

## USO DE REDES NEURAIS ARTIFICIAIS PARA ABORDAGEM DESAGREGADA DE DISTRIBUIÇÃO DE VIAGENS URBANAS COM DADOS DE PREFERÊNCIA REVELADA

**Marina Urano de Carvalho Caldas**

**Renan Favero**

**Cira Souza Pitombo**

Universidade de São Paulo

Escola de Engenharia de São Carlos

### RESUMO

Apesar dos modelos de escolha discreta serem amplamente utilizados em análises desagregadas de demanda por transportes, há restrições relativas ao seu uso, como a propriedade da independência das alternativas irrelevantes e a necessidade de assumir estruturas específicas. Assim, este trabalho propõe uma análise de desempenho do uso de Redes Neurais Artificiais (RNAs) para previsão desagregada de distribuições de viagens urbanas, com dados de Preferência Revelada. O município utilizado neste estudo foi Santa Maria (RS) e os dados utilizados são oriundos de pesquisa domiciliar, elaborada para o Plano Diretor de Mobilidade Urbana. A validação metodológica foi realizada com a calibração de um modelo *Logit Multinomial* para estimativas das escolhas de “macro Bairros”. Foram realizadas diversas comparações entre valores observados e estimados por ambas as abordagens. Conclui-se que a técnica de RNAs pode ser aplicada para análises desagregadas de distribuição de viagens urbanas, sobretudo considerando o seu poder preditivo para alternativas com poucas observações.

### ABSTRACT

Although discrete choice models are widely used in disaggregated travel demand forecasting, there are constraints on their use, such as the independence of irrelevant alternatives and the assumptions of specific structures. Thus, this paper proposes a performance analysis of the use of Artificial Neural Networks (ANNs) for disaggregated forecasting of urban trip distribution, with Revealed Preference data. The municipality used, in this study, was Santa Maria (RS) and the data used came from a household survey, carried out for the Urban Mobility Plan. The methodological validation was performed with the calibration of a *Logit Multinomial* model for estimates of the destinations. Several comparisons were made between observed and estimated values by both approaches. It is concluded that the ANNs technique can be applied for disaggregated analysis of urban trip distribution, especially considering its predictive power for alternatives with few observations.

### 1. INTRODUÇÃO

O estudo da demanda atual e futura, considerando seu objetivo de compreender os deslocamentos de pessoas e mercadorias e os seus determinantes, constitui um importante elemento para o planejamento urbano e para determinar as políticas públicas cabíveis para um maior aproveitamento dos sistemas de transportes (Domecich e McFadden, 1975). Frente a isso, destaca-se o modelo sequencial, o qual consiste em estimar a demanda por transportes através de quatro etapas: (i) geração de viagens; (ii) distribuição de viagens, (iii) escolha modal e (iv) alocação de tráfego.

Este trabalho baseia-se na etapa de distribuição de viagens do modelo sequencial. Para o estudo dela, muitas técnicas foram empregadas ao longo dos anos. Desde modelos clássicos agregados (Casey, 1955; Schneider, 1959; Evans 1970; Wilson, 1967; Evans e Kirby, 1974; Williams, 1976) até modelos de comportamento individual desagregado (Fotheringham, 1983; Ben - Akiva e Lerman, 1985; Novaes, 1986), muito se tem discutido sobre as vantagens e as restrições de cada método.

Com relação aos modelos clássicos agregados, destacam-se o de Fratar, o Gravitacional e o de Oportunidades Intervenientes. O modelo de Fratar (Evans, 1970; Williams, 1976) baseia-se no fator de crescimento e, embora seja considerado de fácil aplicação e entendimento, apresenta

como empecilhos a necessidade de pesquisas sobre as zonas de origem e de destino, o fato de depender da acurácia da matriz presente e a desconsideração de alterações na configuração dos transportes (Cascetta *et al.*, 2007; Ortúzar e Willumsen, 2011).

O modelo Gravitacional, por sua vez, elaborado por Casey (1955) e muitas vezes adaptado (Lowry, 1964; Wilson, 1967; Evans e Kirby, 1974; Mikkonen e Luoma, 1999), é provavelmente o mais utilizado para a etapa de distribuição de viagens. A consideração dos efeitos de impedância, como tempo e custo, e o fato de não exigir uma matriz origem-destino inicial (Ortúzar e Willumsen, 2011) são as maiores vantagens frente ao modelo de Fratar.

Finalmente, o modelo de Oportunidades Intervenientes, concebido por Stouffer (1940), considera que a probabilidade de que uma viagem tenha determinado local como destino é proporcional à quantidade de oportunidades oferecidas pelo mesmo. Muito embora possua uma base teórica consistente (Wilson, 1967), esse modelo, devido a sua difícil compreensão, a sua pouca vantagem frente ao modelo gravitacional e à falta de aplicativos adequados (Ortúzar e Willumsen, 2011), não é usual, sendo sua aplicabilidade indicada para o estudo de viagens em que as oportunidades sejam decisivas para a escolha do destino.

Apesar de possuírem características e propriedades únicas, os modelos mencionados anteriormente exibem em comum a sua natureza agregada, ou seja, o fato de não considerarem as características individuais e domiciliares que também norteiam a escolha dos destinos pelos indivíduos. Essa propriedade dos modelos clássicos foi determinante para que se discutisse sobre a eficiência deles em refletir o que ocorre na realidade e em prever cenários futuros. Nesse contexto, ressalta-se, como alternativa aos modelos agregados tradicionais, os modelos de escolha discreta, dos quais se destaca o modelo *Logit Multinomial*.

Embora seja, no geral, aplicado para a etapa de escolha modal, o modelo *Logit Multinomial* tem sido também utilizado, devido sua natureza desagregada, para a etapa de distribuição de viagens (Chow *et al.*, 2005; Mishra *et al.*, 2013), na qual as opções de destino correspondem às diferentes alternativas. Apesar dos bons resultados obtidos, o modelo *Logit Multinomial* apresenta restrições matemáticas, como suposições de distribuição populacional, problemas de multicolinearidade e o fato de considerar a independência das alternativas irrelevantes (IIE). Essa propriedade assume que a probabilidade de escolha de uma alternativa frente a outras não será afetada pela inclusão ou retirada de novas alternativas (Luce e Suppes, 1965), o que não representa a realidade no caso de correlação entre alternativas.

