



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CIVIL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

LIGIA RABAY MANGUEIRA ARAÚJO

**DEMANDA POR TRANSPORTE PÚBLICO EM METRÓPOLES BRASILEIRAS A
PARTIR DE MODELOS DE REGRESSÃO EM PAINÉIS ESTÁTICOS E
DINÂMICOS**

Recife

2019

LIGIA RABAY MANGUEIRA ARAÚJO

**DEMANDA POR TRANSPORTE PÚBLICO EM METRÓPOLES BRASILEIRAS A
PARTIR DE MODELOS DE REGRESSÃO EM PAINÉIS ESTÁTICOS E
DINÂMICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco (UFPE), como requisito parcial para a obtenção do título de Mestre em Engenharia Civil.

Área de concentração: Transporte e gestão das infraestruturas urbanas.

Orientador: Prof. Dr. Maurício Oliveira de Andrade.

Coorientador: Prof. Dr. Aléssio Tony Cavalcanti de Almeida.

Recife

2019

Catálogo na fonte
Bibliotecária Valdicéa Alves, CRB-4 / 1260

A663d Araújo, Ligia Rabay Mangueira.
Demanda por transporte público em metrópoles brasileiras a partir de modelos de regressão em painéis estáticos e dinâmicos. / Ligia Rabay Mangueira Araújo - 2019.
127folhas, Il.; Tab.; Abr. e Sigl.

Orientador: Prof. Dr. Maurício Oliveira de Andrade.
Coorientador: Prof. Dr. Aléssio Tony Cavalcanti de Almeida.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG.
Programa de Pós-Graduação em Engenharia Civil, 2019.
Inclui Referências e Apêndices.

1. Engenharia Civil. 2. Transporte público. 3. Elasticidades.
4. Econometria. 5. Tarifa. 6. Qualidade do serviço. I. Andrade, Maurício Oliveira de (Orientador). II. Almeida, Aléssio Tony Cavalcanti de (Coorientador). III. Título.

UFPE

624 CDD (22. ed.)

BCTG/2019-025

LIGIA RABAY MANGUEIRA ARAÚJO

**DEMANDA POR TRANSPORTE PÚBLICO EM METRÓPOLES BRASILEIRAS A
PARTIR DE MODELOS DE REGRESSÃO EM PAINÉIS ESTÁTICOS E
DINÂMICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco (UFPE), como requisito parcial para a obtenção do título de Mestre em Engenharia Civil.

Aprovada em 23 de janeiro de 2019.

Prof. Dr. Aléssio Tony Cavalcanti de Almeida – UFPB – Coorientador _____

BANCA EXAMINADORA

Prof. Dr. Maurício de Oliveira Andrade (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. Ignácio Tavares de Araújo Júnior (Examinador Externo)
Universidade Federal da Paraíba

Prof. Dr. Enilson Medeiros dos Santos (Examinador Interno)
Universidade Federal do Rio Grande do Norte

À minha querida mãe Leila, pelo amor e dedicação em toda minha vida e ao meu esposo Carlos Antonio, por me dar o apoio e impulso de seguir em frente.

AGRADECIMENTOS

A Deus, pela minha vida, saúde e por ser a minha fonte inesgotável de força.

Ao meu Orientador Professor Maurício Oliveira de Andrade pela dedicação na elaboração deste trabalho, pelo incentivo em buscar sair da minha zona de conforto e pela paciência e disponibilidade todas as vezes que eu precisei.

Ao meu Coorientador Professor Aléssio Tony C. Almeida, pela generosidade em me auxiliar no desenvolvimento do estudo econométrico, por conduzir o aprimoramento do meu conhecimento na área de economia e na utilização do *software* e pela disponibilidade e apoio fundamental para conclusão desta pesquisa.

A minha família, por entenderem as minhas ausências e me incentivarem sempre a buscar meu crescimento profissional. Primordialmente, à minha mãe Leila, por ser a luz da minha vida; ao meu esposo Carlos Antonio, pelo seu amor e por me ensinar todos os dias a ser uma pessoa melhor; ao meu pai Omar, por todo apoio e encorajamento; e aos meus irmãos e sobrinhos, por compartilharem desta vida comigo. Também, em especial, aos meus tios Yara e Zé por me acolherem em Recife e não pouparem esforços para me fazer sentir em casa.

Aos professores da área de Transportes e Gestão das Infraestruturas do Programa de Pós-Graduação em Engenharia Civil da UFPE, Leonardo Meira, Enilson Santos, Maria Leonor (Nona) Maia, Oswaldo Lima Neto e Anísio Brasileiro, por todo conhecimento transmitido em sala de aula e ensinamentos para a vida.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo incentivo financeiro por meio da bolsa de estudos concedida no período do mestrado.

Às secretárias do Programa de Pós Graduação em Engenharia Civil, em especial, à Andrea, Cleide e Claudiana pela disponibilidade e auxílio nos tramites administrativos.

À Associação Nacional de Empresas de Transportes Urbanos (NTU), na pessoa do atual diretor técnico André Dantas, por ceder os dados operacionais dos sistemas de transportes públicos das nove metrópoles brasileiras para a utilização neste estudo. Também a Paulo Chaves Júnior, membro do Conselho Diretor da NTU, por confiar na minha pesquisa e auxiliar na disponibilização dos dados.

A Isabel Magalhães, amiga que ganhei com o mestrado, por dividir comigo as alegrias e angústias destes dois anos, pelo carinho e presença em todos os momentos da vida pessoal e profissional mesmo morando em cidade diferente, por me ensinar que pessoas muito diferentes podem ser amigas e por decidir conversar comigo nas primeiras aulas.

Ao amigo Luis Henrique Costa pela companhia nas viagens João Pessoa – Recife e companheirismo ao longo do mestrado.

A minha amiga Jéssica Oliveira, por ser minha irmã de alma, sempre me apoiar nas decisões da vida e compartilhar comigo todos os momentos do caminho acadêmico, mesmo estudando um assunto tão diferente. Aos meus lindos amigos Camila Cunha, Raquel Alves, Mayara Maia, Diego Duarte e Gabrielle Lessa, por estarem sempre presentes na minha vida e dividirem comigo muitas risadas, reflexões, jogos e jantares.

Aos meus amigos Alice Moreira, Ana Beatriz Herthel, Roberta Carvalho, Sérgio Pereira, Amanda Farias, Nathália Maia e Germano Gondim por serem minha companhia todos os dias mesmo que virtualmente. Bem como a Rafael Vieira, Deborah Moura, Rodrigo Massao, Yonatha Melo, Pedro Paiva, Larissa e Diego Augusto por sempre estarem presentes e dividirem comigo muitas noites de jogos e risadas.

RESUMO

O sistema de transporte público, parte essencial do funcionamento das cidades, atua como elemento determinante da qualidade de vida da população. A demanda por esse serviço apresenta a flutuação como uma característica significativa, exigindo das autoridades de transportes análises frequentes do seu comportamento para subsidiar ações públicas. Nesse contexto, esta pesquisa objetiva analisar os principais fatores que influenciam a demanda por transporte público no Brasil, tendo em vista identificar as causas da retração da demanda e os meios possíveis de superá-la. Para isso, nove metrópoles brasileiras foram analisadas no período de 2007 a 2017 por meio de dados secundários disponibilizados pela Associação Nacional de Empresas de Transportes Urbanos (NTU), pelo Instituto Brasileiro de Geografia e Estatística (IBGE), pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) e pelo Departamento Nacional de Trânsito (DENATRAN). Por intermédio do método dos mínimos quadrados ordinários e do método generalizado dos momentos, foram estimadas as elasticidades da demanda em relação à tarifa, à qualidade do serviço, à renda da população, à quantidade de veículos particulares, ao preço da gasolina, à idade da frota de ônibus urbanos e à existência do serviço de Uber. Para isso, foram utilizadas abordagens estáticas e dinâmicas da modelagem econométrica de dados em painel com efeito fixo. Após os testes de hipóteses e ajustes do modelo final, os fatores que apresentaram elasticidades significativas estatisticamente no curto e longo prazo foram tarifa, qualidade do serviço, através da quilometragem percorrida pela área, e idade da frota de ônibus urbanos. No curto prazo, as elasticidades principais da tarifa, qualidade do serviço e idade da frota foram de -0,44, 0,75 e -0,09, respectivamente, e no longo prazo as intensidades aumentaram ligeiramente com valores de -0,56, 0,95 e -0,11. Os resultados encontrados são condizentes em intensidade e sinal com a literatura estudada e indicam que melhorias na qualidade do atendimento do serviço e a aquisição de ônibus novos atrairiam mais passageiros do que a redução no preço das tarifas de ônibus urbanos no cenário brasileiro, embora um programa de subsídio tarifário demonstre sua utilidade em reverter perdas de demanda.

Palavras-Chave: Transporte público. Elasticidades. Econometria. Tarifa. Qualidade do serviço.

ABSTRACT

The public transport system, an essential part of the city operation, acts as a determinant element of population's quality of life. The demand for this service presents fluctuation as a significant feature, requiring transport authorities to conduct frequent analyses of demand's behavior in order to guide public actions. In this context, this research aims to analyze the main factors that influence the demand for public transport in Brazil, in order to identify the causes of the demand retraction and the possible means to overcoming it. Therefore, nine Brazilian metropolises were analyzed from 2007 to 2017 through secondary data provided by the Associação Nacional de Empresas de Transportes Urbanos (NTU, Association of Urban Transport Companies), the Instituto Brasileiro de Geografia e Estatística (IBGE, Brazilian Institute of Geography and Statistics), the Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP, National Petroleum, Natural Gas and Biofuel Agency) and the Departamento Nacional de Trânsito (DENATRAN, National Department of Traffic). Using the ordinary least squares method and the generalized method of moments, the demand elasticities were estimated in relation to some factors such as fare, service quality, population income, number of private vehicles, price of gasoline, age of urban bus fleet, and existence of the Uber service. For this purpose, it was used static and dynamic approaches to the econometric modelling of panel data with fixed effect. After the hypotheses tests and final model adjustments, the factors that statistically presented significant elasticities in the short and long-term were the fare, quality of service (by means of the kilometers traveled by the area), and age of the urban bus fleet. In the short-term, the main elasticities of fare, quality of service and age of the fleet were -0.44, 0.75 and -0.09, respectively, and in the long-term the intensities increased lightly with values of -0.56, 0.95 and -0.11. The results found are consistent with the literature and indicate that improvements in the quality of service and the purchase of new buses would attract more passengers than the reduction in the price of urban bus fares in the Brazilian scenario, although a fare subsidy program demonstrates its utility in reversing demand drops.

Keywords: Public transportation. Elasticities. Econometrics. Fare. Service quality.

LISTA DE ILUSTRAÇÕES

Gráfico 1 –	Quantidade de passageiros equivalentes ² transportados por ano nas nove metrópoles.....	42
Gráfico 2 –	Quantidade de passageiros equivalentes transportados por ano nas nove metrópoles (continuação).....	43
Figura 1 –	Fluxograma da Metodologia de Pesquisa	53
Gráfico 3 –	Evolução da tarifa principal	73
Gráfico 4 –	Evolução da tarifa principal corrigida pelo IPC-A (IBGE, 2018).....	73
Gráfico 5 –	Evolução da renda média dos trabalhadores corrigida pelo IPC-A (IBGE, 2018).	74
Gráfico 6 –	Evolução da quilometragem percorrida pelos ônibus urbanos.....	75
Gráfico 7 –	Evolução da quilometragem percorrida/área.....	75
Gráfico 8 –	Evolução da idade média da frota de ônibus urbano.....	76
Gráfico 9 –	Evolução da frota de motocicleta	76
Gráfico 10 –	Evolução da frota de automóveis	77
Gráfico 11 –	Evolução do preço da gasolina corrigida pelo IPC-A (IBGE, 2018).....	77

LISTA DE TABELAS

Tabela 1 – Elasticidade-preço da demanda	30
Tabela 2 – Elasticidades relativas à Qualidade do Serviço	33
Tabela 3 – Elasticidade-renda da demanda.....	36
Tabela 4 – Elasticidade de outros fatores relevantes.....	39
Tabela 5 – População das nove metrópoles brasileiras no ano de 2017.....	41
Tabela 6 – Publicações relevantes no tema	54
Tabela 7 – Estatística descritiva da amostra.....	72
Tabela 8 – Resultados da regressão linear inicial em painel estático.....	78
Tabela 9 – Resultado dos modelos de regressão mais relevantes testados.....	80
Tabela 10 – Resultado dos modelos de regressão mais relevantes testados (continuação)....	81
Tabela 11 – Resultado da regressão mais apropriada sem São Paulo	82
Tabela 12 – Modelos de regressão com correção robusta de White	84
Tabela 13 – Resumo das elasticidades obtidas através do painel estático.....	84
Tabela 14 – Resultado da regressão pelo MGM.....	86
Tabela 15 – Resultados dos modelos dinâmicos mais relevantes	87
Tabela 16 – Resultados dos modelos dinâmicos mais relevantes (continuação)	88
Tabela 17 – Resumo das elasticidades obtidas através do MGM com painel dinâmico	89

LISTA DE ABREVIATURAS E SIGLAS

ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
DENATRAN	Departamento Nacional de Trânsito
FRA	Função Regressão Amostral
FRP	Função Regressão Populacional
IBGE	Instituto Brasileiro de Geografia e Estatística
IPCA	Índice Nacional de Preços ao Consumidor Amplo
MGM	Método Generalizado dos Momentos
MQO	Mínimos Quadrados Ordinários
NTU	Associação Nacional das Empresas de Transportes Urbanos
TP	Transporte Público

SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	APRESENTAÇÃO DO TEMA.....	15
1.2	OBJETIVOS	17
1.2.1	Geral	17
1.2.2	Específicos.....	17
1.3	ABORDAGEM METODOLÓGICA	18
1.4	ESTRUTURAÇÃO DO TRABALHO	19
2	FUNDAMENTAÇÃO TEÓRICA.....	21
2.1	O CONCEITO CLÁSSICO DE DEMANDA	21
2.2	DEMANDA POR TRANSPORTE PÚBLICO	22
2.2.1	Conceituação de demanda por transporte público	23
2.2.2	Fatores relevantes na demanda por transporte público.....	24
2.2.3	Medida de dimensionamento da demanda - Elasticidades	26
2.3	ANÁLISE DOS PARÂMETROS	27
2.3.1	Tarifa.....	28
2.3.2	Qualidade do transporte público.....	31
2.3.3	Renda e fatores econômicos	35
2.3.4	Outros parâmetros relevantes	37
3	CARACTERIZAÇÃO DAS METRÓPOLES BRASILEIRAS EM ESTUDO	40
3.1	CARACTERÍSTICAS DAS METRÓPOLES.....	40
3.2	SISTEMAS DE TRANSPORTE PÚBLICO DAS METRÓPOLES.....	44
3.2.1	Belo Horizonte.....	44
3.2.2	Curitiba	44
3.2.3	Fortaleza	45
3.2.4	Goiânia.....	46
3.2.5	Porto Alegre.....	46
3.2.6	Recife.....	47
3.2.7	Rio de Janeiro	47
3.2.8	Salvador	48
3.2.9	São Paulo	49
4	METODOLOGIA DA PESQUISA	51
4.1	SÍNTESE DOS ESTUDOS E LINHA DE CONDUÇÃO	54

4.2	CARACTERIZAÇÃO DAS VARIÁVEIS	55
4.3	OBTENÇÃO E ANÁLISE DO BANCO DE DADOS	56
4.3.1	Análise de dados em painel	57
4.4	DEFINIÇÃO DO MODELO	59
4.5	APLICAÇÃO DO MODELO DE PREVISÃO.....	64
4.6	TESTES DE HIPÓTESES DO MODELO.....	66
5	RESULTADOS E DISCUSSÕES.....	71
5.1	CARACTERÍSTICA DOS DADOS SECUNDÁRIOS	71
5.2	RESULTADOS DO PAINEL ESTÁTICO	78
5.3	RESULTADOS DO PAINEL DINÂMICO.....	85
6	CONSIDERAÇÕES FINAIS.....	91
	REFERÊNCIAS.....	93
	APÊNDICE A – BASE DE DADOS SECUNDÁRIOS	101
	APÊNDICE B – RESULTADOS DA REGRESSÃO DO PAINEL ESTÁTICO.....	108
	APÊNDICE C – TESTES PARA ESCOLHA DO MODELO.....	118
	APÊNDICE D – TESTES DE HIPÓTESES DO PAINEL ESTÁTICO	119
	APÊNDICE E – CORREÇÃO ROBUSTA DE WHITE.....	121
	APÊNDICE F – RESULTADOS DA REGRESSÃO DO PAINEL DINÂMICO.....	122

1 INTRODUÇÃO

O transporte se apresenta como um elemento importante no desenvolvimento das cidades, principalmente por estreitar as distâncias através dos diferentes modos e do avanço tecnológico deles. Temas como a mobilidade, o papel dos transportes e sua influência na urbanização e no estilo de vida das cidades são pautas frequentes de discussões, tanto entre acadêmicos, gestores e operadores, como entre a população em geral, devido ao fato de representarem preocupações presentes na vida de todos indistintamente.

Um desses temas que gera grandes discussões é o transporte público urbano (TP), em razão da sua relevância na estruturação das cidades. Com um sistema de transporte público eficiente, é possível, por exemplo, melhorar a condição de vida das pessoas, reduzir os congestionamentos nas ruas gerados pelos carros particulares, diminuir a poluição e promover a acessibilidade urbana.

Em contrapartida, quando a qualidade deste sistema é baixa, há problemas relacionados à falta de atendimento de uma parcela da população, à insatisfação dos usuários pelo serviço prestado, à superlotação em muitos casos, à busca por alternativas privadas e ao consequente aumento dos congestionamentos. Este segundo panorama é a realidade de grande parte das cidades brasileiras. Assim sendo, estas circunstâncias atuais são resultados de diversos impasses que decorrem, na maioria das vezes, do crescimento rápido dos aglomerados urbanos com um planejamento deficitário, da priorização e aumento sem controle do número de automóveis nas ruas e da falta de incentivo ao transporte público.

Neste âmbito, os transportes públicos brasileiros se encontram em um ciclo vicioso, no qual a falta de qualidade do transporte atrelada ao aumento do preço da tarifa leva a população a procurar novas alternativas, diminuindo assim a quantidade demandada e consequentemente, gerando mais aumento de tarifas para o restante dos usuários, a fim de tentar reequilibrar os custos e as receitas do sistema (CARVALHO E PEREIRA, 2011). Isso ocorre porque o cálculo da tarifa nas cidades brasileiras é estimado por meio do custo médio para cada passageiro pagante com base na planilha da Empresa Brasileira de Planejamento em Transportes, conhecida como GEIPOT. Segundo o Manual de Instruções do Cálculo das Tarifas de Ônibus Urbanos (BRASIL, 1996), a tarifa é calculado pelo divisão do custo total do serviço, incluindo custos fixos, variáveis e tributos, pela quantidade de passageiros pagantes. Essa condição, ligada à cultura da população brasileira, de que o transporte público

é um bem destinado às classes sociais mais baixas pode estar resultando em uma queda contínua da demanda por transporte público nos últimos anos.

Além disso, a preocupação de operadores, gestores e acadêmicos é que mesmo com o cenário de crise econômica atual do Brasil, a quantidade demandada de transporte público continua caindo. Segundo a NTU (2018a), houve uma perda de 35,6% dos passageiros pagantes em pouco mais de 20 anos até 2017, tendo um agravamento desta redução maior nos últimos cinco anos. Nestas circunstâncias, seria razoável esperar o retorno de partes dos usuários que migraram para o automóvel ou motocicleta, em consequência do aumento da sua renda no período dinâmico da economia. Porém, este fator não gerou aumento na demanda por transporte público no cenário atual. Esta e várias outras questões como a evasão, a insatisfação, o vandalismo, a insegurança e a falta investimentos do governo podem estar resultando na queda da quantidade demandada por transporte público no Brasil.

Por essa razão, a necessidade de entender as causas e os motivos da situação atual brasileira e de localizar as soluções viáveis para reverter a situação revelam-se importantes. Este tema já foi e ainda é abordado em muitos países em desenvolvimento e também com cenários de crise econômica semelhantes. No entanto, no Brasil, os estudos voltados para a investigação da demanda por transporte público através de análises econômicas ainda são escassos.

Uma maneira de compreender o que está ocorrendo com a demanda por transporte público no país é o estudo dos fatores que a influenciam. Esses fatores podem indicar a justificativa da escolha ou não desse modo de transporte pelos usuários, a partir de aspectos econômicos, políticos, sociais e culturais. Em função disso, as características de cada localidade, como situação política e econômica, densidade urbana e cultura da sociedade podem influenciar nos pesos de cada fator e gerar resultados diferentes de outras referências estudadas em várias partes do mundo.

1.1 APRESENTAÇÃO DO TEMA

Uma característica notável de qualquer demanda é ser flutuante, podendo existir fatores que afetam significativamente esta flutuação. O dilema no caso dos transportes começa quando esta demanda entra em uma fase de decrescimento tendencial. Segundo Balcombe *et al.* (2004), o primeiro estudo sobre demanda por transporte público, publicado em 1981 por Webster e Bly, foi escrito em um momento no qual a demanda na Inglaterra caía

aceleradamente e as estratégias de aumento de tarifas, redução de níveis de serviço e de cobertura de rede feitas pelos operadores não estavam produzindo a recuperação dos passageiros perdidos.

Os sistemas de transportes públicos sofrem com a não regularidade da demanda pela dificuldade de prever seu comportamento. Em casos de grande evasão, como no primeiro relatório publicado por Webster e Bly (1981) e no cenário atual brasileiro, se torna complexo reverter a situação na hipótese de não ser realizada uma análise do conjunto de fatores influenciadores para a busca das soluções viáveis. Nessas circunstâncias, faz-se necessário estimar a relação entre a demanda e os fatores que a influenciam, qual o nível de intensidade dessa relação e o sentido em que os parâmetros afetam a demanda, se positiva ou negativamente.

A análise do cenário é feita a partir das variáveis significativas encontradas para conceber onde devem ser feitas as mudanças a fim de reverter o quadro. Esta é uma forma de buscar reduzir ou controlar a flutuação da demanda, visto que ela nem sempre será estável ou fácil de prever. Logo, faz-se necessário o contínuo avanço de políticas públicas focadas no incentivo à qualidade do transporte público, a fim de almejar uma maior estabilidade da demanda, prevenindo-se dessa forma grandes flutuações.

Países em desenvolvimento buscam hoje soluções otimizadas para seus sistemas de transportes urbanos devido à crescente necessidade de mobilidade e acessibilidade da população. Para isso, as estimativas de demanda e seus determinantes têm papel importante no planejamento de novas infraestruturas e serviços e na decisão de investimentos no transporte público urbano. No entanto, a maior parte dos estudos existentes sobre demanda por viagens têm sido realizados em cenários de países desenvolvidos, onde os sistemas de transportes públicos estão bem mais consolidados (CROTTE *et al.*, 2011; RAHMAN; BALIJEPALLI, 2016).

