, p. 171-201.

FERRAZ, A. C. P., I. G. P. TORRES, 2004. *Transporte Público Urbano*. Ed. Rima, São Carlos, Brasil.

FERRONATO, L. G., 2002. Potencial de Medidas de Gerenciamento da Demanda no Transporte Público Urbano por Ônibus. Dissertação (Mestrado). Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre.

GALVÃO, C. O., M. J. S. VALENÇA, 1999. *Sistemas Inteligentes: Aplicações a Recursos Hídricos e Ciências Ambientais*. Porto Alegre: Ed. Universidade Federal do Rio Grande do Sul. 246 p.

GAUDRY, M. J. I., M. G. DAGENAIS, 1977. The Dogit model, *Transportation Research, Part B*, v. 13B, p. 105-111.

HAYKIN, S., 1994. *Neural Networks; a Comprehensive Foundation*. New York, Macmillan College Publishing Company.

HEBB, D. O., 1949. *The Organization of Behavior*. New York: John Wiley.

HENRIQUE, C. S., C. F. G. LOUREIRO, R. A. CAVALCANTE, 2004. Caracterização Espacial da Mobilidade dos Usuários Cativos do Sistema Integrado de Transportes de Fortaleza. Artigo apresentado no XVIII Congresso de Ensino e Pesquisa em Transportes, Florianópolis, Brasil.

HENSHER, D. A., T. T. TON, 2000. A Comparison of the Predictive Potential of Artificial Neural Network and Nested Logit Models for Commuter Mode Choice. *Transportation Research, Part E*, v. 36, p. 155-172.

HOPFIELD, J., 1982. Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences of the USA*. v. 79, n. 8, p. 2554-2558.

IBGE, Painel de São Carlos 2007, <http://www.ibge.gov.br/cidadesat/painel/painel.php?codmun=354890>, acessado em 27/03/2011.

LANCASTER, K. J., 1966. A New Approach to Consumer Theory. *The Journal of Political Economy*. n.74, 132-157.

McFADDEN, D., 1974. Conditional Logit Analysis of Qualitative Choice Behavior, *Frontiers in Econometrics*, Academic Press, P. Zarembka Eds., New York, p. 105-142.

McFADDEN, D., K. E. TRAIN, 2000. Mixed MNL Models for Discrete Response, *Journal of Applied Econometrics*, v.15, p. 447-470.

MARICATO, E., 2008. O Automóvel e a Cidade. *Ciência & Ambiente*, Universidade Federal de Santa Maria, n. 37, p. 5-12.

McCULLOCH, W., W. PITTS, 1943. A Logical Calculus of the Ideas Immanent in Nervous Inactivity. *Bulletin of Mathematical Biophysics*, v. 5, n. 4, p. 115-133.

MINSKY, M. L., S. PAPER, 1969. *Perceptrons*. Cambridge, MA: MIT Press.

MOZOLIN, M., J. C. THILL, E. LYNN USERY, 2000. Trip Distribution Forecasting with Multilayer Perceptron Neural Networks: a Critical Evaluation. *Transportation Research, Part B*, v. 34, p. 53-73.

NIJKAMP, P., A. REGGIANI, T. TRITAPEPE, 1996. Modelling Inter-urban Transport Flows in Italy: a Comparison Between Neural Network and Logit Analysis. *Transportation Research, Part C*, v. 4, n. 6, p. 323-338.

NOVAES, A. G., 1986. *Sistemas de Transportes. Volume 1: Análise da Demanda*. Ed. Edgard Blucher, São Paulo, 151 p.

OLIVEIRA, M. E., 2000. *Redes Neurais Artificiais*. <http://geocities.com/CapeCanaveral/Runway/4303/engenharia.html>, acessado em 05/06/2000.

ORTÚZAR, J. D. S., L. G. WILLUMSEN, 1994. Modelling Transport, 2^a Ed., John Wiley and Sons, 439 p.

OUTWATER, M.L., S. CASTLEBERRY, Y. SHIFTAN, M. BEN-AKIVA, Y. S. ZHOU, A. KUPPAM, 2003. Use of Structural Equation Modeling for an Attitudinal Market Segmentation Approach to Mode Choice and Ridership Forecasting. Paper presented at 82nd Annual Meeting of the Transportation Research Board, Washington, D.C.