Apesar de algumas dessas limitações estarem ausentes em outros modelos de escolha discreta, diversos estudos têm sido publicados acerca de aplicações de ferramentas de Inteligência Artificial para a previsão da demanda por transportes e suas interações espaciais (Faghri e Sandeep, 1998; Huisken e Coffa, 2000; Tillema *et al.*, 2002; Roma *et al.*, 2017; Rasouli, 2013; Pitombo *et al.*, 2017). Essas pesquisas concluíram que o uso de ferramentas de Inteligência Artificial é capaz de prever, com alta precisão, a distribuição espacial das viagens.

Com relação à técnica de Redes Neurais Artificiais (RNAs), Shmueli e Salomon (1996) exaltaram as seguintes características: a aplicabilidade para extensos bancos de dados e a não exigência, assim como para outras ferramentas de Inteligência Artificial, de formalizar, previamente, relações entre as variáveis. Apesar disso, percebe-se que na literatura há muitos trabalhos relativos à aplicação de RNAs para a escolha do modo de transporte, mas há poucos

estudos quanto ao seu uso para a etapa de distribuição de viagens, sobretudo com banco de dados desagregado. Trabalhos como de Black (1995), Subba Rao *et al.* (1998), Carvalho *et al.* (1998), Mozzolin *et al.* (2000), Cantarella e de Luca (2005), Rasouli e Nikraz (2013), Tillema (2006) evidenciaram a maior precisão do uso de um modelo com RNAs quando comparado aos modelos Gravitacional, *Logit Multinomial* e *Nested Logit*, mesmo quando a quantidade de dados é escassa. Ainda que Carvalho *et al.* (1998) proponham, em seu trabalho, uso de RNAs para distribuição de viagens em uma abordagem desagregada, sua pesquisa não inclui características socioeconômicas dos indivíduos, o que poderia aumentar o poder preditivo do modelo, além de, neste caso, ter sido aplicada a dados de Preferência Declarada.

Assim, este trabalho tem como objetivo fazer um estudo da eficiência do uso de Redes Neurais Artificiais para uma análise desagregada de distribuição de viagens urbanas. Para isso, utilizou-se dados reais de uma pesquisa domiciliar de uma cidade de médio porte, a qual foi dividida em “macro Bairros”, sendo eles os destinos possíveis para cada viagem. Além de dados socioeconômicos dos indivíduos, o modelo considerou informações agregadas sobre as origens das viagens. Para fins de validação metodológica, realizou-se calibração tradicional do modelo *Logit Multinomial*, cujo desempenho foi comparado ao da aplicação de RNAs.

## 2. FERRAMENTAS

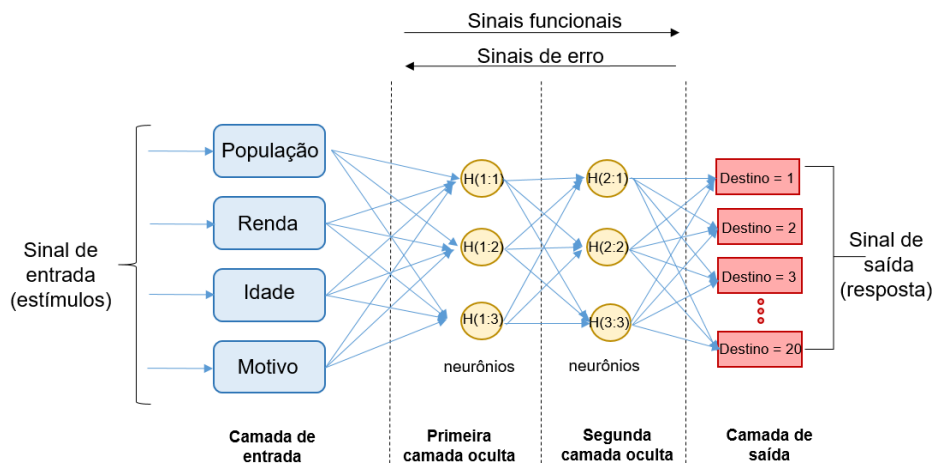
### 2.1. Redes Neurais Artificiais (RNAs)

Uma das técnicas de Inteligência Artificial promissora é a Rede Neural Artificial (RNA). Tal ferramenta reproduz o comportamento de funções matemática, incluindo aquelas não-lineares (Smith, 1996). A RNA tem seu funcionamento baseado na estrutura do cérebro humano, uma vez que o conhecimento é adquirido a partir de um processo de aprendizagem. No caso das RNAs, a conexão entre os neurônios, conhecidas como pesos sinápticos, é utilizada para armazenar o conhecimento adquirido (Haykin, 2001).

Em geral, redes neurais são treinadas para, a partir de um dado de entrada, obter um dado de saída. O conhecimento então é mantido nos neurônios, e esse processo de treinamento é chamado de aprendizagem de máquina. O aprendizado é um processo que permite à rede ajustar e adaptar, gradualmente, os pesos sinápticos e suas conexões para formar um modelo cada vez mais preciso (Carvalho, 1998).

Uma RNA é formada por camadas de entrada (variáveis independentes), ocultas e de saída (estimativa de variável dependente). A informação salva na camada de entrada é transferida para a camada de saída através das camadas ocultas. Nesta pesquisa, utilizou-se a rede progressiva de múltiplas camadas (*multilayer perceptron*), conforme o modelo da Figura 1. Essa rede é capaz de extrair dados mais precisos quando comparadas às redes de única camada. Além disso, esse modelo apresenta maior precisão, rápida convergência e permite grande quantidade de dados de entrada.

Em relação à arquitetura, quando a rede possui um grande número de camadas ocultas ou é treinada por muitas interações, pode ocorrer o *overtraining*. Nesse caso, a rede apresenta uma boa calibração para o banco de dados treinado, mas um baixo poder de generalização para dados não treinados. Por isso, deve-se buscar uma Rede Neural que possibilite uma boa precisão, mas com um menor número de neurônios e camadas, para que o modelo seja eficiente (Carvalho, 1998). Nesta pesquisa, com a finalidade de manter um número máximo de camadas ocultas, impôs-se a limitação de no mínimo 1 e no máximo 20 camadas ocultas.