Apesar de este contexto estar mudando, até os dias atuais a maior parte dos estudos de referência apresentam cenários que se acredita terem um comportamento diferente dos países em desenvolvimento. Nem sempre o cenário de crescimento populacional, nível de renda, localização das moradias, tempo de viagem, quantidade de transbordos, tipo de emprego e propriedade do automóvel é semelhante em países em desenvolvimento e em países já desenvolvidos. Dessa forma, faz-se necessária a busca pelos parâmetros relevantes para os cenários em questão, visto que não se tem garantia de que as informações dos países desenvolvidos sejam generalizáveis (CROTTE *et al.*, 2011).

Assim sendo, pode-se justificar a escolha desse tema pela situação precária na qual os sistemas brasileiros de transporte público se encontram e pela necessidade de se entender as causas de sua decadência. Como afirmam Webster e Bly (1981), a importância do estudo desse tema foi crescendo com a deterioração dos sistemas e o abandono dos passageiros do transporte público. Além do mais, existem poucas estimativas que englobam os principais determinantes da demanda no Brasil e que definam as suas principais características.

Ademais, fundamenta-se a natureza econômica do estudo pelo fato de poder contribuir para a melhor estabilidade dos sistemas, com a redução da possibilidade de desequilíbrio financeiro das empresas por redução de passageiros. Respalda-se também a natureza política, por ter chances de contribuir para ações dos gestores, com objetivo de melhorar a qualidade do transporte e atrair novos usuários. Bem como justifica-se a natureza social da pesquisa, por buscar entender com um nível de serviço mais adequado para a população interfere nas escolhas modais dos cidadãos.

A questão principal dessa pesquisa é, então, buscar quais os fatores que influenciam a demanda por transporte público em cidades brasileiras em anos recentes e qual a estimativa da amplitude de ação de cada parâmetro. Assim, o estudo tem importância no Brasil, uma vez que através do conhecimento dos principais fatores influenciadores da demanda por transporte público é possível definir as necessidades predominantes dos passageiros, os atributos dos sistemas, as infraestruturas essenciais e orientar as políticas públicas relativas ao transporte urbano para minimizar a problemática relativa à diminuição de passageiros no sistema, podendo até, em longo prazo, ajudar a atrair novos passageiros.

1.2 OBJETIVOS

1.2.1 Geral

O objetivo geral da dissertação é caracterizar e aferir os principais fatores que influenciam a demanda por transporte público no Brasil, tendo em vista identificar as causas mais relevantes da retração da demanda e os meios de superá-la.

1.2.2 Específicos

Para tal fim, como objetivos específicos, são necessários:

- Buscar na literatura os determinantes da demanda constatados por diversos estudos realizados em outros países, investigando principalmente as características semelhantes com o quadro nacional;
- Analisar os modelos utilizados na literatura pesquisada para definição da melhor aplicação aos dados brasileiros com base nas similaridades entre os cenários e entre os dados obtidos;
- Estimar a intensidade de influência de cada fator com relação à demanda a partir do cálculo das suas elasticidades em relação à demanda;
- E avaliar quais as ações estratégicas a serem tomadas para que seja possível mudar o cenário atual das cidades, a partir dos resultados encontrados.

A dissertação se limita à aplicação de um modelo econométrico com os dados secundários de algumas cidades brasileiras em certo período de tempo para definição do comportamento da flutuação da demanda brasileira. Mesmo existindo uma compilação de estudos internacionais e uma comparação com eles, esta análise se limita ao contexto brasileiro.

1.3 ABORDAGEM METODOLÓGICA

O estudo possui como primeira etapa a busca pelo maior número de pesquisas referentes à investigação dos determinantes da demanda por transporte público, a fim de encontrar as correspondências necessárias para justificar as escolhas desta pesquisa. Além disso, os resultados encontrados neste trabalho devem ser comparados com as referências com o intuito de verificar a semelhança entre eles e a consistência dos dados e do modelo, sendo possível também entender os tipos de soluções aplicáveis ou não no cenário brasileiro.

Como segunda etapa, o estudo mais aprofundado dos modelos econométricos deve ser realizado com o propósito de compreender os modelos existentes para ser possível captar as aplicações e adaptações feitas nas pesquisas de referência. Em paralelo, a busca pelos dados secundários das cidades brasileiras também fará parte dessa etapa, uma vez que, conhecendo o tipo dos dados que serão estudados, a investigação do método mais adequado é direcionada. Dessa forma, o modelo econométrico é escolhido visando a maior adaptação a esse estudo.

Como próximo passo, a aplicação do modelo escolhido é feita através de regressões com funções variadas para examinar o comportamento dos parâmetros, aliado a testes como,

de autocorrelação, heteroscedasticidade, ajuste de erro, endogeneidade para validação do modelo. Além disso, é importante ressaltar que serão feitos ajustes das variáveis para melhorar os resultados, como por exemplo a normatização da demanda pela população, para testar os efeitos das variáveis através das repetidas tentativas. Com o modelo validado, os valores de elasticidade da demanda serão obtidos para cada variável explicativa.

A partir dos resultados encontrados, a análise foi realizada primeiramente pela similaridade ou disparidade com relação às referências internacionais. Desse modo, é possível entender a forma como a demanda provavelmente se comportará a partir da ação de certas políticas públicas, devido ao fato desta mesma situação já ter ocorrido em outro país de forma semelhante. Ademais, a análise dos resultados também foi feita com o foco voltado para o cenário brasileiro, de acordo com as características e possibilidades daqui, já que soluções aplicadas em outros países, mesmo com características semelhantes, podem ser inviáveis no nosso contexto. E assim, torna-se possível sugerir medidas com base na nossa realidade.

1.4 ESTRUTURAÇÃO DO TRABALHO

O trabalho está dividido em seis capítulos, sendo o primeiro deles esta introdução. O Capítulo 2 refere-se à revisão bibliográfica, onde são apresentados o conceito de demanda e os estudos internacionais encontrados na literatura com o propósito de embasar a pesquisa e compreender a melhor forma de aplicar técnicas semelhantes ao caso brasileiro.

O Capítulo 3 é responsável por caracterizar os sistemas de transporte público das cidades brasileiras estudadas e também apresentar certos atributos essenciais de cada cidade, com o objetivo de contextualizar o leitor sobre a área de estudos. O Capítulo 4 apresenta a metodologia utilizada, detalhando a análise dos estudos internacionais, os dados obtidos e o modelo de regressão utilizado. Os dados secundários obtidos são especificados neste capítulo, apresentando a forma de tratamento deles para aplicação no modelo. O modelo de regressão também é discriminado nesse tópico para detalhamento da metodologia utilizada na aplicação dos dados no modelo.

O Capítulo 5 apresenta os resultados encontrados com a explicação da obtenção de cada parâmetro, os erros associados, os testes utilizados para análise das variáveis e finalmente as elasticidades encontradas. Além disso, nesse capítulo são desenvolvidas as discussões relativas ao comportamento das elasticidades da demanda isoladas e combinadas.

Por fim, o Capítulo 6 apresenta as conclusões do estudo, onde são expostas descobertas relevantes e a justificativa desta evidência. Além disso, são expostas as sugestões de ações referentes ao transporte público a partir dos resultados encontrados. Ademais, são apresentadas sugestões para trabalhos futuros com intuito de prosseguir e aprofundar esta temática.

2 FUNDAMENTAÇÃO TEÓRICA

O Capítulo 2 tem como objetivo principal compilar as pesquisas e informações referentes a estudos da demanda por transporte público separados em duas subseções e os conceitos de métodos econométricos aplicados ao estudo. A primeira seção detalha brevemente o conceito de demanda na microeconomia. A segunda seção aborda os conceitos e contextos da análise da demanda por transporte público no mundo. Já a terceira e última seção expõe os parâmetros utilizados nos estudos de previsão da demanda por transportes públicos, as pesquisas existentes e a relevância de cada um deles.

2.1 O CONCEITO CLÁSSICO DE DEMANDA

A microeconomia é o estudo do comportamento de agentes individuais, como empresas e consumidores, para a construção de uma teoria com resultados econômicos decorrente da interação entre esses agentes. A teoria microeconômica se diferencia por buscar a modelagem da atividade econômica por meio das relações dos agentes econômicos individuais na busca dos seus interesses privados (MAS-COLELL *et al.*, 1995).

A função de demanda, por sua vez, é fundamental para reunir as preferências dos consumidores a fim de solucionar os problemas por meio de procedimentos matemáticos. Essa função é definida pela relação da demanda agregada com o preço, mas também com os níveis de renda dos consumidores. Os pares de observações relativos ao preço e a renda irão demonstrar as escolhas dos consumidores na curva de demanda relacionando o preço com a quantidade demandada. Com isso, a função de demanda torna possível a análise do efeito de uma mudança de preço no bem-estar dos indivíduos, por exemplo. Isto é, assumindo um nível de renda fixo, o impacto da mudança de preço nos consumidores pode ser medida através da função de demanda (MAS-COLELL *et al.*, 1995).

A análise de como a escolha do consumidor varia com as mudanças de preço e renda é alvo frequente dos estudos da demanda, sendo conhecida como análise estática comparativa. Essa investigação resulta no conhecimento dos tipos de produtos e como eles irão se comportar. Os bens podem ser definidos como normais, quando a demanda cresce devido ao crescimento da renda e inferiores quando ocorre o inverso, ou seja, a demanda sofre uma redução com o aumento da renda. Mesmo sendo trivial supor que uma queda de preço resultará numa maior demanda, conhecido como bem comum, a situação inversa também é

possível. Esse bem é conhecido como de *Giffen* e ocorre em casos como, por exemplo, quando o bem é de baixa qualidade, adquirido por consumidores com baixos níveis de renda, sendo assim, uma redução no preço pode induzir a oportunidade de comprar outros bens de qualidade melhor (MAS-COLELL *et al.*, 1995).

Outro conceito fundamental para o estudo da demanda ou da oferta é a elasticidade. Segundo Marshall (2013), a lei universal é relacionada ao desejo das pessoas de adquirir certo bem. Essa vontade reduz a medida que a oferta do bem aumenta, ou seja, o preço que o consumidor está disposto a pagar diminui com o crescimento da oferta. Este desejo é definido como a elasticidade e mede a intensidade da modificação da demanda através de mudanças no preço, na renda e em outras variáveis que possam influenciar a demanda, ou seja, a variação percentual da quantidade demandada dado uma variação percentual no preço, na renda ou em outros fatores. Marshall (2013) ainda aponta que a elasticidade da demanda pode ser grande ou pequena, de acordo com a intensidade de variação da quantidade demandada para um determinado aumento ou queda no preço.

2.2 DEMANDA POR TRANSPORTE PÚBLICO

A perspectiva do transporte público atual é resultado de mudanças significativas que ocorreram nas décadas de 60 e 70 do século XX. Antes disso, os transportes públicos tinham sido reconhecidos como importantes para o modo de vida das pessoas, porém seu fornecimento era considerado uma atividade comercial lucrativa. Foi a partir desta época e de uma pesquisa colaborativa entre um grupo de países desenvolvidos – Austrália, Canadá, França, Holanda, Nova Zelândia, Suécia, Reino Unido, EUA e Alemanha – que esta visão foi contestada. O transporte público começou a ser tratado como uma questão social ou serviço público que não poderia mais ser deixado totalmente a critério das forças de mercado. A defesa do incentivo público foi introduzida com o intuito de ampliar os benefícios diretos e indiretos do transporte (WEBSTER; BLY, 1981).

A eficiência geral do transporte, a proteção ao meio ambiente, a segurança, a melhoria da acessibilidade em áreas carentes e a redução do consumo de energia são benefícios atrelados a essa mudança de visão. Em contrapartida, para que as melhorias ocorressem nos sistemas de transportes públicos, a mudança de perspectiva também veio com a necessidade de um melhor entendimento do funcionamento do transporte. Os motivos de demanda das pessoas por viagens e a satisfação dos usuários, não mais só a lucratividade, são

parâmetros complexos e às vezes conflitantes que começaram a ser avaliados. Foi a partir dessa análise voltada para o desempenho que os primeiros estudos sobre a demanda de transporte público foram realizados. O objetivo foi de buscar e avaliar os dados disponíveis sobre a influência de fatores independentes na demanda por transporte público e conceituar os principais parâmetros para servir de referência na análise da demanda (WEBSTER; BLY, 1981).

O estudo de Webster e Bly (1981) se tornou referência por apontar que existem fatores significativos nas decisões de planejamento de transportes. Primeiramente, é necessário para eles o conhecimento da reação das pessoas a mudanças nos transportes, como tarifas e qualidade do serviço ou provocadas por outras circunstâncias, como renda, propriedade do carro e uso de solo. Depois, os autores apontam a importância de analisar os custos de operação para avaliar o potencial de redução dos mesmos. Assim, as definições para o estudo do planejamento dos transportes públicos através da demanda foram direcionadas e a importância do conhecimento dos fatores influenciadores de cada localidade foi destacada. Muitos estudos já foram feitos com esta finalidade, sendo estes as referências para o desenvolvimento desta pesquisa com foco no cenário brasileiro.

2.2.1 Conceituação de demanda por transporte público

A demanda por transporte público, de maneira mais geral, é conceituada como uma demanda derivada. Ou seja, a viagem existe pela necessidade de consumir outros bens e serviços, não por si só. O conjunto de atividades realizadas terá influência direta na decisão de viagem através da oferta das atividades ou do preço dos bens relacionados, interligando assim os estudos da demanda a análises de oferta, ao desenvolvimento urbano e a fatores econômicos (HOLMGREN, 2007; SMALL; VERHOEF, 2007).

O conceito de demanda por transportes públicos também deriva dos requisitos de análise da demanda de viagens. Small e Verhoef (2007) destacam que a previsão de utilização das infraestruturas, a resposta dos usuários aos preços e às características do serviço e o prognóstico dos benefícios de um projeto têm relação direta com a demanda por transporte público.

Outra perspectiva foca nos usuários como fator de singularidade do transporte público. Esse modo de transporte se torna assim especial por ter as pessoas no seu processo de produção. Por isso, os valores relacionados ao tempo de utilização do transporte podem ter

maior significância que fatores monetários. Já que, os sistemas não são voltados mais para somente a lucratividade, a análise por essa perspectiva também pode ser escolhida para definição da demanda por transporte público (PRESTON, 2015).

2.2.2 Fatores relevantes na demanda por transporte público

A definição das variáveis importantes no dimensionamento da demanda varia dependendo principalmente da sociedade em estudo. Porém, existem fatores que são considerados básicos na análise da demanda por transporte público devido ao seu caráter estruturante. Balcombe *et al.* (2004) destacam que as variáveis conceituais ligadas à demanda por transporte público são vinculadas a duas questões: econômica e de qualidade da oferta. A primeira relacionada a tipo de tarifa, preço de combustível, renda, etc. e a segunda com foco nos intervalos de serviço, confiabilidade, transbordos, etc.

Para Small e Verhoef (2007), a demanda por viagens pode ser explicada pelos fatores relativos a produtos e consumo. No caso da demanda por viagens em geral, a relação é dada pela tarifa, preços dos produtos substitutos, qualidade de serviço e renda média. Além disso, os autores alertam que mesmo abrangendo todos estes aspectos, sempre haverá uma parcela do comportamento da demanda que não será representado, precisando assim da adição de um fator de aleatoriedade.

O preço ao usuário, sua renda e bens e serviços substitutos disponíveis são fatores estruturais clássicos da demanda de viagens urbanas (SOUCHE, 2010). Para Wardman (2012), o custo monetário e o tempo de viagem são os fatores mais influentes na operação e nas tomadas de decisão do setor de transportes. Os parâmetros relacionados ao preço, ao tempo e ao custo financeiro do tempo são essenciais, na visão do autor, para o planejamento e gestão dos transportes. Além disso, o autor ressalta a importância da análise do comportamento das pessoas a partir de mudanças na frequência do serviço, pois esta é uma medida de gerenciamento de mudanças na demanda e de oportunidades de serviços.

Tsai e Mulley (2014) definem o modelo de demanda de transporte público em quatro dimensões: i) tarifa do transporte público; ii) qualidade do serviço; iii) características sociais e econômicas dos usuários; e iv) localização das moradias. A partir de algumas definições, é possível observar que paralelamente existe uma gama de alternativas para determinação da demanda por transporte público. Estes são, então, os fatores estruturantes mais citados e analisados nos estudos revisados.

Os autores nem sempre entram em consenso com relação à comparação do nível de importância de um parâmetro comparado ao outro. Isto ocorre porque fatores relativos à localidade do estudo, ao tipo de metodologia e ao foco da análise exercem forte influência sobre os resultados. Para Balcombe *et al.* (2004), o parâmetro mais discutido com relação a demanda por transportes públicos é possivelmente a tarifa, principalmente por causa da facilidade de identificação e mensuração das mudanças tarifárias.

Para Paulley *et al.* (2006), o parâmetro econômico mais relevante é a renda, sendo este um determinante da propriedade do modo substituto. A propriedade do automóvel ou outro substituto gera influência na demanda, pois variações neste aspecto podem influenciar positiva ou negativamente a demanda por transporte público. Os autores também dissertam sobre os fatores relacionados à qualidade do serviço. Para eles, os parâmetros que envolvem o tempo de forma direta, como intervalos, tempo de acesso e tempo no veículo são fatores mais facilmente quantificados e conseqüentemente, mais utilizados. Variáveis mais qualitativas como confiabilidade, características do veículo e fornecimento de informações são consideradas mais complexas.

Como evidenciado nos estudos de Balcombe *et al.* (2004), Paulley *et al.* (2006) e Holmgren (2013) existe uma maior facilidade na utilização da tarifa e da qualidade do serviço como parâmetros da demanda pela disponibilidade de dados. Porém, a maior compreensão das características da escolha de viagens por transporte público deve ser feita através da junção destes fatores com outros parâmetros também relevantes para buscar uma caracterização mais completa da demanda, a fim de contribuir para o planejamento dos transportes.

Um exemplo de fator significativo, porém nem sempre considerado é dado também por Balcombe *et al.* (2004): a densidade populacional de uma cidade. Para os autores, a densidade influencia na demanda de transporte, pois maiores densidades demográficas resultam em um maior número de passageiros com menores tempos de viagem. Em adição a isso, vale ressaltar que outras características relativas à cidade, como forma urbana e uso do solo, têm potencial de influenciar a demanda por transporte. No entanto, esses fatores às vezes são de difícil mensuração.

Um segundo fator de relevância em certos cenários de estudo é a taxa de desemprego, embora não seja muito estudada. Variações na economia têm influência direta no número de passageiros do transporte público. Estas podem ser analisadas através da taxa de desemprego ou do padrão da renda. Cada um desses fatores possuem efeitos contrários na

escolha de viagem por transporte público, sendo a taxa de desemprego um parâmetro importante na definição da influência dos fatores econômicos na demanda por transporte público, definindo até o modo como bem normal ou inferior (CORDERA *et al.*, 2015).

Por fim, é necessário destacar que mesmo as variáveis estruturais básicas da demanda, quando sujeitas a mudanças, possuem um tempo de adaptação. Da mesma forma, os hábitos das pessoas são fatores comportamentais que não se alteram instantaneamente. Assim, as análises dos parâmetros devem levar em conta o fator temporal como importante, sendo avaliadas as variáveis nos prazos curto, médio e longo, caso seja possível (SOUCHE, 2010; DALDOUL *et al.*, 2016).

2.2.3 Medida de dimensionamento da demanda - Elasticidades

A elasticidade é o parâmetro do modelo econométrico que tem o papel de caracterizar a relação das variáveis independentes com a variável dependente, neste estudo, a demanda por transporte público. Como define Preston (2015), “as elasticidades são indicadores-chave da sensibilidade da variável de interesse (neste caso, demanda por transporte público) às variáveis de política”. Para esse autor, a elasticidade mais importante é a elasticidade-preço da demanda.

O valor da elasticidade também tem o poder de determinar se a variável dependente, a demanda, sofre muita ou pouca influência dos fatores independentes. O limiar para esta definição é o valor 1. Quando o valor da elasticidade do parâmetro com relação a demanda for menor que 1, a demanda é inelástica, ou seja, pouco se modifica com uma mudança no fator estudado. Um exemplo disso é a elasticidade-preço da demanda por transporte público, em que o aumento de preço não gera grande evasão e conseqüentemente, aumenta a receita do setor. Em contrapartida, quando o valor da elasticidade é maior que 1, a demanda é elástica e o parâmetro estudado gera uma mudança mais que proporcional na demanda (PRESTON, 2015).

Em alguns tipos de estimação, como em séries temporais e com dados em painel, a elasticidade pode ser vista de duas formas: a curto e longo prazo. Essas estimativas têm o objetivo de tentar entender as modificações da demanda, devido a mudanças em fatores explicativos ao longo do tempo, ou seja, como as pessoas reagirão de imediato e em um período mais prolongado. No curto prazo, provavelmente a resposta à variação será menor do que no longo prazo, devido às restrições de mudança de comportamento das pessoas e à

percepção das mudanças ocorridas. Além disso, existem modelos de regressão que resultam em elasticidades estáticas, sendo estas comparáveis com as elasticidades de curto prazo. Já com relação ao longo prazo, este é o período estimado que 95% do efeito da mudança está prevista para ocorrer. Geralmente, a elasticidade da demanda por transporte público média do longo prazo é duas vezes maior que a do curto prazo (WARDMAN, 2012).

Um exemplo da importância da diferenciação do curto e longo prazo na elasticidade é dado por Tsai e Mulley (2014), ao afirmarem que um aumento de 100% na tarifa de transporte público, em média por meio da elasticidade, reduziria em 21% da demanda no primeiro ano e em 5% no segundo ano, ou seja, para os autores, se a consideração fosse feita somente com as elasticidades de curto prazo, existiria uma redução de 5% dos usuários não prevista no sistema que poderia acarretar problemas após o período de adaptação das pessoas. Também defendem que se houver negligência com a ação destes parâmetros em médio e longo prazo, a tomada de decisão estará usando dados subdimensionados e poderá resultar em problemas de oferta e qualidade do serviço. Por isso, os autores destacam a importância e utilizar uma estimação que possibilite a distinção da atuação da variável explicativa na demanda no curto e longo prazo.

2.3 ANÁLISE DOS PARÂMETROS

Com a apresentação de alguns conceitos necessários para o desenvolvimento da pesquisa, o objetivo agora é identificar os parâmetros estudados e caracterizá-los através das elasticidades determinadas nos estudos realizados. A exposição dos dados referentes a estudos internacionais e das conclusões provenientes de cada estudo está detalhada nesta subseção. A divisão por parâmetros foi escolhida para facilitar a compreensão e comparação dos estudos apresentados.