PUEBLA J. G., O. D. CARDOZO e J. C. G.PALOMARES, 2008. Modelos de Demanda Potencial de Viajeros en Redes de Transporte Público: Aplicaciones en el Metro de Madrid. Proyección, v. 1, n. 4.

RAIA Jr., A. A., 2000. Acessibilidade e Mobilidade na Estimativa de um Índice Potencial de Viagens Utilizando Redes Neurais Artificiais. Tese (Doutorado). Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

ROSENBLATT, F., 1958. The Perceptron: A probabilistic Model for Information Storage and Organization of the Brain. Cornell Aeronautical Laboratorial, Psychological Review, v. 65, n. 6, p. 386-408.

RUMELHART, D. E., G. E. HINTON, R. J. WILLIAMS, 1986. Learning Representations by Propagation Errors. Nature, n. 323, p. 533-536.

SANCHES, S. P., M. A. G. FERREIRA, 2007. Estudo Comparativo Entre um Modelo de Rede Neural Artificial e um Modelo Logit Binomial para Estimar a Opção Modal. Artigo apresentado no XXI Congresso de Ensino e Pesquisa em Transportes, Recife, Brasil

SHMUELI, D., I. SALOMON, D. SHEFER, 1996. Neural Network Analysis of Travel behavior: Evaluating Tools for Prediction. Transportation Research, Part C, v. 4, n. 3, p. 151-166.

SILVA, A. N. R., C. W. R. BOCANEGRA, M. A. PEREIRA, 2001. Uma Introdução ao Uso de Redes Neurais Artificiais para Planejamento Urbano e de Transportes. Escola de Engenharia de São Carlos. Notas de aula.

SILVA, A. N. R., R. A. R. RAMOS, L. C. L. SOUZA, D. S. RODRIGUES, J. F. G. MENDES, 2008. SIG: Uma plataforma para introdução de técnicas emergentes no planejamento urbano: uma ferramenta 3D para análise ambiental urbana, avaliação multicritério, redes neurais artificiais. Ed. Edufscar, 227 p.

SILVA, F. A. B., 2004. Modelos Paramétricos de Escolha Discreta Aplicados à Receita Médica e Automedicação no Continente Português. Dissertação (Mestrado). Instituto Superior de Economia e Gestão, Universidade Técnica de Lisboa, Lisboa, Portugal.

SMITH, M. 1996. Neural Networks for Statistical Modeling. Londres, UK. International Thomson Computer Press.

SPEAR, B. D., 1977. Applications of New Travel Demand Forecasting Techniques to Transportation: a Study of Individual Choice Models. Final Report to the Office of Highway Planning, Federal Highway Administration, U. S. Department of Transportation, Washington, D.C.

SUBRAMANIAN, V., M. S. HUNG, M. Y. HU, 1993. An Experimental Evaluation of Neural Networks for Classification. Computers & Operations Research, v. 20, n.7, p.769-782.

SUGIKI, N., K. FURUSAWA, e N. AOSHIMA, 2001. Location Behavioral Model Considering Transit Characteristics in Life Stage of Households. Paper presented at 9th World Conference of Transportation Research, Seul, Coréia do Sul.

THEIL, H., 1969. A Multinomial Extension of the Linear Logit Model, International Economic Review, v. 10, p. 251-259.

THOMPSON, G. L., J. R. BROWN, T. BHATTACHARYA, 2011. What Really Matters for Increasing Transit Ridership: A Statistical Analysis of How Transit Level of Service and Land Use Variables Affect Transit Patronage in Broward County, Florida. Paper presented at 82nd Annual Meeting of the Transportation Research Board, Washington, D.C.

TRAIN, K. E., 2009. Choice Methods with Simulation. 2^a Ed. Cambridge University Press, Nova York, 388 p.

TUBB, N. R., 1993. A Development Path to Success in Neural Computing. Expert Systems Applications, v. 9, n. 5, p. 5-9.