**Figura 1:** Representação de uma Rede Neural com duas camadas ocultas. Adaptado de Haykin (1999)

Os resultados dependem diretamente da aptidão da rede em extrair informações e replicá-las. Por isso, de acordo com Cantarella (2005), uma arquitetura eficiente deve, preferencialmente, ter um grande poder de reprodução, medida pelo erro entre observações simuladas e calibradas; boa generalização, medida pelo erro entre observações simuladas e validadas; e baixa dependência nas condições iniciais, avaliada pela dispersão de erro entre observações e simulações para a calibração. Assim, a seleção de arquitetura neste trabalho foi feita diretamente pelo *software* IBM SPSS 24.0, que elege automaticamente a melhor arquitetura.

Outra configuração importante na construção da Rede Neural é a modalidade de treinamento aplicada. Conforme o IBM (2016), o tipo de treinamento determina como a rede processa os registros. Neste trabalho, testaram-se os treinamentos em lote, online e em minilote. De acordo com IBM (2015), o treinamento em lote minimiza diretamente o total de erros, mas pode precisar de muitas atualizações das ponderações e, por isso, necessita de muitas transmissões de dados. O treinamento online atualiza as ponderações sinápticas após a inserção de cada registro no treinamento, comumente utilizado em banco de dados maiores. O treinamento em minilote, por sua vez, divide as observações em grupos de tamanho iguais e, a cada lote, atualiza as ponderações. Nessa etapa, selecionou-se a rede com maior número de acertos para fazer as comparações com o método tradicional (no caso deste trabalho o modelo *Logit Multinomial*).

As regras de interrupção, usadas para o treinamento, foram o máximo de 10 etapas sem uma redução no erro, tempo de treinamento máximo de 15 minutos, cálculo automático de períodos de treinamento, alteração relativa mínima no erro de treinamento de 0,0001 e um máximo de 1000 casos armazenados na memória.

Após o treinamento, as ponderações sinápticas foram salvas e aplicadas ao banco de dados com 30% dos registros para validação. Os resultados permitiram avaliar a quantidade de acertos e a precisão da Rede Neural obtida.

## 2.2. *Logit Multinomial*

O modelo *Logit Multinomial* é um modelo de escolha discreta que se baseia na utilidade de diferentes alternativas, considerando, para medição dessa utilidade, uma combinação de variáveis explicativas, inclusive características individuais, sendo essa uma das vantagens

frente aos modelos clássicos de distribuição de viagens (Ben-Akiva e Lerman, 1985; Ortúzar e Willumsen, 2011). As utilidades configuram-se da seguinte forma:

$$U_{in} = a + b \cdot x_{1i} + c \cdot x_{2n} \quad (1)$$

Onde:

$U_{in}$ : utilidade da opção  $i$  para o indivíduo  $n$ ;  $x_{1i}$  e  $x_{2n}$ : variáveis explicativas relativas à alternativa  $i$  e ao indivíduo  $n$ , respectivamente;  $a$ ,  $b$  e  $c$ : coeficientes a serem estimados.

Definidas as utilidades para cada opção, cujos coeficientes são estimados a partir da máxima verossimilhança, as probabilidades de as alternativas serem escolhidas podem ser calculadas, para cada indivíduo  $n$ , sendo elas definidas por:

$$P_{in} = \frac{e^{U_{in}}}{\sum_{j=1}^z e^{U_{jn}}} \quad (2)$$

Onde:

$P_{in}$ : probabilidade da opção  $i$  ser escolhida pelo indivíduo  $n$ ;  $z$ : quantidade de alternativas;  $e$ : base do logaritmo neperiano.

### 3. MATERIAIS E MÉTODO

#### 3.1. Dados

As informações exploradas nesta pesquisa são relativas à cidade de Santa Maria (RS). Os dados sobre os indivíduos e sobre as viagens foram obtidos a partir de pesquisa domiciliar, realizada para a elaboração do Plano Diretor de Mobilidade Urbana (IPLAN, 2013). Os dados sociodemográficos das origens têm como fonte o Censo do IBGE (IBGE, 2010).

A pesquisa domiciliar teve como foco o distrito urbano, mais especificamente, o distrito Sede, no qual residem e trabalham cerca de 95% da população do município. De acordo com dados do Censo do IBGE de 2010, o distrito em questão concentrava, naquele ano, 246.465 habitantes e era formado por 41 bairros.

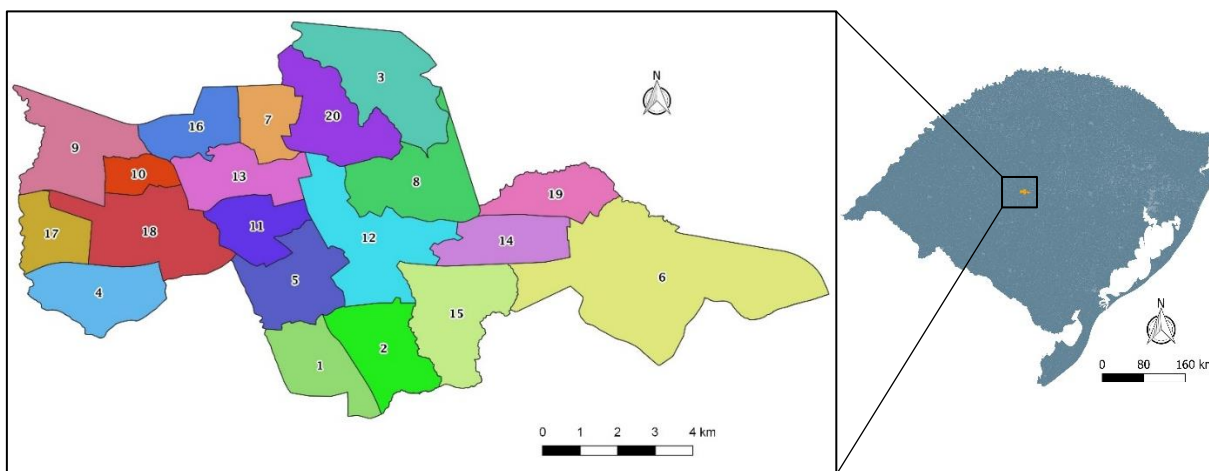
À época da pesquisa domiciliar, em 2013, a cidade tinha como principal fonte de renda o setor dos serviços, que representa 81% do seu PIB, e tinha como característica os polos de atração relacionados à educação. Em contexto nacional, a cidade era considerada a terceira com maior número de mestres e doutores per capita. Além disso, a cidade possuía seis instituições de ensino superior e mais de 35 mil universitários. Além do comércio variado, a localidade oferecia ao público quatro grandes estabelecimentos comerciais. Devido a isso, Santa Maria era considerada centro de referência em serviços para 36 municípios da Região Central do estado do Rio Grande de Sul, influenciando mais de um milhão de pessoas (IPLAN, 2013).