Começando por uma rápida síntese dos estudos apresentados e discutidos nesta subseção, existem dois estudos que apresentam dimensionamentos consistentes e servem de referência para muitos estudos atuais. Bresson *et al.* (2003) detalham os fatores influenciadores da demanda por transporte público na Inglaterra e na França por meio da análise de sistemas de ônibus e de sistemas integrados de metrô e ônibus. O segundo, publicado por Balcombe *et al.* (2004) se chama – ‘*The Demand for Public Transport: A Practical Guide*’ e é a sucessão da pesquisa tida como primeira referência na definição dos

fatores que influenciam a demanda de Webster e Bly (1981), tendo estudado países na Europa, na América do Norte e a Austrália.

Com o desenvolvimento dos sistemas e a necessidade de conhecimento das características da demanda, as pesquisas foram sendo realizadas com várias perspectivas e em vários cenários. Provavelmente a mais abrangente em termos de localidades, foi realizada por Souche (2010), num estudo que englobava 100 cidades de todos os continentes. Outros estudos já analisados apresentam as características de vários países ao redor do mundo. Alguns exemplos são: Cordera et al. (2015) na Espanha; Tsai et al. (2014) na Austrália; De Grange et al. (2013) no Chile; Rahman e Balijepalli (2016) na Índia; Daldoul et al. (2016) na Tunísia; Holmgren (2013) na Suécia; Holmgren (2007) com dados da Europa, América e Austrália; e Hensher (2008) com parâmetros de várias partes do mundo.

Assim, através da análise das variáveis já pesquisadas, da disponibilidade de dados para o cenário brasileiro e dos modelos de previsão da demanda disponíveis, é possível destacar quais parâmetros terão influência na demanda por transporte público nas cidades brasileiras. E com isso, poder auxiliar na definição do direcionamento que os planejadores poderão seguir.

2.3.1 Tarifa

A elasticidade da tarifa em relação à demanda é uma variável relevante que depende das características do sistema, como modo e período em estudo, e também de circunstâncias de operação, hora do dia e amplitude de mudanças tarifárias. Além disso, acredita-se que, independentemente dos fatores relacionados ao cenário, o parâmetro preço tende a ser inelástico e possuir um valor de elasticidade no curto prazo em torno de -0,30 e -0,40 (WEBSTER e BLY, 1981; BALCOMBE *et al.*, 2004).

Para Goodwin e Williams (1985), a relação de dependência entre a demanda e a tarifa é a mais estudada entre os fatores que possuem influência sobre a demanda por transporte. Para esses autores, o intervalo da elasticidade situa-se entre -0,10 e -0,60, sendo o valor de -0,30 o mais recorrente. Os três estudos citados são referências na definição do valor padrão da elasticidade-preço da demanda por transportes públicos mesmo estes sendo estudos realizados em países desenvolvidos. Além disso, os sistemas estudados abrangem os modos de transporte público distintos, como ônibus, metrô e trem, com o objetivo de buscar definir a intensidade da elasticidade-preço padrão.

A Tabela 1 apresenta os estudos analisados e a constatação de que, numa visão geral, a elasticidade-preço da demanda por transporte público teve um crescimento ao longo do tempo, porém mantém alguma tendência e intensidade semelhante ao estudo de referência. Esta mudança pode ter ocorrido devido ao crescimento econômico ou a fatores tecnológicos através de novas alternativas disponíveis. Além disso, a elasticidade-preço da demanda possui variação de intensidade entre os modos estudados, tendo por exemplo, uma faixa de elasticidade maior para estudos com sistema de ônibus ou sistemas de transporte público integrados do que somente o metrô.

Ademais, a Tabela 1 mostra que para estudos somente com ônibus a elasticidade no curto prazo varia entre -0,13 e -0,75 e no longo prazo entre -0,16 e -1,00. Já para os sistemas de transporte público integrado com características diversas esta elasticidade é um pouco menor no curto prazo variando de -0,10 a -0,50 e maior no longo prazo do que os sistemas só de ônibus, -0,26 a -1,70. Por fim, os sistemas de metrô apresentam elasticidades-preço mais baixas e com uma variação menor: -0,05 a -0,60 no curto prazo e -0,33 a -0,60 no longo prazo.

Alguns dos estudos apresentados na Tabela 1 expõem conclusões variadas para as causas das elasticidades encontradas. Schimek (2015) analisou a elasticidade-preço dos transportes públicos dos Estados Unidos, tendo como resultado uma elasticidade de -0,34 no curto prazo e -0,66 no longo prazo. O autor acredita que a influência de uma variação tarifária na demanda de passageiros depende do nível de tarifa inicial. Dessa forma, o aumento em tarifas mais baixas tende a gerar maior insatisfação e evasão de passageiros.

O estudo de Wardman (2014) no Reino Unido analisa as elasticidades-preço da demanda de vários modos e por vários aspectos e resulta em uma elasticidade-preço da demanda por ônibus de -0,46. Segundo o autor, este resultado é condizente com o mercado, pelo fato de o Reino Unido ter em grande parte característica urbana. Dessa forma, uma maior parcela da população depende do transporte público, resultando assim em uma característica inelástica da demanda.

Tsai e Mulley (2014) estimam as elasticidades-preço de demanda em Sydney no curto e longo prazo com valores de -0,21 e -0,26, respectivamente. Isto indica que se houver um aumento de 100% na tarifa, haverá uma redução de 21% na quantidade demandada no primeiro ano e outra redução de mais 5% no segundo ano. Para os autores, se no método econométrico não for considerado o efeito em longo prazo, na formulação de políticas públicas a influência do aumento da tarifa seria subestimada.

Tabela 1 – Elasticidade-preço da demanda

Autor	Local	Sistema	Curto Prazo	Longo Prazo
Bresson <i>et al.</i> (2003)	Inglaterra e França	Ônibus (I) e Sistema de TP (F)	-0,20 a -0,50	-0,50 a -0,80
Balcombe <i>et al.</i> (2004)	Europa América do Norte e Austrália	Ônibus	-0,40	-1,00
		Metrô	-0,30	-0,60
		Trens Suburbanos	-0,60	-
Holmgren (2007)	Europa	Ônibus	-0,75	-0,91
	América/Austrália	Ônibus	-0,59	-0,75
Holmgren <i>et al.</i> (2008)	Linköping, Suécia	Ônibus	-0,25	-
Wang (2009)	Wellington, NZ	Ônibus	-0,23	-0,46
	Canterbury, NZ		-0,26	-0,34
Deb e Filippini (2013)	Índia	Ônibus	-0,37	-0,52
De Grange <i>et al.</i> (2013)	Santiago, Chile	Ônibus entre pico	-0,35	-
		Ônibus no pico	-0,29	-
Fullerton Jr e Walke (2013)	El Paso, Texas, EUA	Ônibus	-0,45 a -0,51	-
Wardman (2014)	Reino Unido	Ônibus	-0,32 a -0,42	-0,64 a -0,83
Cordera <i>et al.</i> (2015)	Santander, Espanha	Ônibus	-0,13 a -0,20	-0,16 a -0,34
Hensher (2008)	Mundo	Sistema de TP	-0,40	-
Souche (2010)	100 cidades do mundo	Sistema de TP	-	-1,70
Holmgren (2013)	Suécia	Sistema de TP	-0,40	-
Tsai <i>et al.</i> (2014)	Sidney, Austrália	Sistema de TP	-0,22	-0,29
Tsai e Mulley (2014)	Sydney, Austrália	Sistema de TP	-0,21	-0,26
Schimek (2015)	198 agências dos Estados Unidos	Sistema de TP	-0,34	-0,66
	Estados Unidos (pop ≥ 1 milhão)		-0,20	-0,48
	Estados Unidos (pop < 1 milhão)		-0,38	-0,73
Burguillo <i>et al.</i> (2017)	Madrid, Espanha	Sistema de TP	-0,10	-
Graham <i>et al.</i> (2009)	22 maiores sistemas de metrô	Metrô	-0,05	-0,33
De Grange <i>et al.</i> (2013)	Santiago, Chile	Metrô entre pico	-0,20	-
		Metrô no pico	-0,57	-
Daldoul <i>et al.</i> (2016)	Tunísia	Urbano, Interurbano e Suburbano.	-0,40	-0,80
Rahman e Balijepalli (2016)	Chennai, Índia	Trens Suburbanos	-0,57	-0,57
	Kolkata, Índia		-0,29	-0,29
	Mumbai, Índia		-0,06	-0,06
	Chennai, Kolkata e Mumbai		-0,24	-

Fonte: a autora, 2018

Uma análise feita por Wang (2009) nas principais regiões da Nova Zelândia gerou conclusões importantes sobre a influência do tamanho do aglomerado urbano na elasticidade-preço da demanda por transporte público. De acordo com os resultados do autor, a maior região analisada, Auckland, não teve resposta significativa da tarifa com relação à demanda para alguns modos, provavelmente pelo tamanho da região e a dependência das pessoas na

utilização do transporte público para seus deslocamentos, já que este sempre foi o principal modo público utilizado. A região de Wellington teve uma elasticidade-preço estimada em -0,23 (menos elástica do que o valor de referência). E por fim, a elasticidade da região de Canterbury foi de -0,34, comparável aos resultados de Balcombe *et al.* (2004).

No cenário de recessão estudado por Burguillo *et al.* (2017), em Madrid na Espanha, as elasticidades-preço da demanda encontradas foram pequenas, porém significantes com valores de -0,10 e -0,13 para cada um dos anos de maior crise econômica. Esta mudança de resposta das pessoas à variação do preço de um ano para o outro pode ter relação com o maior aumento da tarifa no período analisado.

2.3.2 Qualidade do transporte público

Os fatores relacionados à qualidade do serviço são os mais variados. Isto ocorre pela dificuldade de mensuração de certas características qualitativas, gerando assim, uma gama de opções de análise da qualidade do serviço. Efthymiou e Antoniou (2017) definem três perspectivas mais abrangentes de qualidade: qualidade do serviço (condições do veículo, preço e comportamento dos prestadores do serviço); qualidade das transferências (tempo de espera, informações disponíveis e distância); e produção do serviço (frequência e confiabilidade).

De modo mais específico, Efthymiou e Antoniou (2017) apontam as características gerais dos sistemas de transportes públicos que podem atuar como indicadores de qualidade. Frequência do serviço, pontualidade, horários de prestação do serviço, cobertura da rede, fornecimento de informações gerais, tipos de bilhetes, preços das tarifas, pontos de venda, comportamento dos funcionários, existência de faixas exclusivas de ônibus e medidas de transporte público ecológico são os parâmetros citados pelos autores. Para eles, o aumento da tarifa, redução da frequência e fechamento de pontos de venda têm um significativo impacto na insatisfação dos usuários.

Outra maneira de análise da qualidade do serviço é apresentada por Daldoul *et al.* (2016). Os autores afirmam que este é um fator difícil de ser quantificado e apresentam três indicadores que são usados na literatura com maior disponibilidade de dados: i) velocidade comercial média, ii) densidade da malha viária e iii) frequência do serviço. Graham *et al.* (2009) por sua vez, apontam cinco especificações diferentes para medir a qualidade do serviço: i) extensões de linha; ii) mudanças de frequência e nas horas de operação; iii)

quilômetros percorridos e horas de operação por passageiro, sendo estes dois últimos indicativos de aglomeração e conforto; iv) quilômetros percorridos e horas de operação por comprimento de rede; e v) quilômetros de vagões pelas horas de operação, capturando as mudanças de velocidade.

Apesar da variedade de possibilidades de definição da qualidade do serviço de transporte, a variável mais utilizada por razões práticas para este aspecto é veículo-km, ou seja, a quilometragem operada pelos veículos do sistema. Mesmo assim, esta escolha leva a problemas relativos a não consideração dos efeitos relacionados à forma de execução do serviço, a frequência e a quilometragem perdida, por exemplo. Para este parâmetro, o valor padrão de elasticidade considerado na literatura é 0,40 (GOODWIN; WILLIAMS, 1985). Os estudos analisados nesta pesquisa abordam em sua maioria a elasticidade relativa ao veículo-km, como apontado por Goodwin e Williams (1985). No entanto, como mostra a Tabela 2, existem outros aspectos importantes utilizados para definir a qualidade do serviço. Além disso, é possível notar que em média as elasticidades da demanda com relação à qualidade do serviço têm intensidades semelhantes, mas com sinal oposto à elasticidade da tarifa.

Os resultados de estudos sobre a qualidade dos sistemas de transportes públicos por serem estimados com parâmetros diversos apresentam características semelhantes, mas as intensidades dos resultados são variadas. Graham *et al.* (2009) apresentam, como resultado das estimativas de regressão em 22 metrô, valores de elasticidade muito pequenos no curto prazo, entre 0,05 e 0,07, e valores mais compatíveis com as referências no longo prazo, entre 0,37 e 0,51. Para os autores, ainda é possível acreditar que melhorias na qualidade do serviço trarão mais vantagens do que redução da tarifa, visto que a elasticidade-preço da demanda neste caso é mais baixa.

De forma análoga a Graham *et al.* (2009), Wang (2009) encontra a elasticidade da região de Canterbury de 0,07 no curto prazo e de 0,62 no longo prazo, mais próximo, portanto, aos valores referenciados. Em contrapartida, a estimativa de Auckland no curto prazo já possui valor mais próximo das referências com grandeza de 0,46, no curto prazo, e no longo prazo de 0,73. Os autores acreditam que a justificativa para este valor baixo em Canterbury é a alta propriedade de carro e assim, menor mudança de comportamento no curto prazo, sendo esta mudança ocorrida quase que totalmente no longo prazo.

Há mais um estudo que segue a tendência vista nos dados da Tabela 2, em que as mudanças da qualidade de serviço são mais significativas do que mudanças tarifárias no comportamento das pessoas. Nesse caso, os passageiros dos transportes públicos em El Paso

apontam uma elasticidade de qualidade do serviço entre 0,56 e 0,68, enquanto a elasticidade preço varia de -0,45 a -0,51 no curto prazo. Dessa forma, os operadores têm a possibilidade de aumentar a receita de transporte através da manipulação desses dois parâmetros (FULLERTON JR; WALKE, 2013).

Tabela 2 – Elasticidades relativas à Qualidade do Serviço

Autor	Local	Sistema	Tipo de Variável	Curto Prazo	Longo Prazo
Bresson <i>et al.</i> (2003)	Inglaterra	Ônibus (I) e Sistema de TP (F)	Veículo-km	0,50 a 0,70	0,70 a 0,90
	França			0,20	0,30 a 0,60
Holmgren (2007)	Europa e América/Austrália	Ônibus	Veículo-km	1,05	1,38
Holmgren <i>et al.</i> (2008)	Linköping, Suécia	Ônibus	Veículo-km/km ²	0,44	-
Fullerton Jr e Walke (2013)	El Paso, Texas, EUA	Ônibus	Veículo-km	0,56 a 0,68	-
Holmgren (2013)	Suécia	Transportes Públicos Locais	Veículo-km	0,55	-
Chao <i>et al.</i> (2015)	Taiwan	Ônibus	Veículo-km	0,67	-
Cordera <i>et al.</i> (2015)	Santander, Espanha	Ônibus	Veículo-km	0,24 a 1,70	0,40 a 2,16
Schimek (2015)	198 agências dos Estados Unidos	Sistema de TP	Veículo-km	0,41	0,79
	Estados Unidos (pop ≥ 1 milhão)		Veículo-km	0,45	1,12
	Estados Unidos (pop < 1 milhão)		Veículo-km	0,35	0,67
Rahman e Balijepalli (2016)	Chennai, Kolkata e Mumbai	Trens Suburbanos	Veículo-km	0,81	-
Graham <i>et al.</i> (2009)	22 maiores sistemas de metrô	Metrô	Km percorrido/km total	0,07	0,51
			Horas de serviço/km total	0,05	0,36
Wang (2009)	Auckland, NZ Canterbury, NZ	Ônibus	Km/per capita	0,46 0,07	0,73 0,62
Crotte <i>et al.</i> (2011)	Cidade do México, México	Metrô	Km/per capita	0,26 a 0,35 0,52	0,35 a 0,41 0,73
Daldoul <i>et al.</i> (2016)	Tunísia	Urbano, Interurbano e Suburbano	Frequência de serviço	0,20	0,40
Balcombe <i>et al.</i> (2004)	Europa, América do Norte e Austrália	Ônibus	Frequência de serviço	0,40	0,70
Tsai e Mulley (2014)	Sydney, Austrália	Sistema de TP	Frequência de serviço	0,10	0,13
Tsai <i>et al.</i> (2014)	Sidney, Austrália	Sistema de TP	Frequência de serviço	0,15	-
Deb e Filippini (2013)	Índia	Ônibus	Densidade de cobertura	0,68	0,96

Fonte: a autora, 2018

Outra publicação desse mesmo ano analisa a qualidade através da cobertura do serviço de transporte. Deb e Filippini (2013) acreditam que este seja um fator relevante na estimativa da demanda, porém destacam que análises custo-benefício devem ser realizadas antes da definição das metas das políticas de melhoria da qualidade do serviço. As elasticidades encontradas pelos autores tiveram valores no curto prazo entre 0,68 e 0,87. No longo prazo, a modelagem resultou no valor de 0,96, um pouco acima das médias referenciadas.

Nos parâmetros encontrados por Tsai e Mulley (2014) para Sidney na Austrália, a elasticidade da demanda pela frequência de ônibus não é um determinante relevante na estimativa da demanda por transporte público por ter um valor baixo, 0,13. Porém, esse ainda é um valor próximo do outro estudo realizado por Tsai *et al.* (2014). Mesmo assim, ao nível de significância de 90%, os autores esperam que um aumento na frequência pode aumentar moderadamente a demanda.

Schimek (2015) encontrou resultados nos Estados Unidos bem semelhantes à referência de Bresson *et al.* (2003). As elasticidades da qualidade do serviço através da medida de veículo-km apresentam valores entre 0,41 e 0,79, no curto e no longo prazo, respectivamente. Por fim, Brechan (2017) fez um *review* de vários estudos de estimativas de demanda e aponta que as decisões de aumento de frequência podem mudar o comportamento das pessoas em 37%; já os relacionados à redução da tarifa só modificam 30% do comportamento dos usuários. Em síntese, através da compilação de vários estudos, pode-se concluir que a tendência é que a variação na qualidade do serviço pode gerar uma proporção maior de viagens em transporte público do que a redução nas tarifas, estando assim de acordo com vários estudos relevantes.

Um último parâmetro para definição da qualidade do serviço não muito utilizado na literatura é a densidade de cobertura. Para Deb e Filippini (2013), em estudo na Índia, a qualidade pode ser vista através da densidade de rotas de transporte público. Além disso, os autores apontam maiores valores de elasticidade relacionados a este fator, 0,68 para o curto prazo e 0,96 para o longo prazo. Dessa forma, confirmam a importância da estimação da demanda pela utilização desse parâmetro.

2.3.3 Renda e fatores econômicos

Os parâmetros de renda e propriedade de automóvel comumente são analisados em conjunto devido à estreita ligação existente entre eles. Além disso, na maioria das estimativas, existe uma alta correlação entre eles, gerando assim problemas na regressão. Desta forma, nos modelos estimados a tendência é de escolher a renda como fator econômico ou a propriedade do carro, já que a renda é um determinante-chave desse parâmetro. Porém, vale ressaltar que em muitos casos existem outros fatores que podem representar a influência econômica na demanda, sendo menores os casos em que só a propriedade do carro é responsável por este papel (PAULLEY *et al.*, 2006; CORDERA *et al.*, 2015).

Os estudos que incluem a variável renda e propriedade do carro não possuem um padrão de resultado de elasticidade. Como vistos na Tabela 3, estes fatores podem apresentar elasticidades com sinais opostos e até intensidades bem variadas. Em muitos casos, a renda se apresenta como no estudo de Tsai e Mulley (2014) em Sidney, na Austrália, com sinal negativo, indicando que aumento na renda gera menor demanda por transporte público. Nestes casos, esse modo de transporte é considerado como bem inferior para população por variadas razões. Já nos casos em que a elasticidade encontrada é positiva, o transporte público tem característica de bem normal. Isto ocorre em situações em que, por exemplo, o sistema de transporte é bem desenvolvido como descreve Holmgren (2013) na Suécia, ou em situações em que a maior parte da população é tão carente que utiliza meios menos dispendiosos que o transporte público, como é o caso de tração animal ou a pé, a exemplo da Tunísia (DALDOUL *et al.*, 2016).

Fullerton Jr e Walke (2013), em estudos no Texas, acreditam que se os dados da propriedade do automóvel não estejam disponíveis, a renda da população pode representar a relação negativa entre a quantidade de passageiros do transporte público e a propriedade do automóvel. Com isso, os autores obtêm uma elasticidade-renda com valores entre -0,87 e -0,95, confirmando assim que o crescimento na posse do carro tende a reduzir as viagens de ônibus. Da mesma forma, na Índia o aumento da renda concomitantemente com o incentivo à indústria automobilística induziu a tendência de aumentar a utilização de veículos privados, caracterizando o transporte público como inferior, reduzindo o seu uso com o tempo e gerando problemas relacionados a congestionamentos (DEB; FILIPPINI, 2013).

No estudo de Wang (2009), na Nova Zelândia, a propriedade do automóvel foi utilizada como uma variável, definindo através dela a resposta da demanda a fatores

econômicos. O resultado obtido por eles teve sinal negativo representando o transporte público como bem inferior, porém a magnitude dos parâmetros foi muito maior do que as referências revisadas. Para o sistema de ônibus de Auckland, os valores encontrados foram -1,96 e -3,10 para o curto e longo prazo, e -0,32 e -1,04, para os trens de Wellington no curto e longo prazo.

Tabela 3 – Elasticidade–renda da demanda

Autor	Local	Sistema	Curto Prazo	Longo Prazo
Bresson <i>et al.</i> (2003)	Inglaterra	Renda per capita	-	-0,66
	França		-	0,00
Balcombe <i>et al.</i> (2004)	Europa, América do Norte e Austrália	Renda	0,00 a -0,70	-0,50 a -1,50
Holmgren (2007)	Europa e América/Austrália	Renda	-0,62	-
Graham <i>et al.</i> (2009)	22 maiores sistemas de metrô	Renda per capita	0,03	0,18
Crotte <i>et al.</i> (2011)	Cidade do México, México	Renda per capita	-0,18 a -0,26 -0,45	-0,72 a -0,83 -0,94
Deb e Filippini (2013)	Índia	Renda per capita	-0,03	-0,04
Fullerton Jr e Walke (2013)	El Paso, Texas, EUA	Renda	-0,87 a -0,95	-
Holmgren (2013)	Suécia	Renda	0,34 (direta)	-
			0,05 (direta/indireta)	-
Tsai <i>et al.</i> (2014)	Sidney, Austrália	Renda pessoal anual	-0,16	-
Tsai e Mulley (2014)	Sydney, Austrália	Renda	-0,17	-0,23
Schimek (2015)	198 agências dos Estados Unidos	Renda	-0,36	-0,69
	Estados Unidos (pop ≥ 1 milhão)		-0,37	-0,91
	Estados Unidos (pop < 1 milhão)		-0,26	-0,50
Daldoul <i>et al.</i> (2016)	Tunísia	Renda per capita de cada departamento	0,38	0,67
Jia <i>et al.</i> (2016)	Pequim, China	PIB	0,40	0,54
			0,27	0,23
Burguillo <i>et al.</i> (2017)	Madrid, Espanha	Renda	0,85	-
Holmgren (2007)	Europa e América/Austrália	Propriedade do Automóvel	-1,48	-
Holmgren <i>et al.</i> (2008)	Linköping, Suécia	Propriedade do Automóvel	-0,67	-
Wang (2009)	Auckland, NZ	Propriedade do Automóvel	-1,96	-3,10
Holmgren (2013)	Suécia	Propriedade do Automóvel	-1,37	-
Jia <i>et al.</i> (2016)	Pequim, China	Propriedade do Automóvel	-	-0,10

Fonte: a autora, 2018

Para Schimek (2015), o transporte público nos Estados Unidos é tipicamente caracterizado como um bem inferior. O autor usou medidas da renda familiar e pessoal per capita, de emprego em área metropolitana e do preço da gasolina. Neste caso, o autor obteve resultado para cada um dos parâmetros, sendo a renda com elasticidade de -0,36 no curto prazo e -0,69 no longo, os empregos com valor de 0,21 e 0,41 e o preço da gasolina de 0,08 e 0,15 no curto e longo prazo, respectivamente. Confirmava-se, assim, a afirmação inicial do autor de que os transportes públicos são considerados um bem inferior nos Estados Unidos.