VASCONCELLOS, E. A., 1982. Os Conflitos na Circulação Urbana: Uma Abordagem Política da Engenharia de Tráfego. Nota Técnica 083/82 - CET - Companhia de Engenharia de Tráfego, São Paulo.

VEDAGIRI P., V. T. ARASAN, 2009. Estimating Modal Shift of Car Travelers to Bus on Introduction of Bus Priority System. *Journal of Transportation, Systems Engineering and Information Technology*, v. 9, n. 6, p 120-129.

VUCHIC, V.R., 2005. *Urban Transit: Operations, Planning, and Economics*, John Wiley & Sons, Inc. Hoboken, Nova Jersey, EUA.

WAERDEN, P., M. BÉRÉDOS, H. TIMMERMANS, 2010a. Travelers' Sensitivity to Public Transport Related Planning Measures. Paper presented at 12th World Conference on Transport Research, Lisboa, Portugal.

WAERDEN, P., A. N. R. SILVA, H. TIMMERMANS, M. BÉRÉDOS, e G. R. ROCHA, 2008. Public Transport Planning Evaluation Tools and their Data Requirements and Availability. *Anais da 9th Conference on Design and Decision Support Systems*, Valkenswaard, Holanda.

WAERDEN, P., H. TIMMERMANS, e M. BÉRÉDOS, 2005. In Search of the Public Transport Users: Towards Public Transportation Potential Maps. CDROM dos anais do 84th Annual Meeting of the Transportation Research Board, Washington DC.

WAERDEN, P., H. TIMMERMANS, e N. vans BRUSSEL, 2010b. Defining an Area-Based Travel Time Ratio in the Context of Geo-Research and Geo- Marketing in Public Transport. *Anais da 11th Conference on Design and Decision Support Systems*, Eindhoven, Holanda.

ZHOU, Y., K. VISWANATHAN, Y. POPURI, e K. PROUSSALOGLOU, 2004. Transit Customers - Who, Why, Where, and How: A Market Analysis of the San Mateo County Transit District. *Anais do 83rd Annual Meeting of the Transportation Research Board*, Washington, D.C.

ANEXOS

ANEXO A - RESULTADO DO MODELO DE SÃO CARLOS

```
--> Discrete choice
      ; Choices= 2,3
      ; lhs=freq
      ; frequencias
      ; rhs=jcava, jedlev, jhsiz1, jhsiz2, jsoc, jfam1, jfam2, jdcent1, jdcent2, jblin1, ...
```

Normal exit from iterations. Exit status=0.

```
+-----+
| Discrete choice (multinomial logit) model |
| Maximum Likelihood Estimates             |
| Model estimated: Feb 28, 2011 at 10:36:33PM. |
| Dependent variable                       Choice |
| Weighting variable                       None |
| Number of observations                    543 |
| Iterations completed                      5 |
| Log likelihood function                   -24889.18 |
| Log-L for Choice model = -24889.18432 |
| R2=1-LogL/LogL* Log-L fncn R-sqrd RsqAdj |
| No coefficients -25431.5701 .02133 -.00457 |
| Constants only. Must be computed directly. |
|           Use NLOGIT ;...; RHS=ONE $ |
| Chi-squared[13] = 953.97419 |
| Prob [ chi squared > value ] = .00000 |
| Response data are given as frequencies. |
| Number of obs.= 543, skipped 0 bad obs. |
+-----+
```

```
+-----+-----+-----+-----+-----+
|Variable | Coefficient | Standard Error |b/St.Er.|P[|Z|>z] |
+-----+-----+-----+-----+-----+
JCAVA     -.3439169242 .35837702E-01 -9.597 .0000
JEDLEV    -.1151383039 .30422799E-01 -3.785 .0002
JHSIZ1    .2668514642E-01 .15078530E-01 1.770 .0768
JHSIZ2    .1068829382 .17765248E-01 6.016 .0000
JSOC      .1683567762E-01 .24780867E-01 .679 .4969
JFAM1     -.1339802309E-01 .17361572E-01 -.772 .4403
JFAM2     -.1253935972 .16290797E-01 -7.697 .0000
JDCENT1   -.3358460178 .21004998E-01 -15.989 .0000
JDCENT2   .2060502303 .17972586E-01 11.465 .0000
JBLIN1    -.8431553979 .12680469 -6.649 .0000
JBLIN2    .2578403193 .66355959E-01 3.886 .0001
JDENS1    -.1452586395 .24654348E-01 -5.892 .0000
JDENS2    .1906503356 .21471476E-01 8.879 .0000
A_2       -.9836114818 .82108029E-01 -11.979 .0000
```

(Note: E+nn or E-nn means multiply by 10 to + or -nn power.)