##### 3.1.1. Pesquisa domiciliar

Importante ferramenta para a modelagem de transportes e, conseqüentemente, para o planejamento urbano, as pesquisas domiciliares buscam obter características dos domicílios, dos moradores e dos deslocamentos realizados por eles. Para obtenção da quantidade mínima de entrevistas necessárias para o município de Santa Maria, realizadas em 2013, considerou-se nível de confiança de 95% e erro amostral máximo de 10%. Ao final da pesquisa, chegou-se ao total de 3.758 registros (IPLAN, 2013). Ao corrigir eventuais inconsistências e falta de dados, a amostra foi reduzida a 3.136 observações.

##### 3.1.2. Tratamento dos dados

Devido às restrições computacionais relativas à calibração do modelo *Logit Multinomial*, agregou-se os 41 bairros em 20 “macro Bairros”, de modo que cada um deles representasse um destino possível. O objetivo desta agregação foi reduzir o número de alternativas. Essa agregação foi realizada a partir de uma análise de *Cluster k-médias*, na qual se considerou as coordenadas geográficas dos centroides dos bairros como critério para os agrupamentos. A Figura 2 ilustra a disposição dos 20 “macro Bairros” resultantes, bem como a localização do município de Santa Maria no estado do Rio Grande do Sul.



**Figura 2:** Divisão resultante do agrupamento dos bairros de Santa Maria (RS)

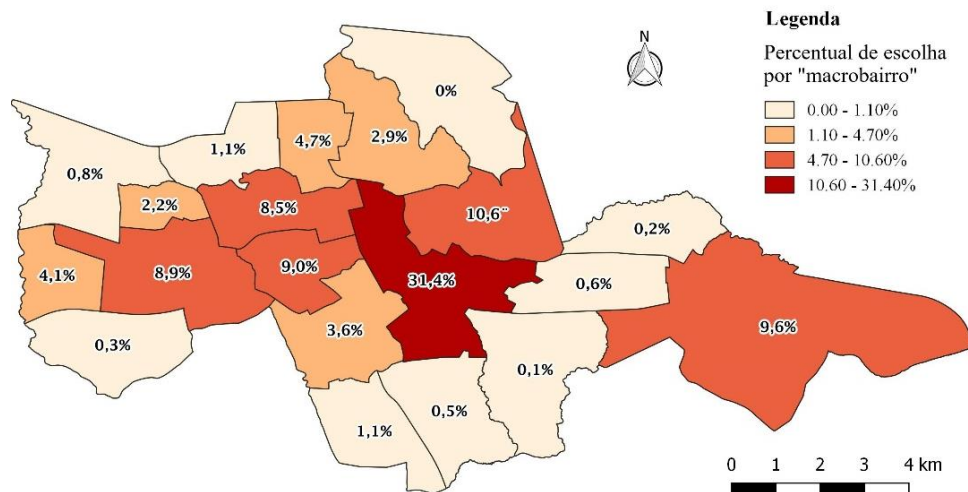
Além disso, incluiu-se ao banco de dados da pesquisa domiciliar informações acerca dos “macro Bairros” de origem e, para fins de validação, das distâncias de viagens, que correspondem às distâncias euclidianas entre os centroides dos “macro Bairros”. No caso de viagens dentro de um mesmo “macro Bairros”, para impedir erros sistemáticos por distâncias nulas, considerou-se o quarto da distância entre o centroide da unidade de área em questão e o centroide da área vizinha mais próxima (Thomas e Hugget, 1980).

A Tabela 1 caracteriza as variáveis explicativas utilizadas nos modelos de RNAs e *Logit Multinomial*. A Figura 3, por sua vez, caracteriza a variável dependente quanto ao percentual de escolha de cada “macro Bairros”, de acordo com a amostra final de 3.166 registros, obtida após tratamento dos dados.

**Tabela 1:** Variáveis usadas dos modelos

Variável	Descrição
Frequência Escolar	(0) Não; (1) Sim
Gênero	(1) Masculino; (2) Feminino
Grau de Instrução	(1) Analfabeto; (2) Alfabetização; (3) Fundamental I incompleto; (4) Fundamental I completo; (5) Fundamental II incompleto; (6) Fundamental II completo; (7) Ensino médio incompleto; (8) Ensino médio completo; (9) Superior incompleto; (10) Superior Completo
Habilitação motorizado	(0) Não possui; (1) Possui
Idade	(1) Até 17 anos; (2) 18 a 28 anos; (3) 29 a 39 anos; (4) 40 a 51 anos; (5) 52 a 65 anos; (6) Acima de 66 anos
Moradores	Quantidade de moradores na residência
Motivo Estudo	(0) Não; (1) Sim
Motivo Integração	(0) Não; (1) Sim
Motivo Lazer	(0) Não; (1) Sim
Motivo Residência	(0) Não; (1) Sim
Motivo Saúde	(0) Não; (1) Sim
Motivo Trabalho	(0) Não; (1) Sim

Renda	(1) Até 1 salário mínimo; (2) 1 a 2 salários mínimo; (3) 2 a 5 salários mínimos; (4) 5 a 10 salários mínimos; (5) Mais de 10 salários mínimos
Trabalha	(0) Não; (1) Sim
Veículos Motorizados	Quantidade de veículos motorizados na residência
Bolsa Família Origem	Quantidade de pessoas beneficiárias do Bolsa Família no “macrobairro” de origem
População Origem	Quantidade de residentes no “macrobairro” de origem