As conclusões de Burguillo *et al.* (2017), em Madrid na Espanha, apontam em uma direção diferente das anteriores, pois expõem uma elasticidade-renda positiva com valor de 0,85, dessa forma, caracterizando o transporte público como bem normal. Porém, os autores acreditam ainda que o preço do combustível pode representar um produto substituto ao transporte público, pois através da elasticidade cruzada da tarifa e preço da gasolina, um aumento na tarifa de 1% na tarifa gera um crescimento de 0,25% no consumo de gasolina. Graham *et al.* (2009) também encontram elasticidades renda positivas, porém com uma magnitude menor, sendo os valores iguais a 0,03 e 0,18 no curto e longo prazo, respectivamente.

O último estudo revisado com estas variáveis é o de Jia *et al.* (2016) com dados de Pequim. Nesse caso, a influência de fatores econômicos é avaliada através do PIB e da posse de automóvel. As elasticidades da demanda com relação ao PIB tiveram valores positivos, com magnitudes entre 0,23 e 0,54 no curto prazo. Já o efeito dos carros particulares é registrado através de uma elasticidade com relação à demanda de -0,10 no longo prazo, sendo esta insignificante no curto prazo. Este resultado é coerente com a velocidade lenta de ajuste do comportamento das pessoas relacionado ao uso do automóvel.

2.3.4 Outros parâmetros relevantes

Como discutido na seção 2.2, existem outros parâmetros para a estimação da demanda que não são relacionados a tarifa, qualidade do serviço e renda. Mesmo não existindo muitos estudos com este foco e sendo difícil o acesso a dados, fatores como forma urbana, tamanho dos terrenos e uso do solo têm potencial para influenciar a demanda. Principalmente, variáveis relacionadas ao uso do solo afetam significativamente a demanda por transporte público, tendo uma característica muito forte de mudança no longo prazo (BALCOMBE *et al.*, 2004; DALDOUL *et al.*, 2016). A Tabela 4 mostra estes e outros

fatores nem sempre estudados, mas que podem influenciar significativamente a demanda de acordo com o cenário estudado.

Tabela 4 – Elasticidade de outros fatores relevantes

Autor	Lugar	Tipo da Variável	Curto Prazo	Longo Prazo
Goodwin e Williams (1985)	Londres, Inglaterra	Taxa de Desemprego	-0,35 a -0,60	-
Cordera <i>et al.</i> (2015)	Santander, Espanha	Taxa de Desemprego	0,13	0,21
Souche (2010)	100 cidades do mundo	Densidade Urbana	0,40	-
Daldoul <i>et al.</i> (2016)	Tunísia	Taxa de Ocupação Geral	0,42	0,74
Tsai <i>et al.</i> (2014)	Sidney, Austrália	Densidade populacional	0,60	-
Tsai e Mulley (2014)	Sydney, Austrália	Densidade Populacional	0,50	0,65
Holmgren (2007)	Europa e América/Austrália	Preço da Gasolina	0,40	-
Wang (2009)	Auckland, NZ	Preço da Gasolina	0,20	0,32
	Canterbury, NZ		0,28	0,37
Fullerton Jr e Walke (2013)	El Paso, Texas, EUA	Preço da Gasolina	0,11 a 0,17	-
Chao <i>et al.</i> (2015)	Taiwan	Preço da Gasolina	0,18	-
Schimek (2015)	198 agências dos Estados Unidos	Preço da Gasolina	0,08	0,15
	Estados Unidos (pop ≥ 1 milhão)	Preço da Gasolina	0,09	0,22
	Estados Unidos (pop < 1 milhão)	Preço da Gasolina	0,07	0,13
Cordera <i>et al.</i> (2015)	Santander, Espanha	Preço da Gasolina	0,03 a 0,14	0,04 a 0,18
Rahman e Balijepalli (2016)	Chennai, Kolkata e Mumbai	Preço da Gasolina	0,15	-

Fonte: a autora, 2018.

No estudo de Tsai e Mulley (2014), os fatores relacionados ao uso do solo possuem elasticidades de 0,50 e 0,65 no curto e longo prazo para a variável densidade populacional e de -0,37 e -0,47 para o parâmetro relacionado à quantidade de pseudo-nós¹ existentes na região. Como esperado, a demanda por transporte público será maior em locais com maior densidade populacional e menos pseudo-nós, representando assim, um melhor cenário para caminhadas. Além disso, a magnitude dessas elasticidades confirma que as características de uso do solo têm potencial de influenciar a demanda por transporte público, com intensidade ainda maior que a tarifa, frequência do ônibus e a renda, sendo esses determinantes chaves na demanda por transporte público em Sydney.

¹ Pseudo-nós é uma medida de configuração da malha viária definida através das curvas e da quantidade de ruas sem saída da rede. Para exemplificar, redes em formato de grade possuem poucos pseudo-nós comparado à uma rede cheia de curvas e ruas sem saída.

Outra variável que pode gerar um efeito substancial na demanda é a taxa de desemprego. O número de passageiros por transporte público é diretamente impactado pela flutuação do cenário econômico e consequentemente pelas taxas de desemprego. Em casos em que o transporte público é considerado um bem inferior, este parâmetro possui efeito contrário ao da renda. Em contrapartida, quando isso não ocorre, a elasticidade da demanda com relação ao desemprego pode variar em torno de -0,60 para sistemas de ônibus e -0,35 para os trens (GOODWIN; WILLIAMS, 1985; CORDERA *et al.*, 2015).

A densidade urbana também é um parâmetro pouco estudado na literatura. Souche (2010) a define como a quantidade disponível de transporte, calculada através do quilômetros percorridos no transporte público per capita dividido pela área da cidade. Este parâmetro resultou em uma elasticidade da demanda de 0,40 no curto prazo. Assim, a autora aponta que o aumento na densidade urbana juntamente com o aumento do custo médio do automóvel e a redução do custo médio do usuário de transporte público estimulam o uso do modo coletivo.

Um último parâmetro destacado como importante na análise dos fatores que influenciam a demanda por transporte público é o preço da gasolina. Para Wang (2009), uma maior elasticidade no preço da gasolina, resulta em uma possibilidade maior de substituição do carro por modos coletivos. Como o autor comenta, a maior probabilidade de substituição dos modos ocorre na cidade de Canterbury – Nova Zelândia, onde a elasticidade do preço da gasolina é 0,28 no curto prazo e 0,37 no longo. Além disso, como destacam Fullerton Jr e Walke (2013), a elasticidade do preço da gasolina também é importante, pois o aumento no preço da gasolina gera oportunidade de aumentar a demanda por transporte público, já que estes são modos substitutos.

3 CARACTERIZAÇÃO DAS METRÓPOLES BRASILEIRAS EM ESTUDO

O detalhamento das informações referentes às metrópoles estudadas na pesquisa é efetivado no Capítulo 3, por meio primeiramente da descrição e análise dos principais parâmetros relativo às cidades, como população, dimensão geográfica e passageiros equivalentes transportados no sistema de ônibus urbano. Em um segundo momento, os sistemas de transporte das metrópoles são descritos a fim de caracterizar cada uma das cidades do ponto de vista dos transportes públicos urbanos, escopo desta pesquisa.

3.1 CARACTERÍSTICAS DAS METRÓPOLES

O estudo abrange as nove principais capitais brasileiras: Belo Horizonte - MG, Curitiba - PR, Fortaleza - CE, Goiânia - GO, Porto Alegre - RS, Recife - PE, Rio de Janeiro - RJ, Salvador - BA e São Paulo - SP. Essas cidades foram definidas pela disponibilidade de estudos anuais da Associação Nacional das Empresas de Transportes Urbanos – NTU realizados desde 1994 e do estudo de Carvalho e Pereira (2011) do Instituto de Pesquisa Econômica Aplicada – IPEA, que analisa a demanda por transporte público com relação à tarifa e renda no período de 1995 a 2008, para essas mesmas cidades.

As dimensões geográficas e populacionais dessas metrópoles têm características bem variadas. A Tabela 5 apresenta os dados de população e área, respectivamente, das capitais estudadas. Vale ressaltar que os dados de transporte disponíveis para Goiânia e Recife são os dados relativos às regiões metropolitanas que as envolvem. Dessa forma, os dados de população e área também foram coletados para o aglomerado urbano metropolitano. A região metropolitana de Goiânia é composta no período em estudo por quinze cidades: Abadia de Goiás, Aparecida de Goiânia, Aragoiânia, Bela Vista de Goiás, Bonfinópolis, Brazabrantes, Goiânia, Goianira, Guaporé, Hidrolândia, Nerópolis, Santo Antônio de Goiás, Senador Canedo, Terezópolis de Goiás e Trindade. Já no caso do Recife, a região metropolitana é composta por quatorze cidades, são elas: Abreu e Lima, Araçoiaba, Cabo de Santo Agostinho, Camaragibe, Igarassu, Ilha de Itamaracá, Ipojuca, Itapissuma, Jaboatão dos Guararapes, Moreno, Olinda, Paulista, Recife e São Lourenço da Mata.

Com relação à população, a Tabela 5 comprova a discrepância entre as proporções das cidades estudadas. Além disso, é possível observar que mesmo Recife e Goiânia sendo consideradas como região metropolitana, as cidades de São Paulo e Rio de Janeiro ainda são

as mais populosas, chegando a quase dez vezes mais em relação à população de Porto Alegre. As áreas estudadas também apresentam valores discrepantes com variação de até cinco vezes quando se relacionam as áreas das cidades de São Paulo e Fortaleza. Nesse parâmetro, as duas regiões metropolitanas se sobressaíram pela quantidade de municípios componentes e provavelmente pela menor densidade populacional nas outras cidades do aglomerado excedendo a capital.

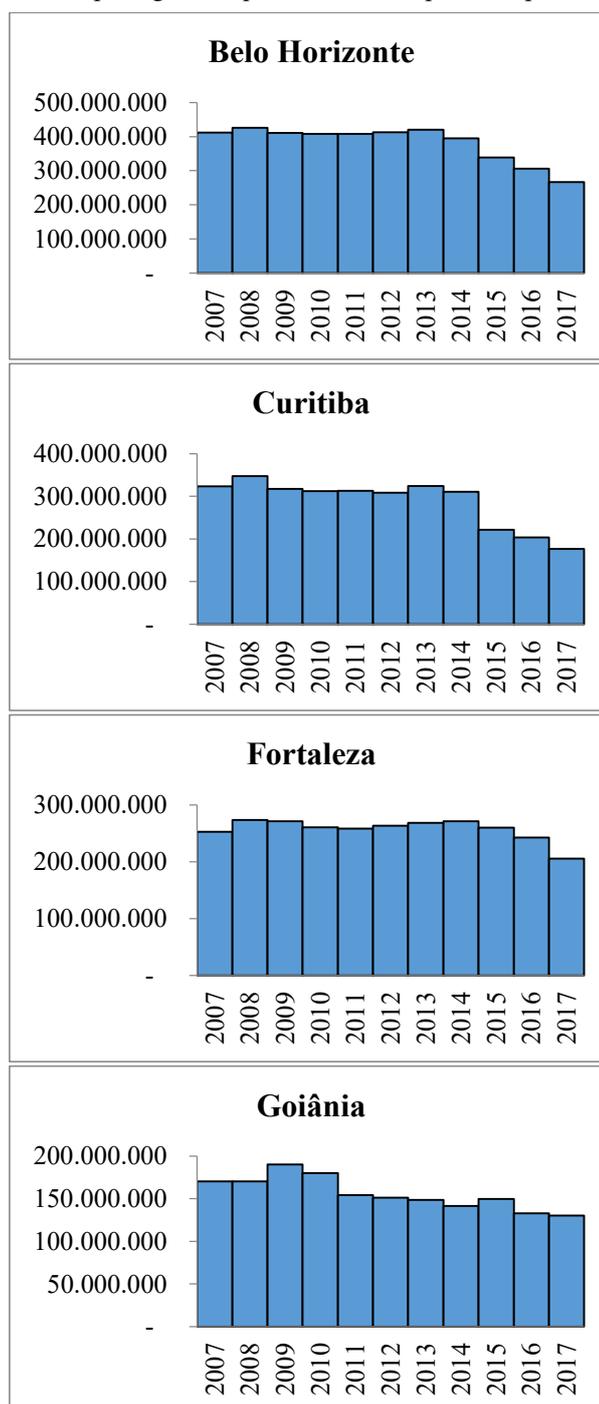
Tabela 5 – Dados das nove metrópoles brasileiras no ano de 2017

Metrópole	População	Área (km²)
Belo Horizonte	2.523.794	331,40
Curitiba	1.908.359	435,04
Fortaleza	2.627.482	314,93
Goiânia	2.411.877	5.981,74
Porto Alegre	1.484.941	496,68
Recife	3.965.699	2.770,45
Rio de Janeiro	6.520.266	1.200,28
Salvador	2.953.986	693,28
São Paulo	12.106.920	1.521,10

Fonte: a autora, 2018 [com dados do IBGE (2018)].

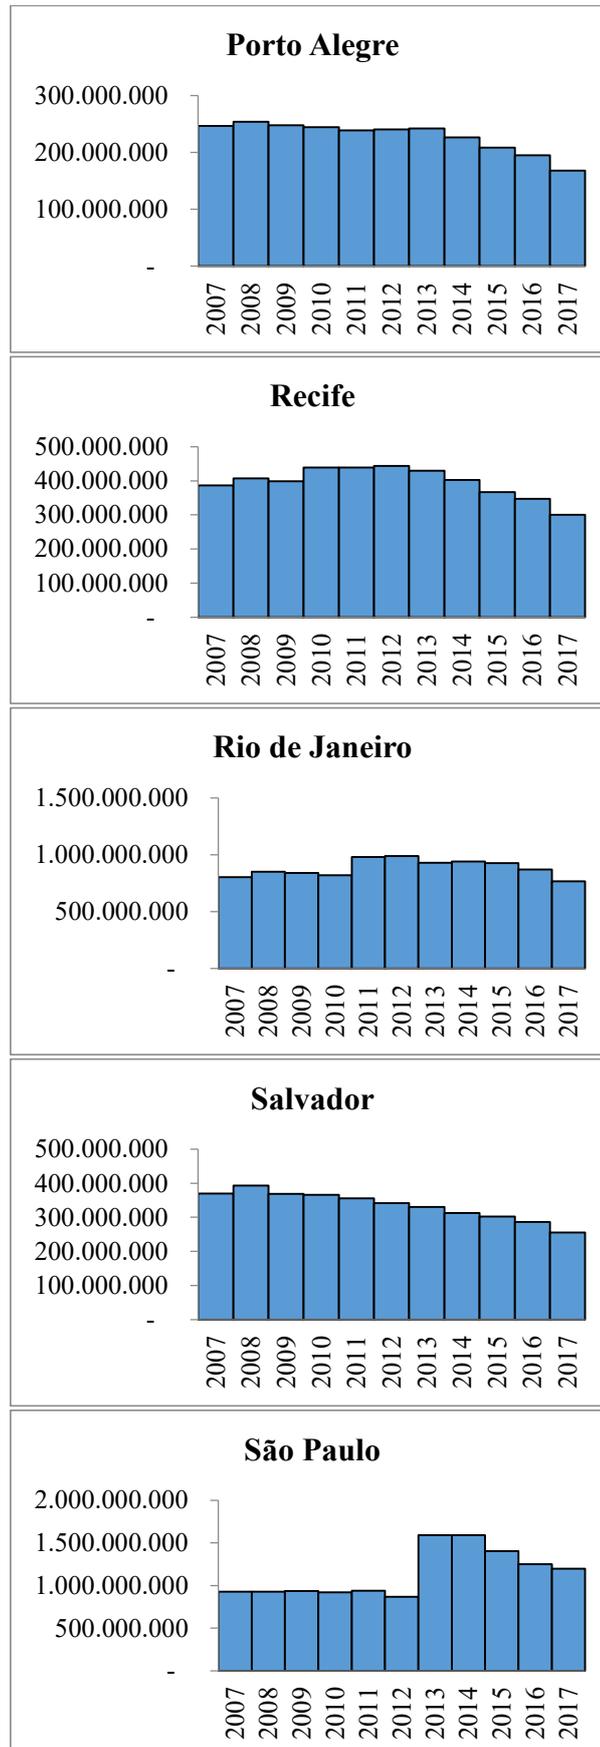
A quantidade de passageiros equivalentes transportados por ano no sistema de transporte público urbano por ônibus é apresentada nos Gráfico 1 e Gráfico 2, para cada uma das nove cidades. A quantidade demandada deste tipo de serviço nos últimos anos, aproximadamente a partir de 2014, vem diminuindo em todas as cidades estudadas. Por este motivo, a busca pelo entendimento dos fatores que podem estar causando essa queda é relevante para o cenário. A ressalva necessária a ser feita é sobre a quantidade demandada de transporte público em São Paulo, pois o salto existente no gráfico é resultado da mudança de metodologia de contabilização dos passageiros da cidade, por ter sido adicionado o sistema de ônibus alimentador a partir de 2013, fato melhor explicado nos itens 4.3 e 5.1.

Gráfico 1 – Quantidade de passageiros equivalentes² transportados por ano nas nove metrópoles



Fonte: a autora, 2018 [com dados da NTU (2018b)]

² Passageiro equivalente é a medida referente à proporção de passageiros que pagam a tarifa integral em um sistema com categorias variadas de desconto. Isto é, a quantidade de usuários que efetivamente pagam a tarifa integral do sistema de transporte público (ANTP, 2017).

Gráfico 2 – Quantidade de passageiros equivalentes transportados por ano nas nove metrópoles (continuação)

Fonte: a autora, 2018 [com dados da NTU (2018b)]

3.2 SISTEMAS DE TRANSPORTE PÚBLICO DAS METRÓPOLES

Os sistemas de transporte público urbano das metrópoles estudadas não são em sua totalidade compostos exclusivamente por ônibus urbanos. Por isso, esta seção tem como objetivo expor sinteticamente as características dos sistemas de transporte público das nove cidades.

3.2.1 Belo Horizonte

O sistema de transporte público de Belo Horizonte é composto por um sistema de ônibus urbanos convencionais, um sistema de BRT conhecido como MOVE, um sistema suplementar e uma linha de metrô. A BHTrans, Empresa de Transportes e Trânsito de Belo Horizonte, é a responsável pela gestão da concessão do serviço de transporte coletivo convencional de ônibus, incluindo o BRT (BELO HORIZONTE, 2018).

O transporte coletivo convencional e estruturante era composto em 2015 por aproximadamente 3.000 veículos operando em 293 linhas. O BRT-MOVE foi implantado em 2014 transportando em média 500 mil passageiros em um dia útil em 2015 por meio de 429 veículos. O sistema de transporte suplementar é composto por operadores autônomos que são regulamentados pela BHTrans e fazem a ligação entre os bairros sem adentrar na área central da cidade. O sistema possuía uma frota de 276 veículos em 2015 e realizou em torno de 50.000 viagens por mês (BELO HORIZONTE, 2017).

O metrô de Belo Horizonte é composto por uma linha de 28 quilômetros de extensão e liga a zona norte da cidade à oeste margeando a área central e chegando até o município de Contagem. A operação desta linha teve início em 1986 com 11 quilômetros de extensão. A linha de metrô em Belo Horizonte transporta cerca de 60 milhões de pessoas por ano o que equivale a 11% dos passageiros de transportes públicos da metrópole (CBTU, 2018b).

3.2.2 Curitiba

O sistema de transporte público de Curitiba é conhecido como Rede Integrada de Transporte Coletivo de Curitiba (RIT) e é totalmente composto por sistemas de ônibus. A RIT permite aos usuários o transbordo de uma linha de ônibus para outra com o pagamento de

apenas uma tarifa. Esta integração só é possível pela rede de terminais físicos, onde há o desembarque e embarque de várias linhas de ônibus. A empresa responsável pelo planejamento, regulação, o gerenciamento da operação e a fiscalização do sistema de transportes públicos de Curitiba é a Urbanização de Curitiba S.A. - URBS (URBS, 2018).

As linhas de ônibus de Curitiba são constituídas por nove categorias, são elas: expreso ligeirão, expreso, linha direta, interbairros, alimentador, troncal, convencional, circular e turismo. Essas linhas são atendidas por uma frota composta por 1.226 veículos no ano de 2018 (URBS, 2018). A operação distinta dessas categorias é feita através de eixos de transporte. A rede de transporte público é composta por eixos estruturantes, estruturantes metropolitanos, de ligação, troncais e interbairros. A grande diferença dos eixos estruturantes e de ligação para os outros eixos é a existência de canaletas ou faixas exclusivas. A rede integrada da cidade atende também à região metropolitana e transporta uma média de 2.225.908 passageiros/dia útil através de 355 linhas (CURITIBA, 2015).

3.2.3 Fortaleza

O sistema de transporte público de Fortaleza é composto por um Sistema Integrado de Transportes – SIT-FOR de ônibus e micro-ônibus e um sistema metroviário. O Sistema Integrado de Transportes opera linhas de ônibus do tipo radial e tronco-alimentadora e é composto por terminais de integração fechados nos bairros periféricos e abertos no área central da cidade. Os terminais fechados possibilitam o transbordo e integração entre as linhas componentes do sistema (FORTALEZA, 2018). O sistema é formado por 249 linhas normais e 22 linhas corujão com uma média de 19.331 viagens diárias (ANUÁRIO DE FORTALEZA, 2013). A empresa responsável pelo gerenciamento do serviço público e privado de transporte público é a Empresa de Transporte Urbano de Fortaleza S/A – ETUFOR (FORTALEZA, 2018).