ANEXO B - RESULTADO DO MODELO DE WAGENINGEN

```

--> Discrete choice
      ; Choices= 2,3
      ; lhs=freq
      ; frequencias
      ; rhs=jcava, jedlev, jhsiz1, jhsiz2, jsoc, jfam1, jfam2, jblin1, jblin2, jdens1, jd...

```

Normal exit from iterations. Exit status=0.

```

+-----+
| Discrete choice (multinomial logit) model |
| Maximum Likelihood Estimates             |
| Model estimated: Feb 25, 2011 at 09:16:32PM. |
| Dependent variable                       Choice |
| Weighting variable                       None |
| Number of observations                    206 |
| Iterations completed                      5 |
| Log likelihood function                   -13344.95 |
| Log-L for Choice model = -13344.94909 |
| R2=1-LogL/LogL* Log-L fncn R-sqrd RsqAdj |
| No coefficients -14242.0951 .06299 .00503 |
| Constants only. Must be computed directly. |
| Use NLOGIT ;...; RHS=ONE $ |
| Chi-squared[11] = 620.72902 |
| Prob [ chi squared > value ] = .00000 |
| Response data are given as frequencies. |
| Number of obs.= 206, skipped 0 bad obs. |
+-----+

```

```

+-----+-----+-----+-----+-----+
|Variable | Coefficient | Standard Error |b/St.Er.|P[|Z|>z] |
+-----+-----+-----+-----+-----+
JCAVA    -.6948071530E-01 .17691958E-01 -3.927 .0001
JEDLEV   -.6445975758E-01 .18762972E-01 -3.435 .0006
JHSIZ1    .3912839397 .50112482E-01  7.808 .0000
JHSIZ2   -.1743098126E-01 .54951690E-01  -.317 .7511
JSOC     .2417514357E-01 .18374705E-01  1.316 .1883
JFAM1    -.1659911508E-02 .29981426E-01  -.055 .9558
JFAM2    -.1948760456 .25450956E-01 -7.657 .0000
JBLIN1   -.6570773000E-01 .22166102E-01 -2.964 .0030
JBLIN2    .2462016363 .23320267E-01 10.557 .0000
JDENS1   -.7122267730E-01 .23122524E-01 -3.080 .0021
JDENS2    .1239972180 .23904698E-01  5.187 .0000
A_2     -.6897979609 .51948907E-01 -13.278 .0000
(Note: E+nn or E-nn means multiply by 10 to + or -nn power.)

```


ANEXO C - MODELO DE SÃO CARLOS PARA COMPARAÇÃO

```
--> Discrete choice
      ; Choices= 2,3
      ; lhs=freq
      ; frequencies
      ; rhs=jcava, jedlev, jhsiz1, jhsiz2, jsoc, jfam1, jfam2, jblin1, jblin2, jdens1, jd...
```