**Figura 3:** Caracterização da variável dependente quanto ao percentual de escolha por “macrobairro”

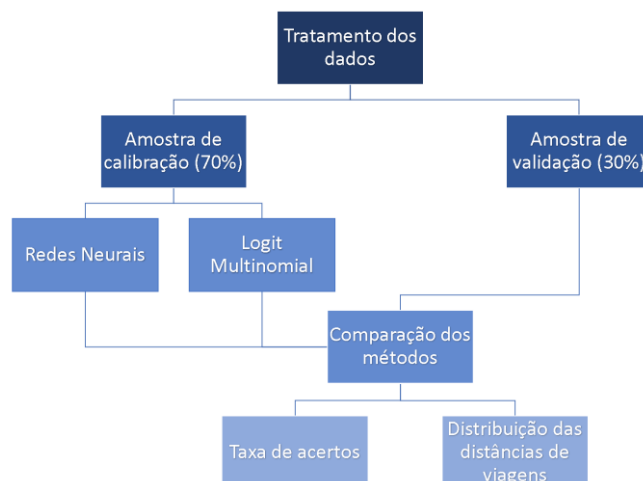
Observa-se na Figura 3 que o banco de dados não possui viagens que se destinem ao “macrobairro” 3 (ao norte do município), constituído pelo bairro ‘Campestre do Menino Deus’. Assim, as análises aqui realizadas não incluem esse destino em suas previsões.

### 3.2. Aplicativos utilizados

A análise realizada por meio de RNAs e a Análise de *Cluster*, para agrupamento dos bairros, foram obtidas por meio do aplicativo IBM SPSS 24.0. A calibração do modelo *Logit Multinomial*, por sua vez, foi realizada com a última versão do aplicativo aberto BIOGEME - PandasBiogeme (Bierlaire, 2018). Os centroides dos “macrobairros” e as distâncias entre eles foram obtidos com auxílio do *software* QGIS (versão 3.6.3). O *software* Microsoft Excel foi utilizado para o tratamento do banco de dados da Pesquisa Domiciliar e para as comparações entre as abordagens.

### 3.2. Método

O procedimento metodológico deste trabalho está apresentado na Figura 4. Para a análise desagregada da distribuição de viagens urbanas, realizou-se, primeiramente, o tratamento dos dados oriundos da pesquisa domiciliar. Em seguida, aplicou-se Redes Neurais Artificiais e modelo *Logit Multinomial* para estudo e previsão dos destinos a partir da amostra de calibração, que corresponde a 70% do total de observações. Em seguida, utilizou-se os modelos calibrados e a amostra de 30% restante para previsão dos destinos individuais. Finalmente, foram feitas comparações e análises de desempenho entre os dois métodos (Tradicional e RNAs). Para isso, avaliou-se a taxa de acertos e a distribuição das distâncias de viagens, calculados a partir da amostra de validação e teste (30%). O uso da distribuição de distâncias baseia-se na calibração do modelo de distribuição gravitacional com base no ajuste das curvas de distribuição de comprimentos de viagens modelada e observada (Ortuzar e Willumsen, 2011).



**Figura 4:** Método proposto para análise de desempenho de Redes Neurais Artificiais para distribuição de viagens urbanas para uma abordagem desagregada

## 4. RESULTADOS

### 4.1. Redes Neurais Artificiais

A seleção automática da arquitetura da RNA do *software* IBM SPSS 24.0 proporcionou a obtenção da rede mais eficiente entre os diferentes treinamentos. As Tabelas 2 e 3 a seguir expõem, para cada tipo de Rede Neural analisada (lote, online e minilote), a arquitetura e os erros e porcentagens de acertos das previsões, respectivamente.

**Tabela 2:** Arquitetura das RNAs analisadas

Treinamento	Lote	Online	Minilote
Camadas ocultas	1	1	1
Neurônios na camada oculta	15	16	13
Função de ativação da camada oculta	Tangente hiperbólica	Tangente hiperbólica	Tangente hiperbólica
Unidades na camada de saída	19	19	19
Função de ativação da camada de saída	Softmax	Softmax	Softmax
Função de erro	Entropia cruzada	Entropia cruzada	Entropia cruzada

**Tabela 3:** Comparação dos resultados das RNAs

Método de treinamento	Lote	Online	MiniLote
Previsões corretas no treinamento	51,37%	37,20%	33,29%
Regra de parada usada	Número máximo de períodos (1000) excedido	Alteração relativa no critério de erro de treinamento (,0001) obtido	10 etapa(s) consecutivas(s) sem nenhuma diminuição do erro
Tempo de treinamento	0:00:15,44	0:00:10,59	0:00:03,73
Previsões corretas na validação	32,66%	33,94%	31,70%

Ainda que o treinamento em lote seja utilizado para bancos de dados pequenos, devido ao maior tempo computacional necessário, conclui-se, com a Tabela 3, que ele demonstrou ser o mais eficiente para o estudo de caso, sendo seu tempo de treinamento de apenas 15 segundos. Esse método proporcionou a maior quantidade de acertos no treinamento, totalizando 51,37%. Isso mostra um maior poder de reprodução, de acordo com Cantarella (2005). Na validação, as três RNAs exibiram valores similares de previsão corretas, ou seja, as redes têm o mesmo poder de generalização. Com base nesses resultados, os dados da rede com treinamento do tipo lote foram escolhidos para serem analisados e comparados ao modelo *Logit* tradicional. Vale ressaltar que, o procedimento de treinamento e teste utilizado pela RNA viabiliza a projeção futura da variável de interesse. Assim, é possível a obtenção de valores futuros da variável dependente a partir de valores futuros das variáveis independentes e do modelo obtido pelo treinamento.



Como resultado, a Rede Neural também oferece o grau de importância normalizado das variáveis independentes. A importância de uma variável independente expressa o quanto ela influencia na seleção do valor predito. Sua medida é dividida pela da variável de maior importância e o resultado é expresso em porcentagem. Dessa forma, os atributos “grau de instrução”, “idade”, “renda” e “veículos motorizados” foram consideradas as variáveis mais importantes do modelo, enquanto “população origem”, “habilitação motorizado” e “gênero” foram as menos importantes.

#### 4.2. Logit Multinomial

A calibração do modelo *Logit Multinomial* seguiu a formulação descrita pela Equação (4), sendo as variáveis explicativas as expostas na Tabela 1. Foram realizadas diversas calibrações, de modo que, para cada uma delas, excluiu-se os parâmetros não significativos na calibração anterior, considerando um nível de significância de 95% (p-valor associado ao teste t menor do que 0,05). Assim, repetiu-se esse procedimento até que uma calibração contivesse todos os parâmetros significativos. A calibração final resultou nas funções utilidades apresentadas na Tabela 5, com  $\rho^2$  com valor 0,297 e  $\rho^2$  ajustado com valor 0,281.