O sistema de metrô de Fortaleza é composto por três linhas: Sul, Oeste e a linha do Veículo Leve sobre Trilho - VLT Parangaba-Mucuripe. A linha Sul possui 24 quilômetros de extensão e atende a 28.000 passageiros por dia. A linha Oeste é um pouco menor com 15,5 quilômetros e transporta em média 8.000 pessoas por dia. Essa linha foi remodelada no período de 2007 a 2010 e funciona com VLT. A linha de VLT Parangaba-Mucuripe tem projeto para 13,2 quilômetros de extensão, mas atualmente só funcionam aproximadamente 11 quilômetros (METROFOR, 2018).

3.2.4 Goiânia

O sistema de transporte público de Goiânia é conhecido como Rede Metropolitana de Transportes Coletivos – RMTC e abrange toda a região metropolitana de Goiânia. A RMTC é composta por agentes públicos e privados que são responsáveis pela prestação do serviço e por todas as questões referentes ao sistema de transporte público. A rede é composta por 293 linhas de ônibus que são integrados de forma física e tarifária, ou seja, podem existir transbordos tanto nos terminais de integração, como fora deles com uma mesma tarifa através de vários pontos de conexão eletrônica (RMTC, 2018).

O sistema viário é composto por rodovias, vias arteriais e vias secundárias. Nas rodovias circulam as linhas semiurbanas, responsáveis pela ligação entre as cidades. As linhas de eixo trafegam nas vias arteriais em que estão inseridos os corredores estruturantes da cidade, como por exemplo, os corredores Norte-Sul e Leste-Oeste. Por fim, nas vias secundárias trafegam as linhas alimentadoras, responsáveis pela ligação dos bairros periféricos ao sistema (RMTC, 2018).

3.2.5 Porto Alegre

O sistema de transporte público de Porto Alegre é composto por um sistema de ônibus e micro-ônibus, estes conhecidos como lotação, e é regulado pela Empresa Pública de Transporte e Circulação – EPTC. Em questão de números, o sistema é composto por 1.704 ônibus e 429 lotações e transportou em 2011 cerca de 1.100.000 passageiros nos dias úteis com 1.659 ônibus (PORTO ALEGRE, 2018).

O sistema de tarifação é feito através da bilhetagem eletrônica conhecida como Tri. Esse sistema de bilhetagem tem o intuito de integrar as linhas de ônibus para que os passageiros possam se locomover com transbordos pagando uma só passagem através da integração temporal, conhecida como passagem integrada. Com relação ao sistema de micro-ônibus, a operação é feita em 29 linhas e 18 desmembramentos e transportou em 2010 cerca de 57.000 passageiros por dia (PORTO ALEGRE, 2018).

3.2.6 Recife

O sistema de transporte público do Recife é composto por ônibus, BRT e metrô, o chamado de Sistema Estrutural Integrado – SEI. Pelo SEI, as linhas de ônibus, metrô e BRT estão integradas fisicamente através dos terminais e é possível através deles, fazer transbordos pagando uma única tarifa. A malha urbana da cidade do Recife é composta por eixos perimetrais e radiais e os terminais de integração foram alocados nos cruzamentos destes eixos. Nesse sistema existem cinco opções de linhas: alimentadora, troncal, perimetral, interterminal e circular (GRANDE RECIFE, 2018).

As alimentadoras são responsáveis por ligar os bairros periféricos ou subúrbios a um terminal integrado. A linha troncal transporta as pessoas do terminal integrado para a área central da cidade. A perimetral tem como objetivo fazer a ligação entre dois terminais pelos eixos perimetrais. A interterminal se diferencia da perimetral por atender as vias perimetrais e locais, tendo a função da perimetral associada com alimentadora. Por último, a linha circular tem o objetivo de atender a uma determinada área a partir de um terminal e retornar a ele. O sistema de ônibus do Recife é composto por 185 linhas com 123 alimentadoras, 3 perimetrais, 24 troncais, 18 interterminais, 6 transversais e 11 circulares, englobando assim toda a região metropolitana do Recife (GRANDE RECIFE, 2018).

O sistema de BRT, conhecido como BRT Via Livre, foi implantado em 2014. Esse sistema é composto por dois corredores: Norte/Sul e Leste/Oeste que englobam desde os municípios de Igarassu e Camaragibe até o centro da cidade (GRANDE RECIFE, 2018). Com relação ao metrô, o sistema é composto por 70,4 quilômetros, sendo 39,4 quilômetros eletrificados e 31,0 não eletrificados com o diesel como combustível. Esse sistema transporta 245.000 passageiros por dia útil e possui 36 estações (CBTU, 2018b).

3.2.7 Rio de Janeiro

O sistema de transporte é composto por metrô, ônibus, BRT, VLT e um sistema local. O sistema metroviário conhecido como MetrôRio, atualmente dispõe de 41 estações com 14 pontos de integração tarifária física com os outros sistemas divididas em três linhas (METRORIO, 2018). O sistema de ônibus é operado por 36 empresas associadas através do Sindicato das Empresas de Ônibus da Cidade do Rio de Janeiro – Rio Ônibus (RIO ÔNIBUS, 2018).

O sistema de BRT, por sua vez, transporta 450.000 passageiros por dia através de 125 quilômetros de faixas segregadas com uma frota de 440 ônibus articulados. As três linhas implantadas são conhecidas como TransOeste, TransCarioca e TransOlímpica e são operadas por meio de quatro categorias de veículos: expresso, parador, direto e semidireto. O sistema de transportes público no Rio de Janeiro possui integração tarifária através do Bilhete Único Carioca. Dessa forma, o BRT pode ser integrado com os outros meios de transporte por intermédio tanto das integrações físicas, como da tarifária por meio do bilhete. Isso é possível não somente entre o BRT e os outros modos, mas entre todos os modos públicos (BRTRIO, 2018).

O VLT, implantado em 2016, é responsável pelo transporte de passageiros, em sua maioria na região central do Rio de Janeiro. Com este sistema, é possível unir os pontos principais da área central e da região portuária, como no passado com a existência dos bondes elétricos. Além disso, o VLT também está próximo de trens, metrô, porto, ônibus e do Aeroporto Santos Dumont, havendo assim uma possibilidade de integração com os outros modos (VTLRIO, 2018).

Por fim, o sistema complementar existente na cidade se chama Sistema de Transporte Público Local do Rio de Janeiro – STPL. Este meio tem como objetivo complementar o sistema de transporte por ônibus através de veículos menores, de 8 a 16 lugares, que atendam às necessidades da população. Esta ligação prioritariamente deve ser feita para conectar os bairros próximos ou atender à carência de um serviço interno em determinado bairro. O serviço complementar é regulamentado e vistoriado pela Secretaria Municipal de Transportes (RIO DE JANEIRO, 2018).

3.2.8 Salvador

O sistema de transporte público de Salvador é composto por ônibus, metrô, trens e o elevador Lacerda. O Sistema de Transporte Coletivo por Ônibus de Salvador é operado por três concessionárias com um total de 358 linhas regulares e mais de 2.032 quilômetros de extensão da rede viária urbana atendida pelo serviço. Os passageiros transportados por este sistema no ano de 2017 foram em torno de 400 milhões de pessoas através de uma frota aproximada de 2.550 ônibus (SALVADOR, 2018).

O Elevador Lacerda possui uma quantidade demandada média mensal de 409.000 pessoas com capacidade de 32 passageiros por viagem. Além deste modo, outros funiculares fazem parte do sistema de Salvador, são eles: Plano Inclinado Pilar, Plano Inclinado

Gonçalves e Plano Inclinado Liberdade-Calçada. Já o metrô possui duas linhas com 19 estações no total e atendeu a uma demanda de aproximadamente 42 milhões de pessoas no ano de 2017. Por último, o trem que atende ao sistema de transportes de Salvador possui 10 estações e teve uma demanda de 3.208.105 passageiros no ano de 2017 por intermédio de aproximadamente 10.000 viagens diárias (SALVADOR, 2018).

3.2.9 São Paulo

O sistema de transporte público de São Paulo é composto por ônibus, metrô e trem urbano. As linhas de ônibus são operadas por empresas privadas gerenciadas pela entidade conhecida como São Paulo Transporte S.A. – SPTrans. Os consórcios das empresas de ônibus são divididos em dois subsistemas: local e estrutural com uma operação de 15 mil veículos em mais de 1.300 linhas. O subsistema estrutural tem o objetivo de atender altas demandas através de veículos maiores de médio e grande porte, como os ônibus articulados, biarticulados e comuns. Além disso, esse subsistema integra as grandes regiões da cidade ao centro, sendo esta a espinha dorsal do transporte coletivo por ônibus (SPTRANS, 2018).

O subsistema local tem como intuito atender aos deslocamentos internos nas regiões ou subcentros através de ônibus menores, como os ônibus comuns, micro-ônibus e mini-ônibus. Dessa forma, esse subsistema é responsável por alimentar o subsistema estruturante. Além desses subsistemas da cidade de São Paulo, o sistema metropolitano de ônibus é responsável por ligar a cidade às demais regiões do aglomerado urbano. Essa rede é composta por linhas comuns operadas por empresas privadas, um corredor intermunicipal com faixa segregada e linhas estruturantes de ônibus e trólebus e um serviço especial para atender à demanda do Aeroporto Internacional de Guarulhos. A bilhetagem eletrônica engloba os sistemas de ônibus, micro-ônibus, metrô e trens metropolitanos (SPTRANS, 2018).

O sistema metroviário é operado pela Companhia do Metropolitano de São Paulo – Metrô e controlada pelo Governo do Estado através da Secretaria de Estado dos Transportes Metropolitanos (STM) e é responsável pelo transporte de pessoas da região metropolitana de São Paulo. A rede é composta por seis linhas com 96 quilômetros de extensão e 84 estações com algumas integrações com o sistema de trens metropolitanos. O Metrô São Paulo opera quatro linhas totalizando cerca de 65 quilômetros e 58 paradas. As outras duas linhas são pela empresa Via Quatro desde 2010 e Via Mobilidade, a partir de 2018. A rede metroviária transporta diariamente cinco milhões de pessoas, atingindo anualmente 1,3 bilhão em todas as linhas e 1,1 bilhão somente nas linhas do Metrô São Paulo (METRO SÃO PAULO, 2018).

A Companhia Paulista de Trens Metropolitanos – CPTM é responsável pelos trens da região metropolitana de São Paulo desde quando assumiu a operação da Companhia Brasileira de Trens Urbanos - CBTU e da Ferrovia Paulista S/A – FEPASA. A rede é composta por oito linhas, sendo uma delas o Expresso Turístico. Neste sistema, em 2017, foram transportados 827,7 milhões de passageiros na sua extensão de aproximadamente 261 quilômetros e 92 estações (CPTM, 2018).

4 METODOLOGIA DA PESQUISA

A metodologia proposta visa avaliar o comportamento da demanda por transporte público através de fatores econômicos. Para tal fim, um procedimento econométrico é definido por meio da teoria econômica estudada juntamente com as metodologias aplicadas nos estudos de referência sobre a demanda por transporte público e a disponibilidade dos dados necessários para a validação do modelo proposto.

A estruturação desta metodologia de análise dos parâmetros influenciadores da demanda estudados no referencial teórico é fundamental para a construção das variáveis essenciais ao modelo e disponíveis no cenário brasileiro em estudo. Além disso, a forma em que os dados estão disponíveis para uma pesquisa de dimensão nacional também afeta a escolha das variáveis explicativas devido ao fator agregação. No caso desta análise, os dados de transporte para as nove principais cidades brasileiras estudadas foram disponibilizados agregados por ano, sendo alguns tipos de parâmetros indisponíveis na escala anual.

Da mesma maneira, a função de regressão com resultado mais adequado é obtida por meio de diversas tentativas, pelo fato de não existir a definição do modelo mais pertinente para determinada situação. A definição da função depende sempre da qualidade e tipo dos dados, do método de regressão escolhido e dos critérios estatísticos referentes à significância do modelo. Deste modo, a sistemática metodológica foi dividida em seis etapas para detalhar o desenvolvimento, são elas:

1. Pesquisa dos estudos de referência para definição dos valores das elasticidades da demanda por transporte público;
2. Caracterização das principais variáveis presentes nos estudos e quais serão testadas e utilizadas nesta dissertação através também do conhecimento da existência dos dados;
3. Busca de dados em painel das principais cidades brasileiras para composição do escopo do estudo;
4. Definição do modelo de estimativa da demanda de acordo com os dados secundários e com a literatura e;
5. Aplicação do modelo de previsão para a estimativa das elasticidades das principais cidades brasileiras e análise das características da demanda agregada no país;
6. Teste de hipóteses para validação da função de regressão obtida através dos dados estudados.

Como síntese da metodologia, a Figura 1 exibe um fluxograma detalhando a sequência de atividades e a relação entre elas. Dessa forma, é possível obter uma visão geral do procedimento adotado e entender melhor a apresentação desta seção. Nas fases de aplicação do modelo e teste de hipóteses, é importante ressaltar que para cada método, possibilidade de regressão, tipo de painel e variáveis escolhidas o ciclo se repete com uma nova função de regressão obtida e novos testes de hipóteses até a obtenção do resultado com as melhores propriedades.

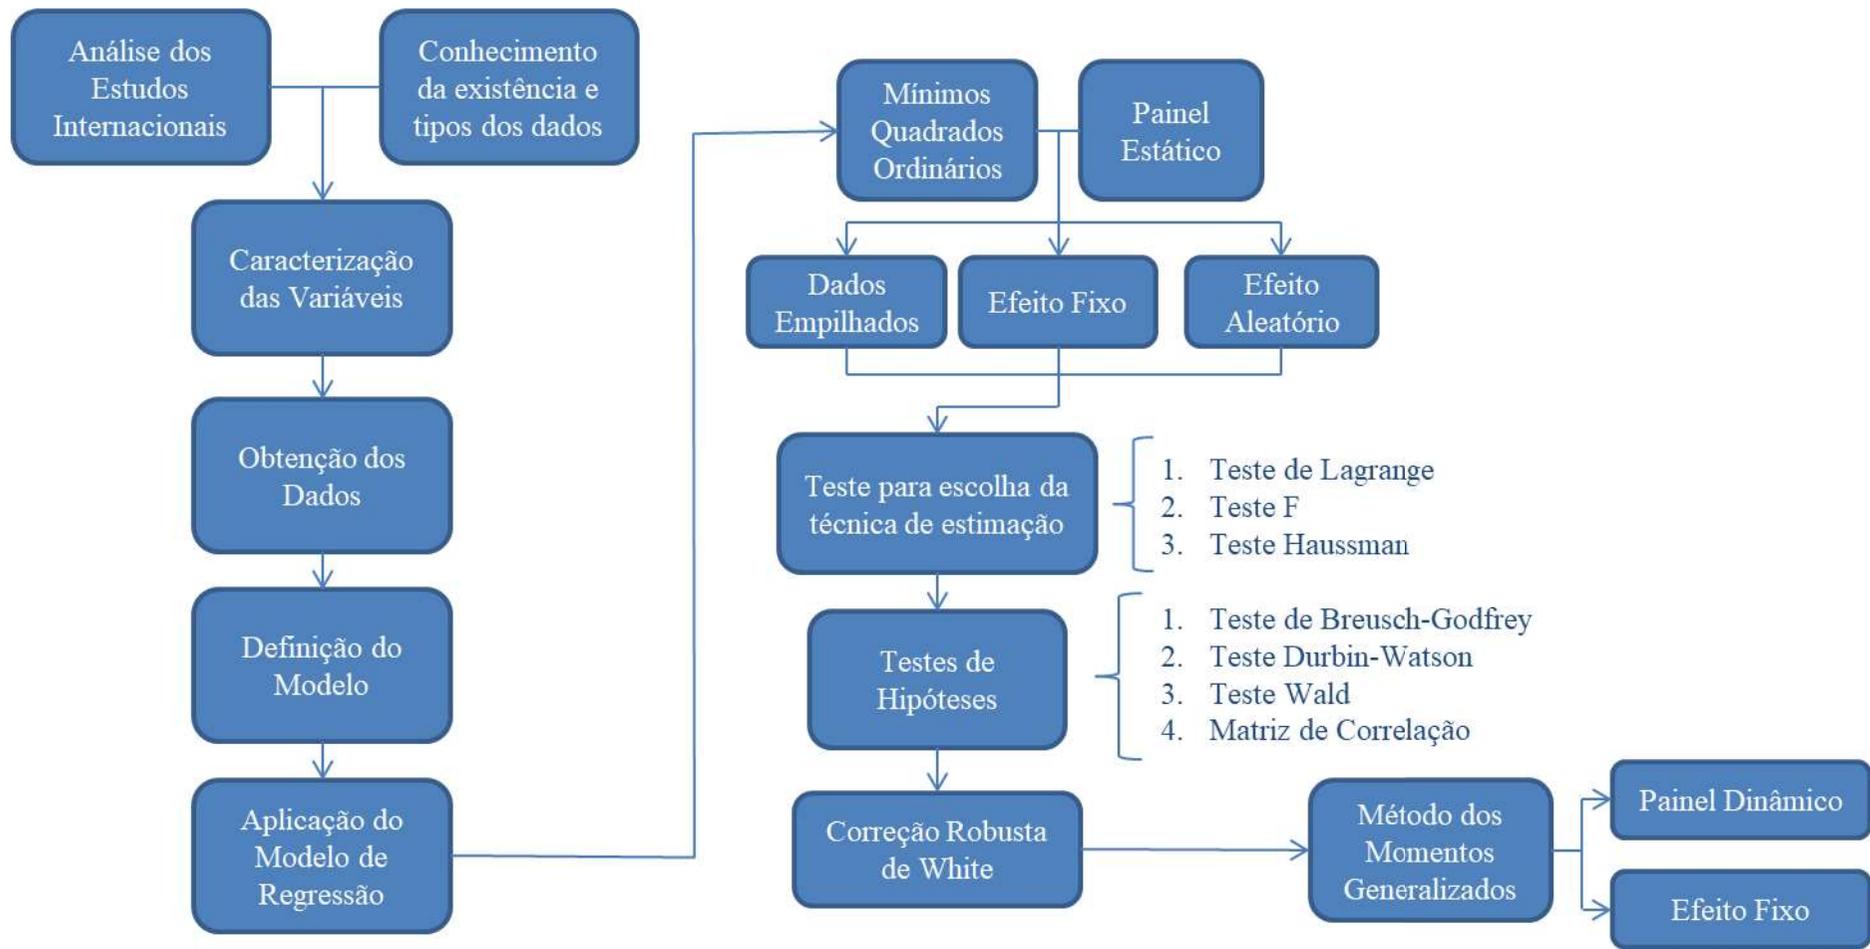


Figura 1 – Fluxograma da Metodologia de Pesquisa

Fonte: Elaboração própria.

4.1 SÍNTESE DOS ESTUDOS E LINHA DE CONDUÇÃO

A análise dos estudos sobre o tema tem como ponto de partida o guia prático de Balcombe *et al.* (2004) para direcionamento das principais variáveis estudadas ao longo dos anos e a definição dos valores relevantes das elasticidades de alguns desses parâmetros já mundialmente estudados. Esse texto é resultado da atualização das informações existentes e dos objetivos de estudo sobre o controle da flutuação da demanda por transporte público no mundo, mas principalmente para melhoria dos sistemas ingleses.

A origem desse guia são as publicações de Webster e Bly (1981; 1982) que exploraram os efeitos dos principais fatores que influenciavam a demanda por transporte público no mundo. A motivação para este primeiro estudo foi o cenário de decadência do transporte público na Inglaterra, no qual a estratégia de aumentar as tarifas e reduzir a qualidade para se obter mais lucro para os empresários não estava mais dando resultado.

A partir destas três referências, o primeiro passo foi agrupar em torno delas mais dez publicações com relevância no tema, que abrangessem as variáveis explicativas mais utilizadas e que têm representação na função de regressão e nos modelos econométricos que melhor se aplicam às funções de demanda. A Tabela 6 apresenta as onze publicações pesquisadas e analisadas na primeira etapa. Com a compilação dos resultados desses estudos, a busca por outras pesquisas foi feita através do direcionamento dessas referências e pesquisas na base de dados Scopus, a fim de aumentar o alcance das referências da pesquisa e buscar pesquisas mais recentes publicadas ao longo deste estudo.

Tabela 6 – Publicações relevantes no tema

Nº	Autores
1	Bresson <i>et al.</i> (2003)
2	Paulley <i>et al.</i> (2006)
3	Holmgren (2007)
4	Hensher (2008)
5	Souche (2010)
6	De Grange <i>et al.</i> (2013)
7	Holmgren (2013)
8	Tsai <i>et al.</i> (2014)
9	Cordera <i>et al.</i> (2015)
10	Daldoul <i>et al.</i> (2016)
11	Rahman e Balijepalli (2016)

Fonte: a autora, 2018.

A segunda parte da pesquisa bibliográfica foi buscar publicações e autores referências no tema, relacionados com os doze textos iniciais para alicerçar os parâmetros e as

elasticidades discutidas nos textos. Em adição, os modelos de regressão, funções e testes de hipóteses também foram extraídos dos textos, como apresentado na seção 2.4, para embasar as decisões tomadas referentes ao modelo estudado. A busca por estudos publicados ao longo da pesquisa também fez parte desta etapa, visto que a análise da demanda por transporte público em países em desenvolvimento é um tema discutido atualmente, o que gera consequentemente publicações recentes relevantes para esta pesquisa.

Em suma, o objetivo desta etapa foi extrair os conceitos das principais variáveis presentes nos estudos, compilar as elasticidades estudadas e compará-las de acordo com o cenário brasileiro. Além disso, o intuito é buscar os modelos econométricos, funções de regressão e testes de hipóteses utilizados nas análises de demanda por transporte público e analisar as consequências dos valores obtidos em cada estudo e os possíveis fatores relevantes para o cenário brasileiro.

4.2 CARACTERIZAÇÃO DAS VARIÁVEIS

A caracterização das variáveis foi desenvolvida com base em três aspectos. Primeiro, as variáveis foram determinadas de acordo com as publicações estudadas. Em segundo ponto, a teoria econômica da demanda também tem potencial de direcionar quais as principais variáveis da regressão. O terceiro aspecto é relativo à disponibilidade e características dos dados, visto que o resultado da regressão também é relacionado pelo tipo de dado inserido no modelo, gerando restrições ou variações na função de regressão resultante.

Através das publicações analisadas, as variáveis descritas são extraídas e avaliadas a partir da quantidade de vezes que cada uma está sendo estudada e a importância que elas têm em influenciar na variação da demanda. Além disso, os estudos também trazem informações sobre a utilização de cada variável em decorrência do tipo de dado disponível, pois como evidencia Wardman (2014), a qualidade dos dados e da análise influencia diretamente na precisão da estimativa. Desta forma, é importante extrair das referências às elasticidades, entendendo os tipos de dados que foram usados e as análises que foram feitas.