Normal exit from iterations. Exit status=0.

```
+-----+
| Discrete choice (multinomial logit) model |
| Maximum Likelihood Estimates             |
| Model estimated: Feb 28, 2011 at 10:35:05PM. |
| Dependent variable                       Choice |
| Weighting variable                       None |
| Number of observations                    543 |
| Iterations completed                      5 |
| Log likelihood function                   -25111.86 |
| Log-L for Choice model = -25111.85732 |
| R2=1-LogL/LogL* Log-L fncn R-sqrd RsqAdj |
| No coefficients -25431.5701 .01257 -.00974 |
| Constants only. Must be computed directly. |
|           Use NLOGIT ;...; RHS=ONE $ |
| Chi-squared[11] = 508.62820 |
| Prob [ chi squared > value ] = .00000 |
| Response data are given as frequencies. |
| Number of obs.= 543, skipped 0 bad obs. |
+-----+
```

```
+-----+-----+-----+-----+-----+
|Variable | Coefficient | Standard Error |b/St.Er. |P[|Z|>z] |
+-----+-----+-----+-----+-----+
JCAVA     -.3431368230 .35720702E-01 -9.606 .0000
JEDLEV    -.1978592544 .29894666E-01 -6.619 .0000
JHSIZ1    .2160637103E-01 .14980963E-01 1.442 .1492
JHSIZ2    .1320110539 .17632340E-01 7.487 .0000
JSOC      .9495862231E-02 .24611816E-01 .386 .6996
JFAM1     -.1801583207E-01 .17270817E-01 -1.043 .2969
JFAM2     -.1231608832 .16151981E-01 -7.625 .0000
JBLIN1    -.7901784930 .12671557 -6.236 .0000
JBLIN2    .1728580333 .66206479E-01 2.611 .0090
JDENS1    -.1477795102 .24514874E-01 -6.028 .0000
JDENS2    .1970819958 .21202552E-01 9.295 .0000
A_2      -.9165538969 .80254790E-01 -11.421 .0000
```

(Note: E+nn or E-nn means multiply by 10 to + or -nn power.)

ANEXO D - RESULTADO DO MODELO DE SÃO CARLOS, AJUSTADO COM NOVAS CLASSES

```
--> Discrete choice
      ; Choices= 2,3
      ; lhs=freq
      ; frequencias
      ; rhs=jcava, jedlev, jhsiz1, jhsiz2, jsoc, jfam1, jfam2, jdcent1, jdcent2, jdhigh, ...
```

Normal exit from iterations. Exit status=0.

```
+-----+
| Discrete choice (multinomial logit) model |
| Maximum Likelihood Estimates             |
| Model estimated: Feb 26, 2011 at 09:25:36AM. |
| Dependent variable                       Choice |
| Weighting variable                       None |
| Number of observations                    543 |
| Iterations completed                      5 |
| Log likelihood function                   -23855.08 |
| Log-L for Choice model = -23855.08233 |
| R2=1-LogL/LogL* Log-L fncn R-sqrd RsqAdj |
| No coefficients -25431.5701 .06199 .03167 |
| Constants only. Must be computed directly. |
|           Use NLOGIT ;...; RHS=ONE $ |
| Chi-squared[16] = 3022.17817 |
| Prob [ chi squared > value ] = .00000 |
| Response data are given as frequencies. |
| Number of obs.= 543, skipped 0 bad obs. |
+-----+
```

```
+-----+-----+-----+-----+-----+
|Variable | Coefficient | Standard Error |b/St.Er. |P[|Z|>z] |
+-----+-----+-----+-----+-----+
JCAVA     -.1880771629 .36229163E-01 -5.191 .0000
JEDLEV    .1076316774 .11802813E-01  9.119 .0000
JHSIZ1    -.4076660776 .16124163E-01 -25.283 .0000
JHSIZ2    .3077756895 .16223131E-01  18.971 .0000
JSOC      .7713339478E-01 .18114743E-01  4.258 .0000
JFAM1     .1338538974 .18076398E-01  7.405 .0000
JFAM2     -.1940682504 .16245600E-01 -11.946 .0000
JDCENT1   -.3836047909 .21689180E-01 -17.686 .0000
JDCENT2   .1243497459 .18685735E-01  6.655 .0000
JDHIGH    .3365077353 .12535629E-01  26.844 .0000
JBLIN1    -1.089179596 .12781750 -8.521 .0000
JBLIN2    .4362878721 .66816051E-01  6.530 .0000
JDENS1    -.1614080628 .16687016E-01 -9.673 .0000
JDENS2    .2824560123 .16581511E-01  17.034 .0000
JTRAT1    -.5070292481E-01 .19152422E-01 -2.647 .0081
JTRAT2    -.8125792593E-01 .17812352E-01 -4.562 .0000
A_2       -.5089936358 .78118631E-01 -6.516 .0000
```

(Note: E+nn or E-nn means multiply by 10 to + or -nn power.)