**Tabela 4:** Funções utilidade para cada “macrobairro” de destino

---

$U_1 = 0$
$U_2 = -7,22 + 3,07 \cdot BolsaFamíliaOrigem + 10,1 \cdot MotivoEstudo + 6,69 \cdot MotivoLazer + 5,76 \cdot MotivoTrabalho$
$U_4 = -16 + 5,01 \cdot GraudeInstrução + 6,43 \cdot HabilidadeMotorizado - 3,02 \cdot MotivoEstudo - 9,95$ $\cdot MotivoResidência + 6,13 \cdot Trabalha$
$U_5 = -0,97 \cdot Idade - 1,73 \cdot Moradores + 3,65 \cdot MotivoEstudo - 2,75 \cdot MotivoIntegração - 5,17 \cdot MotivoSaúde$ $+ 2,46 \cdot PopulaçãoOrigem$
$U_6 = 0,852 \cdot HabilidadeMotorizado - 1,06 \cdot Moradores + 6,29 \cdot MotivoEstudo - 4,33 \cdot MotivoIntegração$ $- 1,36 \cdot MotivoResidência + 4,00 \cdot MotivoSaúde + 2,93 \cdot PopulaçãoOrigem$
$U_7 = 2,29 + 4,53 \cdot MotivoEstudo + 6,04 \cdot MotivoIntegração + 4,43 \cdot MotivoSaúde - 2,76 \cdot Renda$
$U_8 = 1,8 - 1,21 \cdot Moradores + 4,75 \cdot MotivoEstudo + 5,69 \cdot MotivoIntegração - 1,35 \cdot MotivoResidência$ $+ 3,61 \cdot MotivoSaúde + 1,74 \cdot PopulaçãoOrigem$
$U_9 = -1,76 \cdot Gênero - 4,11 \cdot MotivoEstudo + 5,64 \cdot MotivoSaúde$
$U_{10} = -2,39 \cdot FrequênciaEscolar - 2,89 \cdot GraudeInstrução - 2,42 \cdot Idade + 3,38 \cdot MotivoLazer + 2,92$ $\cdot MotivoResidência + 7,73 \cdot MotivoSaúde + 2,34 \cdot MotivoTrabalho + 2,14 \cdot PopulaçãoOrigem$ $- 1,87 \cdot Renda$
$U_{11} = 1,76 \cdot GraudeInstrução - 1,1 \cdot Moradores + 5,28 \cdot MotivoEstudo + 6,04 \cdot MotivoIntegração - 1,15$ $\cdot MotivoResidência + 3,43 \cdot MotivoSaúde + 2,05 \cdot PopulaçãoOrigem$
$U_{12} = 1,39 + 1,83 \cdot GraudeInstrução - 1,22 \cdot Moradores + 4,43 \cdot MotivoEstudo + 6,58 \cdot MotivoIntegração$ $- 2,07 \cdot MotivoResidência + 3,82 \cdot MotivoSaúde + 2,18 \cdot PopulaçãoOrigem$
$U_{13} = 1,52 \cdot GraudeInstrução + 5,25 \cdot MotivoEstudo - 4,65 \cdot MotivoIntegração - 1,47 \cdot MotivoResidência$ $+ 3,04 \cdot MotivoSaúde + 1,98 \cdot PopulaçãoOrigem$
$U_{14} = -2,59 \cdot Moradores + 6,26 \cdot MotivoEstudo - 3,11 \cdot MotivoSaúde - 7,06 \cdot MotivoTrabalho$
$U_{15} = -9,8 + 3,21 \cdot BolsaFamíliaOrigem + 8,72 \cdot FrequênciaEscolar - 9,65 \cdot MotivoResidência$
$U_{16} = 2,24 + 6,12 \cdot MotivoEstudo - 1,57 \cdot MotivoIntegração - 6,82 \cdot MotivoLazer - 4,61 \cdot MotivoSaúde - 3,06$ $\cdot PopulaçãoOrigem - 1,94 \cdot Renda$
$U_{17} = 3,09 - 2,38 \cdot BolsaFamíliaOrigem - 2,05 \cdot Moradores + 5,61 \cdot MotivoEstudo - 2,94 \cdot MotivoIntegração$ $+ 3,31 \cdot MotivoSaúde - 1,45 \cdot Renda$
$U_{18} = -1,45 \cdot Moradores + 5,69 \cdot MotivoEstudo - 3,81 \cdot MotivoIntegração + 4,25 \cdot MotivoSaúde + 3,78$ $\cdot PopulaçãoOrigem - 1,8 \cdot Renda$
$U_{19} = -6,98 \cdot FrequênciaEscolar - 9,13 \cdot MotivoResidência - 4,15 \cdot MotivoSaúde$
$U_{20} = 5,11 \cdot MotivoEstudo + 5,94 \cdot MotivoIntegração + 4,27 \cdot MotivoSaúde + 1,5 \cdot PopulaçãoOrigem - 0,84$ $\cdot Renda$

---

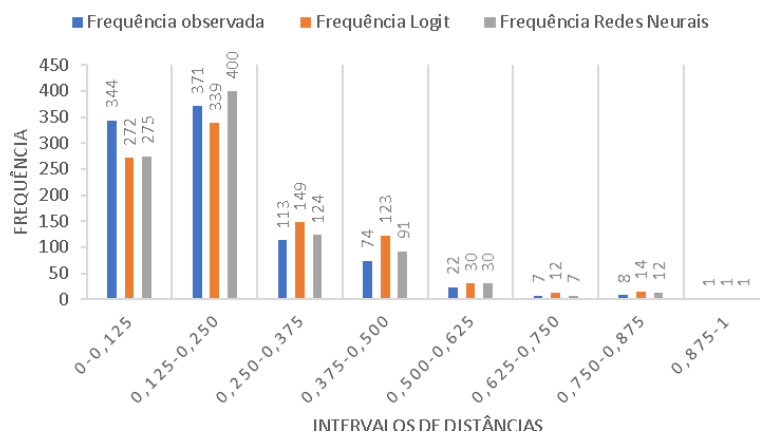
Ao analisar a Tabela 4, pode-se compreender os fatores que influenciam a escolha de cada destino pelos indivíduos. Na equação representativa do “macrobairro” 6, por exemplo, observa-se que o fato de a viagem ser por motivo estudo aumenta significativamente a utilidade dessa macrozona, e, conseqüentemente, a probabilidade de o indivíduo escolhê-la como destino. O contrário ocorre se a viagem for motivada por saúde ou integração. Esse resultado é facilmente

compreendido ao constatar no “macrobairro” 6, constituído pelo bairro Camobi, a presença da Universidade Federal de Santa Maria (UFSM), importante polo atrativo para estudantes no município. Por outro lado, não há nessa região polos significativos para integração ou saúde, o que justificaria o efeito negativo dessas motivações ao destino em questão.