Quanto ao segundo aspecto, a função de demanda é resultado do comportamento da curva de demanda que relaciona o preço de um bem com a quantidade que as pessoas estão dispostas a consumir dele. Assim, os consumidores tendem a comprar mais à medida que o preço diminui, também surgindo novos consumidores quando existe este comportamento do preço. Porém, outros fatores também podem induzir a disposição das pessoas em comprar. A renda é, então, um exemplo especialmente importante que afeta a demanda de maneira que o

aumento dela, mesmo com preço mantido, gera uma tendência de maior gasto das pessoas (PINDYCK; RUBINFELD, 2015). Sendo assim, este aspecto torna indispensável à inserção do preço, ou seja, da tarifa e da renda na função de regressão do modelo, definindo assim, as duas primeiras variáveis teóricas do modelo.

Por último, o terceiro aspecto refere-se à disponibilidade e às características dos dados. Esse aspecto é o último por ser determinante na caracterização das variáveis, pois mesmo existindo diversos estudos para um tipo de variável importante, a não existência dos dados disponíveis para o grau de agregação, período e indivíduos do estudo acarretará na exclusão dessa variável. Ao mesmo tempo, algumas variáveis mesmo existentes, podem não apresentar as tendências semelhantes aos estudos na regressão pela razão das características dos dados obtidos. Este é um motivo para a exclusão de várias variáveis ditas relevantes na função de regressão da demanda por transporte público.

O único parâmetro que não se encaixa nos três aspectos elencados é a variável Uber. Uber é um aplicativo de *smartphone* que presta um serviço de transporte privado por meio da intermediação entre os passageiros que buscam se locomover e os motoristas cadastrados no sistema. Como este é um serviço relativamente barato, comparado ao táxi, e com a vantagem de um trajeto direto entre o local de partida e o destino final, este está sendo um meio de transporte que cresce rapidamente no Brasil, atualmente operando em todas as nove metrópoles estudadas. Com isso, esperou-se com a utilização desta variável verificar se este meio de transporte pode ser considerado substituto do sistema de transporte público, ou seja, se os passageiros estão escolhendo o Uber ao invés do transporte público convencional. Como não existem dados disponíveis dos passageiros transportados no Uber ou da frota de motoristas operantes em cada uma das cidades, a solução foi criar uma variável *dummy* que indica a operação ou não do Uber em cada cidade no determinado ano, como pode ser constatado no Apêndice A.

4.3 OBTENÇÃO E ANÁLISE DO BANCO DE DADOS

Os dados da pesquisa são determinantes no desenvolvimento e grau de explicação do modelo econométrico. Os dados necessários para análise foram levantados em sua totalidade a partir de fontes oficiais, sendo esses dados secundários. A elaboração do painel de dados ocorreu pela união e tratamento de quatro fontes nacionais de dados: Instituto Brasileiro de Geografia e Estatística – IBGE, Associação Nacional das Empresas de Transportes Urbanos –

NTU, Departamento Nacional de Trânsito – DENATRAN e Agência Nacional do Petróleo, Gás Natural e Biocombustíveis – ANP.

Os dados populacionais, geográficos e econômicos foram coletados do banco de dados oficial do IBGE (2018), sendo este responsável pelos seguintes parâmetros: população, área e rendimento médio nominal mensal de todos os trabalhos, esse obtido através da Pesquisa Nacional por Amostra de Domicílios (PNAD). Os dados operacionais de transporte público, cedidos pela NTU (2018b), são: passageiros equivalentes transportados anualmente por ônibus urbanos, tarifa principal, quilometragem anual percorrida pelos ônibus urbanos, idade média da frota, índice de passageiros equivalentes por quilômetro e frota total de ônibus urbanos. Já os dados coletados no site oficial do DENATRAN (2018) foram relacionados à frota de veículos total e por categoria, por exemplo, automóvel e motocicleta. Por fim, os dados provenientes da ANP (2018) dizem respeito à série histórica do levantamento de preços e de margens de comercialização de combustíveis para serem extraídos os preços de gasolina e diesel nos anos do estudo.

4.3.1 Análise de dados em painel

Os dados em painel são um tipo especial de dados combinados em que existe uma associação de dados em corte transversal com série temporal. Este tipo de dado é atualmente muito utilizado pela possibilidade de se ter mais dados disponíveis, do que os dois tipos anteriores isolados, uma maior variabilidade na amostra, pois diversifica com o tempo e com o indivíduo, tendo assim, uma maior precisão dos parâmetros estimados na função regressão. Além disso, devido a maior variabilidade, os dados em painel tendem a ter uma maior heterogeneidade nas unidades e menor colinearidade entre as variáveis (RAHMAN; BALIJEPALLI, 2016).

Os dados em painel podem examinar melhor as mudanças ocorridas ao longo do tempo para diversos indivíduos relacionados, detectar alguns efeitos não encontrados em cortes transversais e séries temporais puras e minimizar o viés de dados agregados de indivíduos. Para que isso aconteça, os dados em painel permitem que a variável dependente seja explicada por dois meios: pelas variações nas variáveis independentes e pelos fatores não observados ao longo do tempo que também afetarão na regressão (RAHMAN; BALIJEPALLI, 2016).

No estudo dos dados em painel, existem duas possibilidades de função de regressão: o painel estático e o dinâmico. A função de regressão para dados em painel estático simples

está apresentada na Equação 1, em que o subscrito i representa a unidade de corte transversal do painel e o subscrito t representa o período de tempo. O erro está representado pela variável u_{it} e configura dois aspectos: o efeito individual ou heterogeneidade individual (α_i) e o termo de erro independente ou idiossincrático (ε_{it}). A configuração do painel estático é muito próxima da função de regressão linear mais simples, sendo a maior diferença a composição do termo do erro (WOOLDRIDGE, 2001).

$$Y_{it} = \beta_0 + \beta_1 X_{it} + u_{it}, \quad u_{it} = \alpha_i + \varepsilon_{it} \quad (1)$$

Com relação ao painel dinâmico, a grande diferença é a existência da variável dependente defasada em um período de tempo como variável explicativa. A Equação 2 representa uma função de regressão de um painel dinâmico, em que λ é a velocidade de ajuste da variável dependente e $Y_{i,t-1}$ é a variável dependente defasada no tempo. Um dos benefícios de estimar o painel dinâmico é a possibilidade de definição das elasticidades não só no curto, mas também no longo prazo através da variável dependente defasada. Por meio da regressão linear ou múltipla log-log, é possível obter diretamente as elasticidades de cada variável explicativa no curto prazo, visto que o valor do parâmetro β é a própria elasticidade. A elasticidade no longo prazo é obtida através da divisão de cada elasticidade do curto prazo por $(1 - \lambda)$ (GOODWIN, 1992; BRESSON *et al.*, 2003; TSAI *et al.*, 2014).

$$Y_{it} = \beta_0 + \lambda Y_{i,t-1} + \beta_1 X_{it} + \beta_2 X_{it} + u_{it} \quad (2)$$

Para regressão da Equação 2, a escolha da técnica de estimação utilizada deve ser feita. A decisão entre as técnicas de estimação conhecidas como modelo de efeito fixo e aleatório é definida por meio do erro conhecido como efeito individual (α_i) que terá sua característica estabelecida como fixo ou aleatório. No caso do efeito fixo, a parcela do erro α_i é analisada como um fator que será estimado para cada observação da seção transversal (WOOLDRIDGE, 2001).

Outras técnicas utilizadas são através da utilização do método dos Mínimos Quadrados Ordinários (MQO) com dados empilhados (em inglês, *pooled data*), sendo a regressão feita pela junção ou empilhamento de todas as observações sem diferenciar a natureza do corte transversal ou da série temporal. E a utilização de variáveis dummies para

definir as unidades de corte transversal, chamada de modelo de mínimos quadrados com variáveis dummies para efeitos fixos (WOOLDRIDGE, 2001).

Apesar da existência das quatro possibilidades de estimação de dados em painel, a maior utilização ocorre nas duas últimas, o modelo de efeitos fixos e aleatórios. A principal diferença entre os dois modelos é a forma que o termo de erro relacionado à heterogeneidade é tratado. O modelo de efeito fixo considera que a heterogeneidade individual está correlacionada com os regressores, enquanto o modelo de efeito aleatório não considera esta correlação (RAHMAN; BALIJEPALLI, 2016).

Como também explica Bresson *et al.* (2003), a utilização de modelos de efeito fixo, aleatório ou até o mais simples com dados empilhados é comum na literatura clássica para dados em painel. Os autores também expõem na forma de equação a diferença entre os modelos fixos e aleatórios, já que a variação ocorre na consideração do tipo de efeito da heterogeneidade individual. As Equações 3 e 4 apresentam, respectivamente, a posição do efeito heterogêneo nos modelos fixos e aleatórios, onde o primeiro se comporta como um fator do intercepto e o segundo como um termo do erro.

$$Y_{it} = (\alpha_i + \beta_0) + \lambda Y_{i,t-1} + \beta_1 X_{it} + \beta_2 X_{it} + \varepsilon_{it} \quad (3)$$

$$Y_{it} = \beta_0 + \lambda Y_{i,t-1} + \beta_1 X_{it} + \beta_2 X_{it} + (\alpha_i + \varepsilon_{it}) \quad (4)$$

Em adição, Bresson *et al.* (2003) expõem que a decisão pela utilização de modelos com efeito fixo ou aleatório passa principalmente pela escolha do economista em conceber a inferência segundo as características da população ou os efeitos da amostra. Porém, os autores acreditam que nas regressões não seria mais necessário escolher entre estes dois métodos para painel dinâmico. Eles argumentam que já existe uma maneira eficiente de estimação com o método através de variáveis instrumentais que elimina os efeitos fixos e aleatórios do termo do erro, conhecido como o estimador do método dos momentos generalizados (da sigla em inglês, GMM) ajustado por Arellano e Bond (1991).

4.4 DEFINIÇÃO DO MODELO

A definição do modelo econométrico para estimativa da função de demanda sucedeu com base na literatura analisada, através dos modelos já utilizados e das características dos dados secundários obtidos. Como indica Souche (2010), a estimação dos coeficientes

desconhecidos do modelo de regressão é sempre feita inicialmente através do método dos mínimos quadrados ordinários. Assim, o método definido inicialmente para a determinação da função de regressão foi o MQO, pela sua simplicidade de definição e complexidade econômica.

A função de regressão populacional (FRP) é definida a partir da função de regressão amostral (FRA), sendo esta uma representação mais próxima possível da população. Os métodos utilizados para a estimação da função amostral tem a finalidade de entender os efeitos que a alteração de uma ou mais variáveis geram no fator estudado, sendo os dois mais conhecidos o método dos mínimos quadrados e o método de máxima verossimilhança. O primeiro deles é o mais utilizado em análises de regressão por ser simples matematicamente, mas robusto na teoria econômica relacionada e também por ter propriedades estatísticas que o torna um método bastante difundido e eficaz (PINDYCK; RUBINFELD, 2004; GUJARATI; PORTER, 2011).

Para definição do princípio do método dos mínimos quadrados, é necessário apresentar a expressão da função de regressão populacional e amostral nas Equações 5 e 6 respectivamente. Pois, a estimativa do comportamento da população é feita através dos resíduos da função de regressão amostral, sendo \hat{Y}_i a média condicional de Y_i . Assim, pode-se extrair os resíduos da função de regressão amostral, sendo esses, resultado da diferença entre os valores observados (Y) e os valores estimados (\hat{Y}), conforme mostrado na Equação 7 (GUJARATI; PORTER, 2011).

As suposições que fazemos sobre como os inobserváveis são relacionados às variáveis explicativas $X_1; X_2; \dots; X_g$ são cruciais para determinar quais estimadores do β_g possuem propriedades aceitáveis. Muitas vezes, quando o sistema representa um modelo estrutural (sem variáveis omitidas, erros-em-variáveis ou simultaneidade), podemos assumir que u_g não está correlacionado com as variáveis explicativas em todas as equações, assim como todas as funções dessas variáveis explicativas (WOOLDRIDGE, 2001)

$$Y_i = \beta_1 + \beta_2 X_i + u_i \quad (5)$$

$$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_i + \hat{u}_i = \hat{Y}_i + \hat{u}_i \quad (6)$$

$$\hat{u}_i = Y_i - \hat{Y}_i = Y_i - \hat{\beta}_1 + \hat{\beta}_2 X_i \quad (7)$$

Com os dados disponíveis para determinar a função amostral, o propósito é buscar uma expressão que se aproxime ao máximo dos dados observados. Para isso, faz-se necessário que a soma dos resíduos obtidos na Equação 7, seja a menor possível. Porém, para que se consiga obter a mesma importância para resíduos de dimensões e direções diferentes, o método dos mínimos quadrados propõe o critério da soma dos resíduos elevados ao quadrado, para evitar o problema de que erros com sentidos diferentes se anulem e reduzam a soma algébrica para próximo de zero, disfarçando o melhor resultado. Assim, a função de regressão amostral será modificada para a Equação 8, considerando, dessa forma, o somatório dos resíduos elevados ao quadrado o menor possível. Em suma, com os resíduos elevados ao quadrado, é possível atribuir mais pesos em resíduos mais dispersos ao contrário da simples soma dos resíduos, que pode ser baixa mesmo existindo uma dispersão alta, já que resíduos com direções contrárias podem se anular (PINDYCK; RUBINFELD, 2004; GUJARATI; PORTER, 2011).

$$\sum \hat{u}_i^2 = \sum (Y_i - \hat{Y}_i)^2 = \sum (Y_i - \hat{\beta}_1 + \hat{\beta}_2 X_i)^2 = f(\hat{\beta}_1, \hat{\beta}_2) \quad (8)$$

Na análise de regressão linear, a estrutura básica é fundamentada em um conjunto de hipóteses, discutidas adiante no item 4.6, e chamada de modelo clássico de regressão linear (MCRL). A partir das hipóteses do estudo econométrico, os estimadores de mínimos quadrados são definidos como os melhores estimadores não viesados (MELNT). Isto porque, os estimadores devem ser não tendenciosos, consistentes, lineares e produzir estimativas com a menor variância dentre todos os estimadores lineares não tendenciosos, baseado no Teorema de Gauss-Markov. A definição da precisão dos estimadores e da qualidade de ajustamento do modelo é medida pelos seus erros padrões e pelo coeficiente de determinação (r^2), respectivamente. O coeficiente de determinação expõe quanto a variável explanatória explica o aumento ou a redução na variável dependente (PINDYCK; RUBINFELD, 2004; GUJARATI; PORTER, 2011).

Através das funções de regressão populacional e amostral em sua forma mais simples, para uma variável dependente e uma variável explanatória, é possível expandir a expressão para as situações mais comuns em que não existe só uma variável explanatória. A Equação 9 exemplifica uma regressão linear com uma variável dependente (Y) e duas variáveis explanatórias (X_2 e X_3). Como no caso anterior, u é o termo estocástico, β_1 é o intercepto, o ponto onde os valores de X são iguais à zero, β_2 e β_3 são os coeficientes parciais

da regressão e i é o indicador da observação da amostra. Quando a amostra for um corte transversal, o i será o indivíduo em questão, ao contrário de séries temporais, em que o indicador expresso será o t que seria o período de cada ponto estudado. Para dados combinados, os dois subscritos aparecem na Equação 7 (PINDYCK; RUBINFELD, 2004; GUJARATI; PORTER, 2011).

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i \quad (9)$$

Do mesmo modo que na regressão com duas variáveis, a regressão múltipla é relacionada aos valores amostrais dos regressores, ou seja, de X_2 e X_3 , para a obtenção do valor esperado de Y , como mostrado na Equação 10. Assim, os coeficientes parciais da regressão medirão neste caso, a variação no valor médio de Y por unidade de variação em uma variável independente, mantendo a outra constante. Ou seja, os β_2 e β_3 são os efeitos diretos de cada variável explanatória isoladamente sobre o valor médio de Y (PINDYCK; RUBINFELD, 2004; GUJARATI; PORTER, 2011).

$$E(Y_i | X_{2i}, X_{3i}) = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} \quad (10)$$

Outro ponto importante é a medição da qualidade de ajustamento da equação de regressão. Como visto para a equação com duas variáveis, o r^2 fornece o percentual de explicação da mudança da variável dependente, causada pela variável explicativa. No caso de mais de um regressor, a qualidade de ajustamento é a medida da proporção de explicação da variação de Y causada por todas as variáveis explicativas. Sendo assim, a denominação dada é o coeficiente de determinação múltiplo, caracterizada por R^2 . Um destaque deve ser dado a uma especificidade do coeficiente R^2 , em que com o aumento do número de variáveis explanatórias, aumenta também o seu valor, com exceção de variáveis perfeitamente colineares. Uma forma de avaliar a melhoria da função pela adição da variável sem ter a influência dessa propriedade é a utilização do R^2 ajustado, sendo esse o resultado do ajuste do R^2 pelos graus de liberdade (PINDYCK; RUBINFELD, 2004; GUJARATI; PORTER, 2011).

Enfim, um exemplo bastante difundido de regressão linear é a função conhecida como função de produção Cobb-Douglas. Essa função pode ser descrita na Equação 11 e representa a produção (Y) como variável dependente do insumo trabalho (X_2) e do insumo capital (X_3), com o termo do erro estocástico u e o logaritmo de base natural representado por e . Para confirmar que o modelo se trata de uma função linear nos parâmetros, é necessário

transformar logaritmicamente a Equação 11 na Equação 12. Dessa forma, é possível observar a linearidade nos parâmetros e a não linearidade nas variáveis Y e X, estes só serão lineares nos logaritmos das variáveis. Assim, a Equação 10 também é conhecida como o modelo de regressão múltipla log-log, duplo log ou log linear (GUJARATI; PORTER, 2011).

$$Y_i = \beta_1 X_{2i}^{\beta_2} X_{3i}^{\beta_3} e^{u_i} \quad (11)$$

$$\ln Y_i = \ln \beta_1 + \beta_2 \ln X_{2i} + \beta_3 \ln X_{3i} + u_i = \beta_0 + \beta_2 \ln X_{2i} + \beta_3 \ln X_{3i} + u_i \quad (12)$$

A partir dessa teoria, a escolha da forma funcional é também parte da definição do modelo. Apesar de existirem várias formas funcionais utilizadas nos estudos da demanda por transporte, existem duas formas mais difundidas que são a função potência e a função exponencial negativa. A função potência é comumente utilizada por poder ser uma função linear com transformação em log, resultado em uma elasticidade direta através dos coeficientes de regressão. Além disso, é um modelo que resulta em uma elasticidade constante, mais utilizada para estimativas de demanda (GOODWIN; WILLIAMS, 1985; WARDMAN *et al.*, 2007; RAHMAN; BALIJEPALLI, 2016).

Outro fator importante na definição do modelo é a agregação dos dados. Coerentemente, quanto menor a desagregação dos dados, maior será a proximidade da regressão com a realidade em estudo, ou seja, a utilização de uma abordagem desagregada que analisa a variável dependente através da escolha do indivíduo é mais abrangente. Porém, a disponibilidade de fornecimento dos dados individuais é inacessível em muitos casos. Assim, em muitos propósitos de estudo, a forma agregada dos dados está disponível e tem potencial de fornecer uma boa tendência do comportamento da demanda (DALDOUL *et al.*, 2016). Dessa forma, a função definida para esta pesquisa é de demanda agregada, sendo os parâmetros disponíveis agregados por ano. Mesmo assim, é possível encontrar o comportamento aproximado da demanda por transporte público para o cenário brasileiro e estimar as elasticidades que indiquem tendências. Daldoul *et al.* (2016) discutem a função de demanda agregada e aponta a possibilidade de se obter uma aproximação numérica relevante dos fatores que afetam a demanda por transporte público, além de apontar dois outros estudos que apresentam a mesma característica: Fitzroy e Smith (1999) e Matas (2004).

Os modelos econométricos também possuem características principais relativas ao tipo de dado utilizado e a forma de modelagem. Por exemplo, modelos clássicos tendem a

assumir os dados como estacionários, sob a hipótese de que as variações são constantes ao longo do tempo. No entanto, já foi constatado que em muitas aplicações essa suposição não é válida. As características sociais, políticas e econômicas variam com o tempo e essas mudanças devem ser adicionadas ao modelo para permitir a caracterização mais real das estimativas (CROTTE *et al.*, 2011).

O tipo de modelo, estático ou dinâmico, trará resultados com interpretações diferentes para as elasticidades. Nos dois casos, o estimador utilizado pode ser o mesmo, sendo o mais comum o método dos mínimos quadrados ordinários, como definido no início desta seção. O modelo dinâmico, em contrapartida, inclui uma variável dependente que representa a defasagem do valor da demanda, especulando assim que a demanda do ano anterior tem influência sobre a demanda atual de transporte público. Com isso, é possível gerar resultados de elasticidades no curto e no longo prazo, diferentemente dos modelos estáticos que só apresentam resultados no curto prazo. Nestes modelos, após a regressão, faz-se necessária a análise do viés de variável, heterocedasticidade ou autocorrelação para validação do modelo (TSAI; MULLEY, 2014).

Devido a isto, o modelo estático foi testado inicialmente através do método MQO com o intuito de buscar a relação linear e constante entre a demanda e as variáveis explicativas. Porém, em uma segunda fase, o modelo dinâmico foi escolhido para avaliar o potencial de influência dos parâmetros em um longo prazo e se esta forma de modelagem seria mais adequada ao cenário estudado. Para isso, o painel dinâmico foi modelado através do método generalizado dos momentos (MGM) com sigla em inglês, GMM.

4.5 APLICAÇÃO DO MODELO DE PREVISÃO

A aplicação do modelo de previsão é a etapa de experimento, em que os modelos, os tipos de estimativa e as variáveis são substituídos a fim de atingir uma função de regressão mais adequada estatisticamente e com características condizentes com o cenário. O *software* escolhido para as estimativas foi o R (versão 3.5.1) pela sua abrangência desde a definição das equações de regressão até os testes de hipóteses, bem como é uma das linguagens de programação mais utilizadas no mundo para estudos estatísticos. Em adição, o pacote “plm” do *software* utilizado para a estimativa com dados em painel foi desenvolvido por Croissant e Millo (2008).

Com o painel de dados elaborado, os primeiros testes do modelo foram realizados com o método dos MQO para as regressões com dados empilhados, efeito fixo e efeito

aleatório, para um painel estático, a fim de encontrar o tipo de regressão mais adequado para os dados estudados. As variáveis explicativas aplicadas inicialmente foram tarifa e renda, como definido na função de demanda, sendo as outras variáveis incluídas uma a uma ao modelo para obtenção da função mais conveniente com o modelo escolhido. As outras variáveis explicativas foram sendo definidas a partir da combinação das referências analisadas com os dados disponíveis. Um exemplo importante dessa associação é a escolha da utilização da quilometragem anual percorrida relacionada com a população e/ou a área, como representação da qualidade do serviço por intermédio da quantidade de transporte público disponível, como delineado por Wang (2009), Souche (2010) e Crotte *et al.* (2011).