### 4.3. Comparação entre as abordagens

#### 4.3.1. Distribuição das distâncias de viagem

A exemplo do realizado por Roma *et al.* (2018), analisou-se a distribuição das frequências das distâncias de viagens observadas e estimadas para a amostra de validação, de forma a identificar o método que minimiza a diferença entre elas. Para isso, normalizou-se os valores de distância, que foram distribuídos em 8 categorias, como ilustrado na Figura 5.



**Figura 5:** Histograma das distâncias de viagem observadas e estimadas

O histograma resultante indica que o modelo executado por Redes Neurais Artificiais apresentou desempenho igual ou melhor ao obtido por *Logit Multinomial* para todos os intervalos de distâncias. Além da análise do histograma, realizaram-se os testes estatísticos não paramétricos *Mann-Whitney*, *Kolmogorov-Smirnov* e da Mediana para avaliar similaridades de distribuições populacionais e medianas entre as distâncias observadas e estimadas por ambas as abordagens. Considerando a hipótese nula como a igualdade das frequências observadas e estimadas, o teste de *Mann-Whitney* reteve para ambos os modelos, enquanto o teste *Kolmogorov-Smirnov* refutou a hipótese nula para ambas as abordagens. O teste da Mediana, por sua vez, reteve a hipótese nula de similaridade de medianas das distâncias observadas e estimadas para o modelo de Redes Neurais Artificiais. A hipótese nula, no entanto, foi refutada para o modelo *Logit Multinomial*.

#### 4.3.2. Taxa de acertos

Aplicando os modelos calibrados para ambas as abordagens para a amostra de validação e teste, comparou-se as escolhas de destinos estimadas com as observadas, obtendo-se, então, taxa de acertos de 33,7% para o modelo *Logit Multinomial* e de 32,66% para RNAs. Embora as taxas sejam muito próximas, ao analisá-las para cada “macrobairro” de destino, observa-se grande diferença entre seus valores, como mostra a Tabela 5.

Percebe-se, também, ao analisar a Tabela 5, que a taxa de acertos de RNAs foi superior para todos os destinos, com exceção dos “macrobairros” 12 e 17, os quais representam 35,5% de todas as observações (vide Figura 3). Esse resultado indica que o modelo de RNAs não necessita de tantas observações para cada alternativa quanto o modelo *Logit Multinomial*.

**Tabela 5:** Taxas de acertos para cada alternativa (“macrobairro”)

	Destino																			
	1	2	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	
Logit																				
MN	0%	0%	0%	0%	15%	18%	2%	0%	0%	0%	89%	0%	0%	0%	0%	15%	27%	0%	0%	
RNA	9%	20%	33%	15%	36%	20%	17%	0%	15%	11%	65%	3%	0%	0%	30%	8%	27%	0%	19%	

## 5. CONCLUSÕES

A abordagem desagregada aqui descrita proporcionou uma análise de desempenho de Redes Neurais Artificiais para estimativas de distribuição de viagens urbanas frente à calibração do tradicional modelo desagregado *Logit Multinomial*.

Diante dos resultados obtidos para as duas abordagens, conclui-se que a aplicação de RNAs para a etapa de distribuição de viagens urbanas, com dados de Preferência Revelada, é tão eficiente quanto a do modelo *Logit Multinomial* no que diz respeito à taxa de acertos, mas sem exibir, no entanto, suas restrições, como os problemas de multicolinearidade, as propriedades de IIA, o fato de assumir estrutura específica e de possuir limitações computacionais em casos de muitas alternativas e parâmetros a serem estimados.

Além disso, os histogramas de distâncias indicam que a ferramenta Redes Neurais Artificiais tem melhor atuação quanto às diferenças entre distâncias de viagens observadas e estimadas. Quanto à quantidade de observações para cada alternativa, por sua vez, a técnica de Redes Neurais Artificiais indica menor necessidade de maiores observações para cada alternativa em comparação ao modelo *Logit Multinomial*, uma vez que teve maior poder preditivo para os destinos com menores quantidades de observações.

Vale ressaltar, no entanto, que as análises supracitadas possuem teor puramente quantitativo, uma vez que não é possível obter relações entre as variáveis pelo método de RNAs, por se tratar de uma técnica não paramétrica.

### Agradecimentos

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq Processos 303645/2015-6 e 130796/2018-2) e da Coordenação de Aperfeiçoamento do Pessoal de Ensino Superior (CAPES). Os autores também agradecem ao Instituto de Planejamento de Santa Maria/RS (IPLAN) pela cessão dos dados da pesquisa domiciliar.

### REFERÊNCIAS BIBLIOGRÁFICAS

- Ben-Akiva, M. e Lerman, S. R. (1985) *Discrete Choice Analysis: Theory and Application to Travel Demand*, Cambridge, MA: MIT Press.
- Bierlaire, M. (2018) *PandasBiogeme: a short introduction*. Technical report TRANSP-OR 181219. Transport and Mobility Laboratory, ENAC, EPFL.
- Black, W. R. (1995) Spatial interaction modeling using artificial neural networks. *Journal of Transport Geography*, v. 3(3), p. 159–166.
- Cantarella, G. E. e De Luca, S. (2005) Multilayer feed forward networks for transportation mode choice analysis: An analysis and a comparison with random utility models. *Transportation Research Part C: Emerging Technologies*, v. 13, p. 121-155.
- Cascetta, E.; Pagliara, F. e Papola, A. (2007) Alternative approaches to trip distribution modelling: A retrospective review and suggestions for combining different approaches, *Papers in Regional Science*, v. 86(4), p. 597-620. DOI: 10.1111/j.1435-5957.2007.00135.x.
- Casey, H. J. (1955) Applications to traffic engineering of the law of retail gravitation. *Traffic Quarterly IX*, p. 23-35.
- Chow, L.; Zhao, F.; Li, M. e Li, S. (2005) Development and evaluation of aggregate destination choice models for trip distribution in Florida, *Transportation Research Record*, 1931(1), p. 18-27. DOI: 10.3141/1931-03.