A variável dependente foi definida para a regressão como a demanda equivalente anual per capita e foi calculada através da divisão entre os dados dos passageiros equivalentes transportados anualmente disponibilizados pela NTU (2018b) e a população de cada cidade em cada ano, disponibilizada pelo IBGE (2018). Outro ponto relevante sobre as variáveis nesta etapa é que foi incluído na equação de regressão, o fator ano através do qual o efeito sazonal, neste caso anual das variáveis estão considerados.

Algumas variações de aplicação também foram executadas através do tratamento dos dados em painel. Para certos dados como PIB a disponibilidade do IBGE é até o ano de 2015, então o painel foi reduzido para o período de 2007 a 2015, com o intuito de investigar a influência destes dados sobre a demanda. Outro aspecto detectado e que será detalhado no Capítulo 5, é uma mudança na metodologia de contagem dos passageiros equivalentes da cidade de São Paulo. Segundo a NTU (2015), no ano de 2013 foi considerada uma nova abrangência do sistema da cidade, em que o sistema coletado anteriormente era unicamente o subsistema estrutural e a partir desta data o subsistema local é adicionado. Neste caso, o subsistema estrutural é composto pelas linhas destinadas a atender a grandes demandas com veículos de médio e grande porte, integrando as grandes regiões da cidade, enquanto que, o subsistema local é o alimentador do estrutural, com ônibus comuns e de menor porte (NTU, 2015). Por essa razão, a regressão foi testada excluindo a cidade de São Paulo, para avaliar a existência de alguma distorção no modelo gerada pelos dados dessa cidade.

Após diversos experimentos, a função de regressão escolhida como mais apropriada passou pelos testes de hipóteses descritos no item 4.6 e foram examinadas as características estatísticas principais. Através dos testes, a função de regressão será considerada com significância para explicação do modelo ou não. Quando a função não apresenta um resultado satisfatório no teste de hipóteses, as opções disponíveis com os mesmos dados são buscar uma

forma de correção do problema encontrado ou aplicar outro método econométrico para estimativa dos coeficientes de regressão.

Na segunda parte da aplicação do método, a escolha foi de utilizar o modelo de regressão com painel dinâmico estimado através do método generalizado dos momentos com efeito fixo. Como na primeira etapa, as regressões foram feitas inicialmente com as variáveis de tarifa e renda, posteriormente com as variáveis relevantes para o primeiro modelo e por último combinando com as variáveis que não apresentaram relevância na etapa anterior. Como o MGM pode ser usado em modelos lineares com variáveis explicativas endógenas ou exógenas, esse método foi escolhido para a segunda etapa, com o objetivo de minimizar possíveis problemas de endogeneidade do modelo. Além disso, este método tem sido utilizado em estudos da literatura de demanda de transporte, como é o exemplo de Graham *et al.* (2009).

4.6 TESTES DE HIPÓTESES DO MODELO

No estudo dos métodos econométricos, a regressão linear é estimada com o objetivo de compor inferências estatísticas sobre quais os verdadeiros coeficientes que representariam a variação da variável dependente em relação às variáveis explicativas. Dessa forma, o intuito da análise de regressão não é somente obter os valores destes coeficientes, mas entender a equivalência do modelo estimado com a realidade em estudo. Para isso, é necessário definir os critérios estatísticos norteadores da estimação da função de regressão, sendo algumas das principais hipóteses definidas nesta seção.

A primeira hipótese é a propriedade da linearidade do modelo. Neste aspecto, a hipótese afirma que o modelo deve ser linear nos parâmetros, mesmo que não seja linear nas variáveis. A segunda hipótese se refere ao valor médio do termo do erro. Segundo essa hipótese, a média dos erros resultantes da estimativa da função de regressão tem que ser zero (WOOLDRIDGE, 2001).

A terceira hipótese indica que os valores dos regressores (X) devem ser fixos em amostras repetidas ou independentes do termo do erro. Neste segundo caso, os valores dos regressores podem variar com a mudança da variável dependente, ou seja, são regressores aleatórios ou estocásticos. Porém, esses devem ser independentes do termo do erro, isto é, com covariância entre o regressor e o erro igual a zero (WOOLDRIDGE, 2001).

A quarta hipótese está relacionada à homocedasticidade. Esta propriedade significa que os erros resultantes da função de regressão devem ter uma variância constante, ou seja, a

média da subtração do termo do erro pela média do termo do erro deve ter valor constante para todos os valores observados do regressor. Como quinta hipótese tem-se o critério relacionado a não autocorrelação entre os termos de erro, ou seja, a covariância entre os termos de erro dos regressores tem que ser igual à zero (STOCK; WATSON, 2008).

A sexta hipótese implica na existência de variabilidade dos valores dos regressores (X). Isto é, os valores de X da amostra não devem ser o mesmo e a sua variabilidade deve ser um número positivo. Além disso, essa hipótese também restringe os valores dos regressores, não podendo existir valores muito discrepantes na amostra, chamados de *outliers*, para que estes valores não modifiquem o comportamento da função de regressão (STOCK; WATSON, 2008).

Uma última hipótese relevante na análise de regressão é a ausência de viés de especificação. Esta hipótese sendo comprovada implica dizer que o modelo está especificado corretamente e possui significância para explicar a relação das variáveis estudadas (WOOLDRIDGE, 2001).

Com as hipóteses elementares apresentadas, a discussão entra no tópico da necessidade de aplicação destes critérios para aproximação da realidade, sendo esta uma questão antiga na ciência. Por isso, quatro hipóteses clássicas terão maior detalhamento teórico devido à necessidade de verificação mais completa através dos testes de hipóteses conhecidos, são eles: a homocedasticidade, a autocorrelação ou correlação serial, a multicolinearidade e a endogeneidade.

Começando pela homocedasticidade do modelo, é fundamental que na regressão linear clássica todas as variâncias do termo do erro sejam iguais, ou seja, que não exista heterocedasticidade. Dessa forma, no teste de hipóteses, a hipótese nula deve ser satisfeita para os estimadores sejam considerados os melhores estimadores lineares não tendenciosos. Porém, a presença de heterocedasticidade não causa inconsistência ou tendenciosidade dos estimadores. Ademais, a heterocedasticidade também pode alterar os resultados dos testes t e F no método dos mínimos quadrados, gerando resultados incoerentes (MADDALA, 2008).

Uma maneira comprovada de reduzir o risco da heterocedasticidade é usando a transformação logarítmica na função de regressão, porém esta alternativa não elimina completamente o problema. Por fim, mesmo este problema não sendo crucial para os estimadores, ainda reduz a robustez do modelo, visto que o torna menos convergente e quanto maior o tamanho da amostra, mais o modelo irá divergir (MADDALA, 2008).

Passando para a análise da autocorrelação ou correlação serial, o ponto a ser estudado é a relação entre as observações. Neste caso, a observação em série temporal ou

corte transversal de uma variável não pode ser afetada pela observação defasada dessa mesma variável. Os motivos para a existência da autocorrelação podem variar, algumas possibilidades são: a inércia ou lentidão das séries temporais econômicas, a escolha incorreta da forma funcional e o problema de especificação pela exclusão de variáveis importantes no modelo. Por isso, existe uma distinção entre a autocorrelação pura, intrínseca ao modelo e a autocorrelação induzida, resultante de algum dos problemas mencionados (STOCK; WATSON, 2008).

Um teste bastante utilizado na detecção de autocorrelação é o teste Durbin-Watson que identifica a existência de autocorrelação, porém não a corrige. A existência da autocorrelação não faz com que os parâmetros sejam tendenciosos, mas eles serão ineficientes. Mesmo assim, existem procedimentos que podem ser usados para estimar o modelo com a existência da autocorrelação sem que ela afete a significância do modelo. Dois exemplos são o algoritmo de Prais–Winsten e o método de Cochrane–Orcutt (CORDERA *et al.*, 2015).

A multicolinearidade é, por definição, a existência de uma relação linear exata ou parcialmente exata entre as variáveis explicativas (X) do modelo de regressão. Ou seja, com a multicolinearidade perfeita, os coeficientes de regressão serão indeterminados e os erros padrões serão infinitos. Quando esta multicolinearidade é aproximadamente exata, os coeficientes de regressão serão determinados, mas os erros padrões relacionados a eles serão grandes, resultando na redução da precisão dos coeficientes. Apesar disso, a multicolinearidade não viola nenhuma das hipóteses clássicas da regressão, a consequência da existência desta característica é a complicação na obtenção dos coeficientes com erros padrão pequenos (STOCK; WATSON, 2008; HOFFMANN, 2016).

A endogeneidade, por sua vez, é um problema que viola a hipótese de independência entre as variáveis explicativas e o termo do erro ou resíduo. Em outras palavras, a variável explanatória é endógena quando está correlacionada com o termo do erro ou com a perturbação (WOOLDRIDGE, 2001). A endogeneidade pode ser testada através do teste Wu e os modelos que apresentam esta característica podem ser estimados pelo método dos mínimos quadrados em dois estágios. Esse método permite a obtenção de coeficientes de regressão consistentes, o que não ocorre quando a estimação é feita pelo método dos mínimos quadrados com a existência de endogeneidade. A complexidade deste método existe pela necessidade da definição de variáveis instrumentais exógenas que sejam correlacionadas com a variável dependente (CORDERA *et al.*, 2015).

O grande problema da estimação de dados em painel dinâmico é a existência da variável dependente defasada como regressor, pois se não houver controle do efeito individual dessa variável, ela será correlacionada com o erro e o modelo apresentará endogeneidade (TSAI *et al.*, 2014). Na presença da endogeneidade não é ideal estimar a regressão através do método dos mínimos quadrados com dados empilhados ou com efeito fixo, pois a variável defasada estará correlacionada com o termo do erro, conhecido como viés de Nickell. Segundo Tsai *et al.* (2014), vários estudos empregam variáveis instrumentais conhecidas como estimadores IV, pois ele apresenta resultados melhores que os estimadores de efeitos fixos. Porém, esse método possui a mesma complexidade do citado por Cordera *et al.* (2015) devido à necessidade da definição de variáveis instrumentais (TSAI *et al.*, 2014).

A escolha dos critérios a serem testados na análise de regressão deve sempre buscar definir o modelo, de modo que ele seja útil para determinar tendências econômicas das variáveis em estudo. Entretanto, nem sempre existe um modelo totalmente realista ou verdadeiro. Variações nos tipos de dados e nas especificações funcionais afetarão os resultados para cada caso e podem implicar em variações nos resultados e nas políticas que eles serão aplicados através das elasticidades obtidas (DALDOUL *et al.*, 2016).

No que concerne à utilização de modelos econométricos no contexto da estimação da demanda por transporte público, a forma funcional mais utilizada é a linear ou log-log. Como a função linear é de estimativa simples e tem resultados de fácil interpretação, ela foi usada em muitos estudos desde os primeiros. No caso da função log-log, como os coeficientes de regressão representam diretamente as elasticidades das variáveis explicativas, este modelo passou a ser o mais utilizado na análise da demanda de transporte (DALDOUL *et al.*, 2016; FITZROY; SMITH, 1994; MATAS, 2004).

Em primeiro momento, três testes de hipóteses foram realizados a fim de encontrar qual tipo de regressão dos dados é mais apropriada. O teste F para efeitos individuais compara regressões com dados empilhados e efeitos fixos e determina a regressão de efeitos fixos melhor quando a hipótese alternativa tem efeitos significativos. Do mesmo modo, o teste do Multiplicador de Lagrange compara modelos com dados empilhados e efeitos aleatórios e admite a regressão com efeitos aleatórios como melhor opção também quando a hipótese alternativa é significativa (BALTAGI, 2005). Enfim, para comparar os efeitos fixos com os aleatórios o teste usado é o de Hausman. A hipótese nula desse teste é de que os efeitos não observados estão correlacionados com o erro, sendo mais recomendado o uso da regressão com efeitos fixos (RAHMAN; BALIJEPALLI, 2016).

Para a determinação da correlação serial, os testes de Breusch–Godfrey e Durbin-Watson foram usados por permitirem a análise deste critério em dados em painel para o primeiro modelo regredido. Além disso, o teste quiquadrado de Wald foi utilizado para análise da heterocedasticidade do modelo de painel estático. Por fim, vale ressaltar que testes de endogeneidade não foram realizados pela complexidade de definição de variáveis instrumentais, principalmente com uma quantidade de variáveis restrita. Porém, o método do segundo modelo com painel dinâmico foi adotado justamente para minimizar alguma possível presença de endogeneidade no modelo.

5 RESULTADOS E DISCUSSÕES

O Capítulo 5 é destinado a apresentar os resultados encontrados na pesquisa e tecer as análises das características e valores encontrados, além de compará-los aos estudos internacionais citados. Para isso, em primeiro momento, são apresentadas as variáveis e explorada a origem e as particularidades de cada cidade do modelo. A segunda subseção apresenta os resultados do modelo com dados em painel estático, as elasticidades referentes a esta regressão e as hipóteses testadas para esse método. Por fim, os resultados da regressão com dados em painel dinâmico são apresentados na terceira subseção concluindo assim, o estudo com as elasticidades de curto e longo prazo da demanda por transporte público em metrópoles brasileiras.

5.1 CARACTERÍSTICA DOS DADOS SECUNDÁRIOS

Os dados estudados nesta pesquisa são apresentados em sua totalidade no Apêndice A e a estatística descritiva da amostra está exposta na Tabela 7. A demanda anual utilizada nos modelos é a quantidade de passageiros equivalentes transportados anualmente padronizados pela população, visto que as metrópoles estudadas têm dimensões variadas, como mostrado na estatística descritiva da demanda equivalente anual. A tarifa utilizada como preço do serviço foi o valor mais recorrente em cada cidade, devido à variação da quantidade de níveis tarifários nas cidades. Esta determinação é feita pela NTU (2018b) e indica o nível tarifário predominante da cidade.

A quilometragem percorrida anual pelos ônibus urbanos para ser utilizada no modelo foi testada com a padronização através da área e da população, também pelo fato da grande variação de tamanho e quantidade de habitantes das cidades. Este parâmetro foi escolhido desta forma com referência nos estudos de Wang (2009), Souche (2010) e Crotte *et al.* (2011), nos quais, a qualidade do serviço é determinada através de uma *proxy* da quilometragem percorrida per capita e pela área, sendo este um índice da qualidade de transporte público disponível para a população.

A renda utilizada no modelo, proveniente das pesquisas do IBGE, é o valor referente ao rendimento médio nominal de todos os trabalhos, habitualmente recebido por mês, pelas pessoas de 10 anos ou mais de idade ocupadas na semana de referência, com rendimento de trabalho. Este parâmetro foi escolhido pela dificuldade em obter dados monetários mais abrangentes para todas as cidades nos anos do estudo. Mesmo com esta particularidade, os

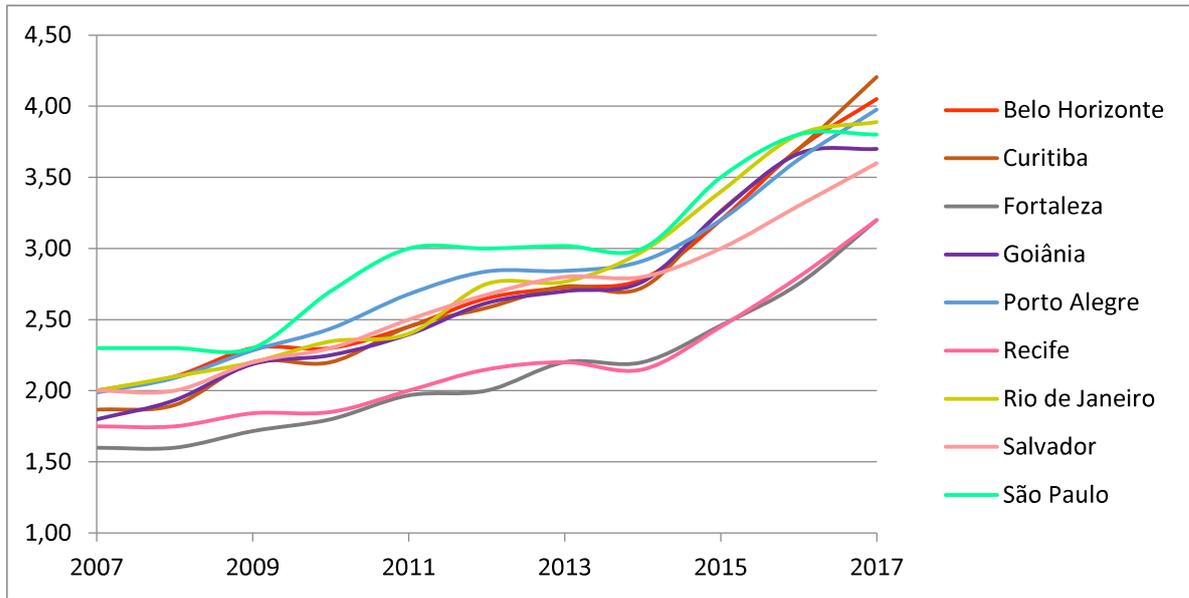
dados da renda devem ser testados na regressão por ser uma das duas variáveis clássicas da função de demanda. Os outros parâmetros: idade da frota, frota de motos e automóveis e preço da gasolina foram testados sem normalização, ou seja, da forma que foram obtidos das entidades responsáveis.

Tabela 7 – Estatística descritiva da amostra

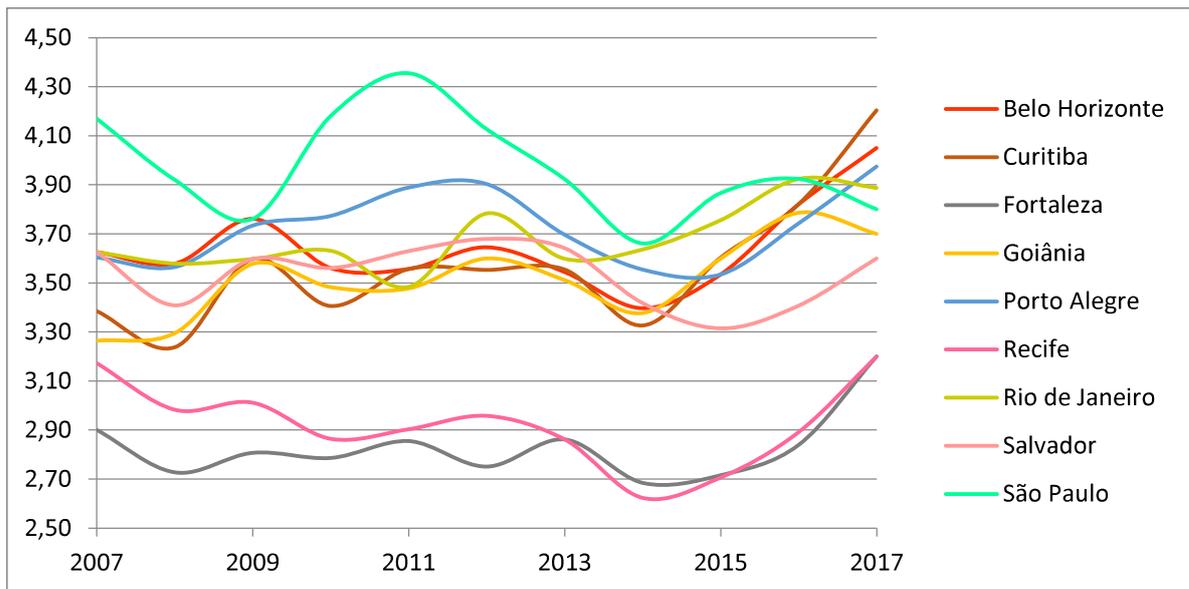
Variável	Média	Desvio Padrão	Mínimo	Máximo
Demanda equivalente anual (Passageiro Equivalente Anual)	451.602.376	330.046.983	130.346.652	1.589.243.454
Demanda equivalente anual per capita (Passageiro Equivalente Anual per capita)	122,64	35,08	54,04	190,10
Tarifa principal (R\$)	2,63	0,64	1,60	4,20
Quilometragem percorrida anual (km)	279.641.509	238.385.807	66.136.392	868.519.818
Renda média de todos os trabalhos (R\$)	1.389,51	519,60	452,00	2.768,20
Idade da frota de ônibus urbanos (anos)	4,86	1,15	1,35	8,32
Frota de motos (veículo)	239.945,40	203.607,80	47.419	924.175
Frota de automóveis (veículo)	1.263.295	1.344.974	347.623	5.582.546
Preço da gasolina (R\$)	2,91	0,48	2,33	4,09
População (habitantes)	3.889.801	3.043.498	1.409.351	12.106.920
Área (km ²)	1.524,18	1.746,29	314,93	5.981,74

Fonte: a autora, 2018 [por meio do banco de dados da NTU(2018b) e do IBGE(2018)].

Além da estatística descritiva, os gráficos das variáveis explicativas para cada cidade do painel ao longo dos anos em estudo estão apresentados, a fim de analisar inicialmente o comportamento isolado de cada uma e suas peculiaridades. O Gráfico 3 e Gráfico 4 apresentam a evolução da tarifa principal das cidades. No primeiro, a tarifa é apresentada sem correção e no segundo a tarifa está corrigida para o mês de dezembro de 2017, pelo Índice Nacional de Preços ao Consumidor Amplo (IPCA) do IBGE (2018). Como previsto, o comportamento de aumento exclusivo do Gráfico 3 não é estendido para o Gráfico 4 com o valor corrigido. Porém, é importante observar que a oscilação da tarifa é semelhante nas nove cidades tendo um crescimento contínuo na maioria delas a partir do ano de 2014, período em que o cenário econômico do país começou a desestabilizar.

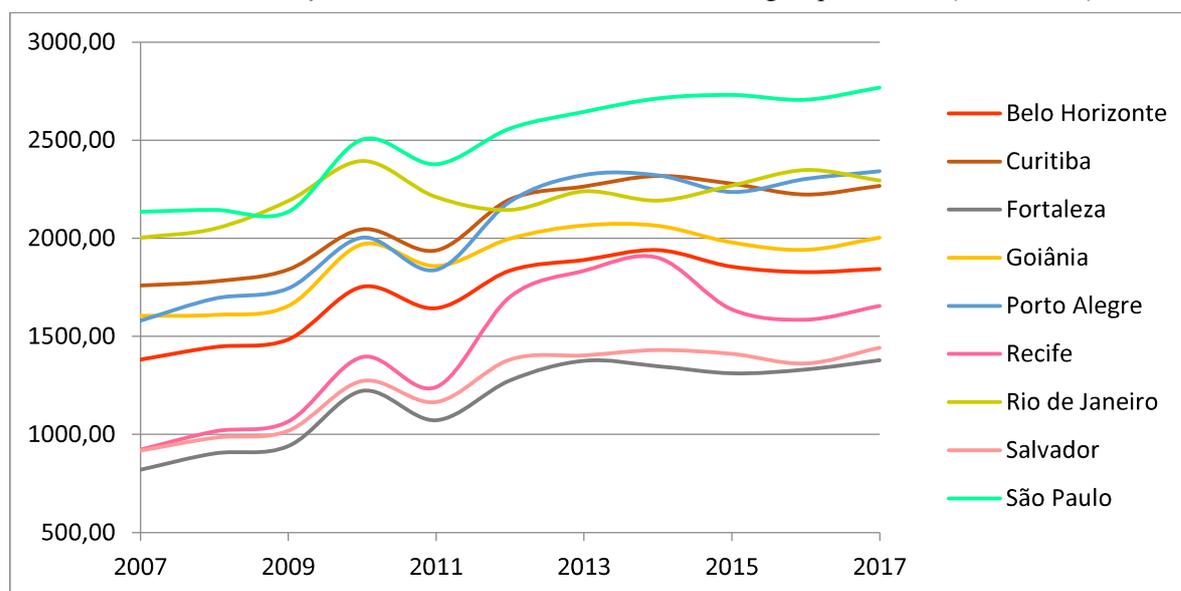
Gráfico 3 – Evolução da tarifa principal

Fonte: a autora, 2018 [por meio do banco de dados da NTU(2018b)].