- De Carvalho, M. C. M.; Dougherty, M. S.; Fowkes, A. S. e Wardman, M. R. (1998) Forecasting travel demand: A comparison of logit and artificial neural network methods, *Journal of the Operational Research Society*. DOI: 10.1057/2600590.
- Domecich, T. A. e McFadden, D. (1975) *Urban travel demand: A behavioral analysis*, North Holland Publishing Co., NY, USA.
- Evans, A. W. (1970) Some Properties of Trip Distribution Methods. *Transportation Research*, v.4, n.1, p. 19–36. doi: 10.1016/0041-1647(70)90072-9.
- Evans, S. P. e Kirby, H. R. (1974) A three-dimensional furness procedure for calibrating gravity models. *Transportation Research*, v.8, n.2, p. 105–122. DOI: 10.1016/0041-1647(74)90037-9.
- Faghri, A. e Hua, J. (1992) Evaluation of Artificial Neural Network Applications in Transportation Engineering, *Transportation Research Record*, 1358, p. 71-80.
- Fotheringham, A. S. (1983) Some theoretical aspects of destination choice and their relevance to production-constrained gravity models. *Environment and Planning A*, v.15, n.8, p. 1121–1132. DOI: 10.1068/a151121
- Haykin, S. (2001) *Redes neurais: princípios e práticas*, 2a edição.
- Huisken, G. e Coffa, A. (2000) Neural networks and fuzzy logic to improve trip generation modelling, in *Proceedings of the 9th International Association for Travel Behaviour Research Conference*, IATBR 2000, Gold Coast, Queensland, Australia.
- IBGE - Instituto Brasileiro de Geografia e Estatística (2010) *Censo Demográfico 2010*.
- IBM Corp. Released 2016. *IBM SPSS Statistics for Windows*, Version 24.0. Armonk, NY: IBM Corp.
- IPLAN (2013) *Plano Diretor de Mobilidade Urbana de Santa Maria (1ª Edição)*. Santa Maria: Prefeitura Municipal de Santa Maria.
- Lowry IS (1964) *A model of metropolis*. RM-4125-RC, Rand Corporation, Santa Monica. California.
- Luce, R. D. e Suppes, P. (1965) Preference, utility, and subjective probability. In R. D. Luce, R. R. Bush, & E. Galanter (Eds.), *Handbook of mathematical psychology*, v. 111. New York: Wiley. p. 249-410.
- Mikkonen, K. e Luoma, M., (1999). The parameters of the gravity model are changing - how and why? *Journal of Transportation Geography*, v.7 (4), p. 277–283. DOI: 10.1016/S0966-6923(99)00024-1.
- Mishra, S.; Yanli, W.; Xiaoyu, Z.; Rolf, M e Subrat, M. (2013) Comparison between Gravity and Destination Choice Models for Trip Distribution in Maryland, *Transportation Research Board*, (January), p. 1–22.
- Mozolin, M.; J.-C. Thill e E. L. Usery (2000) Trip distribution forecasting with multilayer perceptron neural networks: A critical evaluation. *Transportation Research Part B: Methodological*, v. 34(1), p. 53–73.
- Ortúzar, J. D. e Willumsen, L. G. (2011) *Modelling Transport*. Wiley, London.
- Pitombo, C. S.; de Souza, A. D. e Lindner, A. (2017) Comparing decision tree algorithms to estimate intercity trip distribution, *Transportation Research Part C: Emerging Technologies*. DOI: 10.1016/j.trc.2017.01.009.
- Rasouli, M. e Nikraz, H. (2013) Trip Distribution Modelling Using Neural Network. *Transport Research Forum*, Brisbane, Australia.
- Roma, A. D. de S.; Pitombo, C. S.; Guimarães, H. S. e Costa, L. H. M. (2018) Análise de desempenho de algoritmos de aprendizagem de máquinas para análise desagregada de viagens intermunicipais, *Transportes*, v. 26, p. 159-175. DOI: 10.14295/transportes.v26i3.1614.
- Shmueli, D.; Salomon, I. e Shefer, D. (1996) Neural network analysis of travel behavior: Evaluating tools for prediction, *Transportation Research Part C: Emerging Technologies*, v. 4(3 PART C), p. 151–166. DOI: 10.1016/S0968-090X(96)00007-1.
- Smith, M. (1996) *Neural Networks for Statistical Modeling*. International Thomson Computer Press, Londres, Inglaterra.
- Stouffer, S. A. (1940) Intervening Opportunities: A Theory Relating Mobility and Distance, *American Sociological Review*, v.5, p. 845-867. DOI: 10.1016/S1003-6326(10)60620-6.
- Subba Rao, P. V.; Sikdar, P. K.; Krishna Rao, K. V. e Dhingra, S. L. (1998) Another insight into artificial neural networks through behavioural analysis of access mode choice. *Computers, Environment and Urban Systems*, v. 22, p. 485-496.
- Thomas, R. W. e Hugget, R. J. (1980) *Modeling in Geography: A Mathematical Approach*. Barnes and Noble, Totowa.
- Tillema, F.; Van Zuilekom, K. M. e Van Maarseveen, M. F. (2006) Comparison of neural networks and gravity models in trip distribution. *Computer-Aided Civil and Infrastructure Engineering*, v. 21(2), p. 104–119.
- Williams, I. (1976) A comparison of some calibration techniques for doubly constrained models with an exponential cost function, *Transportation Research*, v. 10(2), p. 91-104. DOI: 10.1016/0041-1647(76)90045-9.
- Wilson, A. G. (1967) A statistical theory of spatial distribution models, *Transportation Research*, v.1(3), p. 253–269. DOI: 10.1016/0041-1647(67)90035-4.