Gráfico 4 – Evolução da tarifa principal corrigida pelo IPC-A (IBGE, 2018).

Fonte: a autora, 2018 [por meio do banco de dados da NTU(2018b)].

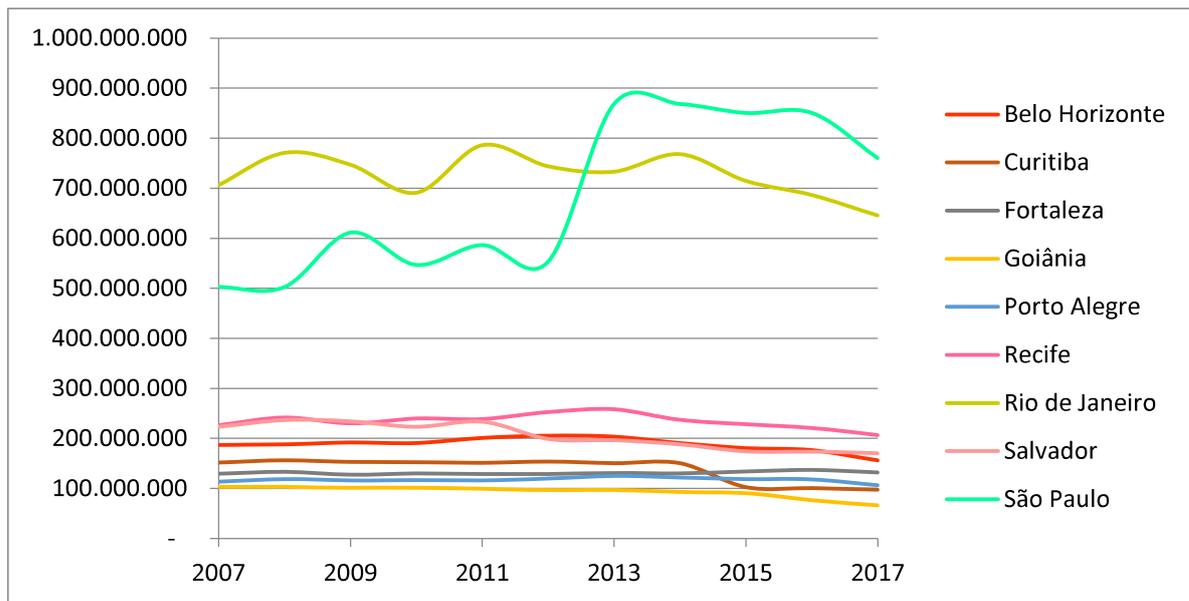
O Gráfico 5 apresenta a renda média dos trabalhadores corrigida pelo IPCA e aponta um comportamento semelhante entre as cidades. Além disso, é possível observar que o rendimento médio dos trabalhadores é em geral crescente, porém, como é uma média, sua variação é pequena, mesmo as cidades tendo proporções diferentes.

Gráfico 5 – Evolução da renda média dos trabalhadores corrigida pelo IPC-A (IBGE, 2018).

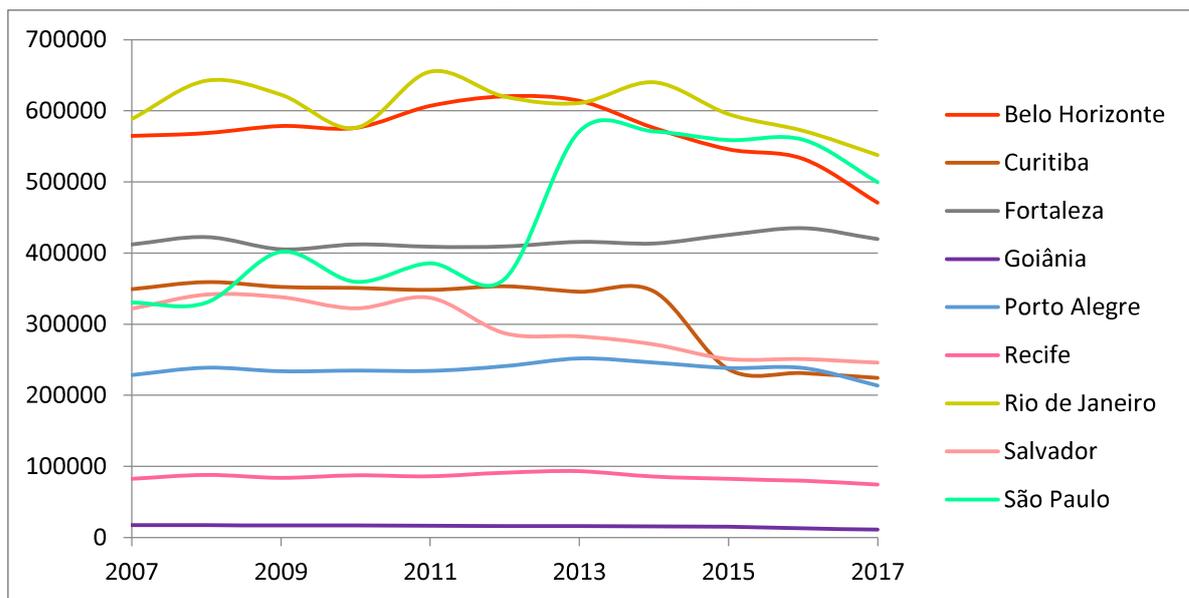
Fonte: a autora, 2018 [por meio do banco de dados da NTU(2018b)].

Com relação à variável de qualidade do serviço de transporte, o Gráfico 6 apresenta a quilometragem percorrida pelos ônibus urbanos e o Gráfico 7 é a variável anterior normatizada pela área. No primeiro deles, o ponto mais notável é a discrepância entre a quilometragem percorrida por Rio de Janeiro e São Paulo com relação às outras cidades, tendo estas uma distância percorrida relativamente constante ao longo dos anos de estudo. Outro ponto a se ressaltar neste mesmo Gráfico 6 é o salto ocorrido entre os anos de 2012 e 2013 devido à mudança de metodologia citada no item 4.5. Mesmo com a existência dessa modificação metodológica, os dados de São Paulo foram utilizados como fornecidos pela NTU (2018b), pela não existência dos dados desagregados entre o sistema principal e alimentador a partir do ano de 2013.

O Gráfico 7, por sua vez, apresenta a quilometragem percorrida pelos ônibus urbanos após a normatização pela área das cidades. Neste caso, é possível observar que o intuito de aproximar os dados estudados e reduzir a influência da dimensão das cidades foi alcançado. Isto é, as curvas das cidades se aproximaram, não perdendo, no entanto, suas características individuais, como por exemplo, a permanência do salto nos dados de São Paulo.

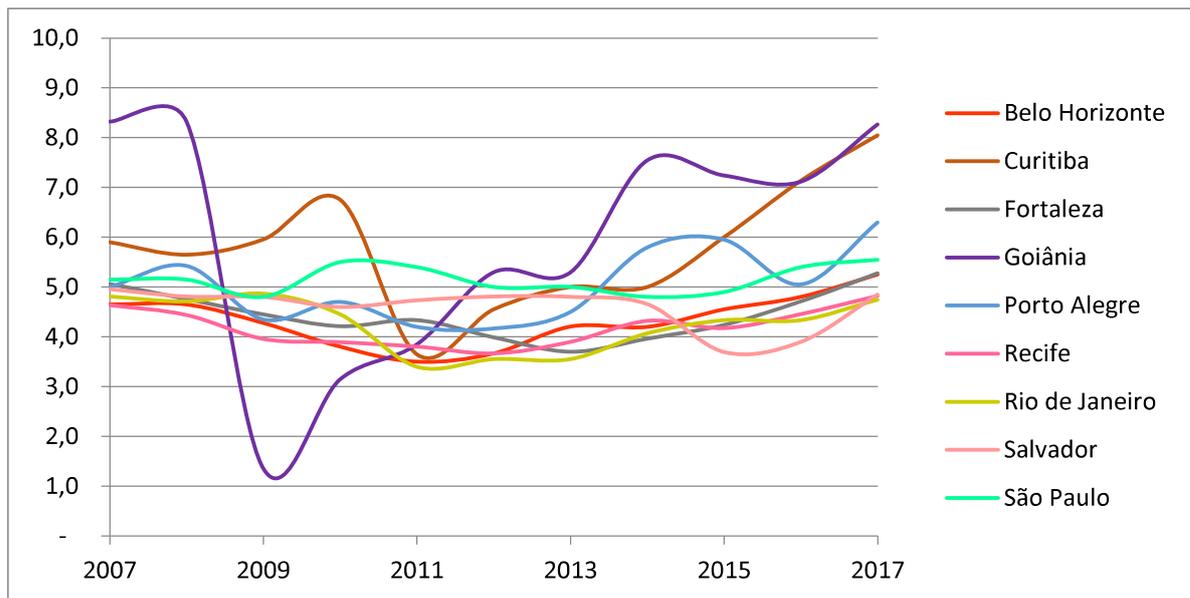
Gráfico 6 – Evolução da quilometragem percorrida pelos ônibus urbanos

Fonte: a autora, 2018 [por meio do banco de dados da NTU(2018b)].

Gráfico 7 – Evolução da quilometragem percorrida/área

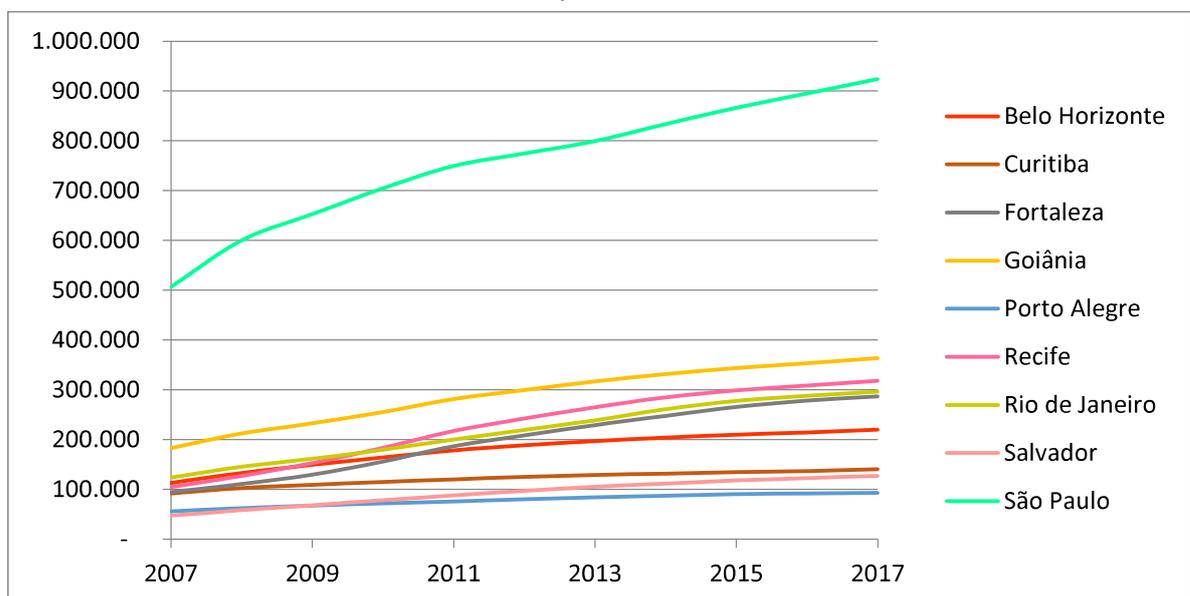
Fonte: a autora, 2018 [por meio do banco de dados da NTU(2018b)].

A evolução da idade média da frota é apresentada no Gráfico 8 e possui, no geral, uma tendência de queda até aproximadamente 2011 a 2013 e posteriormente um ligeiro crescimento. As duas cidades com maior discrepância nesta variável são Curitiba e Goiânia, possivelmente pela aquisição de novos veículos para redução da idade média da frota em 2011 e 2009, respectivamente.

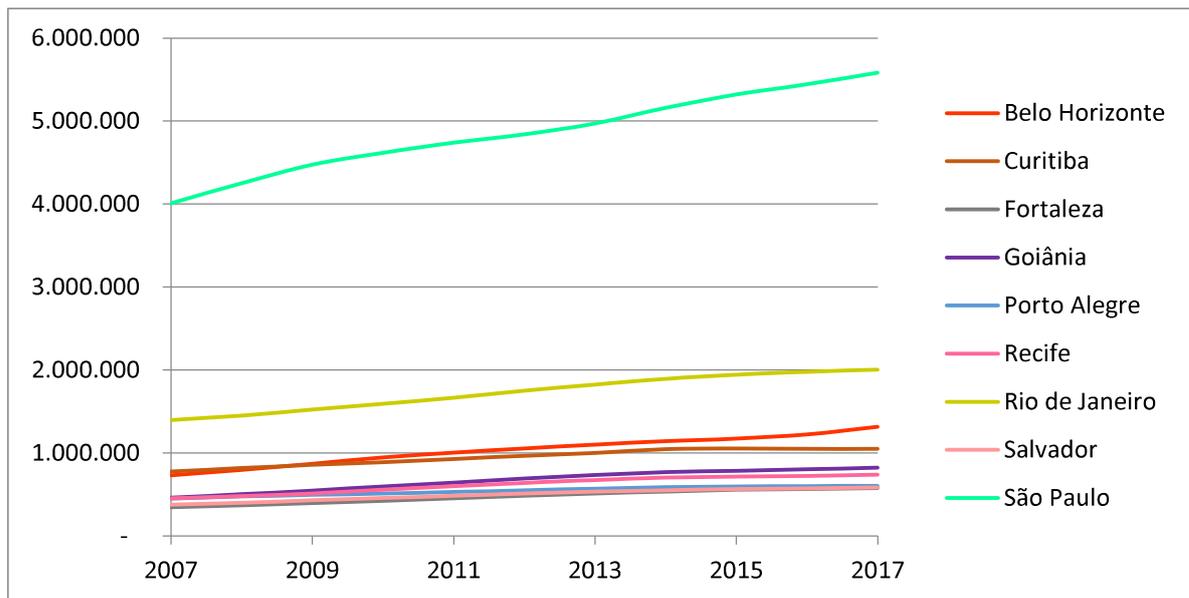
Gráfico 8 – Evolução da idade média da frota de ônibus urbano

Fonte: a autora, 2018 [por meio do banco de dados da NTU(2018b)].

O Gráfico 9 e Gráfico 10 apresentam o crescimento das frotas de motocicleta e automóvel, respectivamente. Os dados expostos comprovam que a utilização de modos privados no Brasil é um comportamento crescente em todo o período estudado. Além disso, vale ressaltar que a frota de automóveis teve um crescimento e uma quantidade maior em cidades maiores, como São Paulo, Rio de Janeiro, Belo Horizonte e Curitiba. No entanto, as cidades do Centro-Oeste e Nordeste crescem de intensidade quando a questão analisada é a motocicleta, como os casos de Goiânia, Recife e Fortaleza.

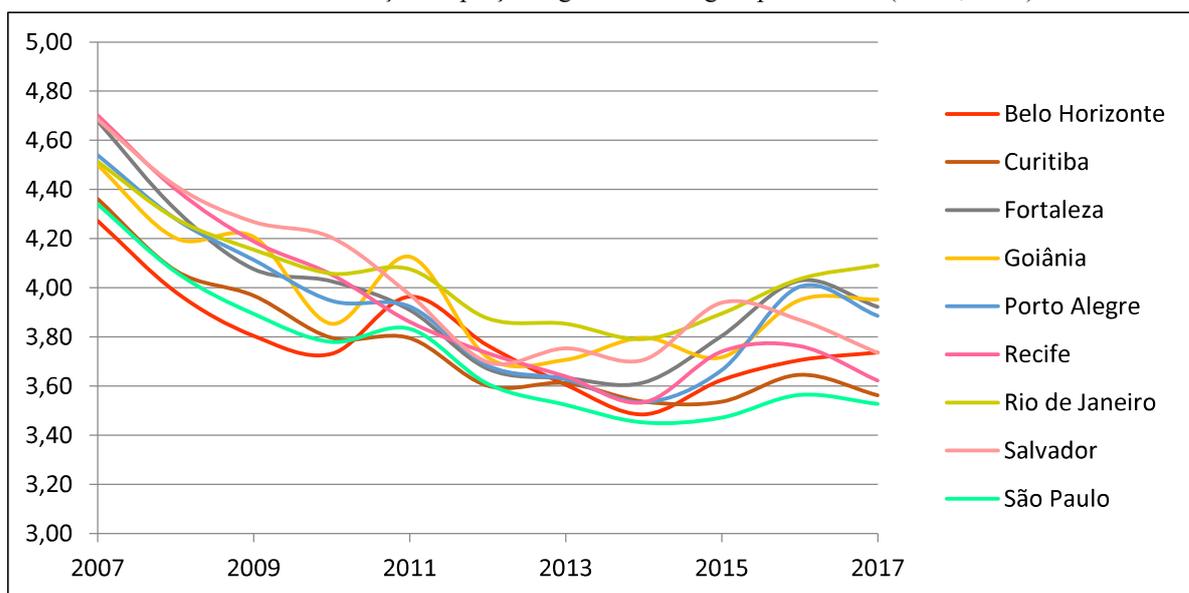
Gráfico 9 – Evolução da frota de motocicleta

Fonte: a autora, 2018 [por meio do banco de dados da NTU(2018b)].

Gráfico 10 – Evolução da frota de automóveis

Fonte: a autora, 2018 [por meio do banco de dados da NTU(2018b)].

O preço da gasolina obtido na ANP e corrigido pelo IPCA (IBGE, 2018) é apresentado no Gráfico 11. A evolução do preço da gasolina ao longo dos anos em estudo exhibe uma tendência única para as nove cidades, possivelmente pela regulação da ANP, e tem característica de decrescimento na maior parte do período, com um leve aumento em 2011 e em 2016. Isto é, no geral, houve um incentivo indireto ao modo privado, pelo aumento abaixo da inflação do preço da gasolina na média do período analisado.

Gráfico 11 – Evolução do preço da gasolina corrigida pelo IPC-A (IBGE, 2018)

Fonte: a autora, 2018 [por meio do banco de dados da NTU(2018b)].

Enfim, com as variáveis quantitativas destacadas, a interpretação das estimativas de regressão poderá ter embasamento nas características específicas de cada variável. Assim, as seções 5.2 e 5.3 exploram os modelos testados e resultados para o painel estático e dinâmico.

5.2 RESULTADOS DO PAINEL ESTÁTICO

A primeira etapa da estimação dos fatores que influenciam a demanda de fato é a modelagem de regressão dos dados em painel. Como mencionado na seção 4.4, o primeiro método utilizado foi o MQO pela simplicidade de estimação e pela vasta utilização nos estudos de transportes. Para o estudo, o primeiro passo é regressar a função de demanda básica com o passageiro equivalente anual per capita como variável dependente e a tarifa e a renda como variáveis explicativas. Estes parâmetros foram estimados por três modelos: dados empilhados, efeito fixo e efeito aleatório, apresentados na Tabela 8.

Tabela 8 – Resultados da regressão linear inicial em painel estático

Variáveis Explicativas	Coeficiente parcial (erro padrão)		
	Dados empilhados	Efeito Fixo	Efeito Aleatório
Tarifa (em log)	0,391 (0,371)	-1,669*** (0,329)	-1,257*** (0,310)
Renda (em log)	0,053 (0,161)	-0,489* (0,194)	-0,229 (0,175)
<i>Tendência</i>			
2008	0,012 (0,139)	0,125* (0,057)	0,086 (0,057)
2009	-0,049 (0,141)	0,268*** (0,077)	0,176* (0,073)
2010	-0,063 (0,147)	0,473*** (0,120)	0,303** (0,108)
2011	-0,101 (0,151)	0,588*** (0,136)	0,390** (0,122)
2012	-0,154 (0,160)	0,766*** (0,181)	0,494** (0,160)
2013	-0,146 (0,165)	0,896*** (0,206)	0,584** (0,181)
2014	-0,197 (0,168)	0,910*** (0,221)	0,574** (0,194)
2015	-0,350 (0,186)	1,062*** (0,265)	0,654** (0,232)
2016	-0,486* (0,208)	1,199*** (0,306)	0,727** (0,269)
2017	-0,642** (0,225)	1,237*** (0,337)	0,718* (0,296)
Constante	4,583*** (0,291)		5,576*** (0,224)
Observações	99	99	99
R ²	0,170	0,631	0,574

Fonte: a autora, 2018 (por meio da base de dados secundários).

Legenda: '***'p<0,001; '**'p<0,01; '*'p<0,05; '.'p<0,1; ' 'p<1

Na regressão, o efeito da variação anual é considerado através da adição do fator ano à função de regressão. Dessa forma, a influência dos anos nas variáveis não modificará as elasticidades da demanda de cada variável. Por isso, os dados monetários utilizados na regressão, como tarifa e renda, poderão ser empregados com os valores obtidos das entidades oficiais, sem a necessidade de correção.

Com os três modelos regredidos, os testes para definição técnica de estimação mais adequada para estes dados foram feitos. Três testes foram necessários para comparação dos modelos dois a dois com resultados apresentados no Apêndice C. O primeiro deles é o teste de Lagrange para comparar o modelo de dados empilhados com o modelo de efeito aleatório. Neste caso, o p-valor é muito baixo, menor que 5%, e o efeito significativo é da hipótese alternativa que considera o efeito aleatório como mais adequado.

O segundo teste é o teste F para efeitos individuais que compara os dados empilhados com o efeito fixo. Do mesmo modo, o p-valor resultante é baixo e a hipótese alternativa é a mais adequada, ou seja, o modelo com efeito fixo. Por fim, o teste de Hausman compara o efeito fixo com o efeito aleatório. O teste apresenta como resultado a hipótese de que um dos modelos é inconsistente, sendo indicado utilizar o modelo de efeitos fixos por gerar estimativas mais consistentes que o efeito aleatório. Isto posto, a estimação com efeito fixo foi escolhida para a regressão com painel estático e diversos testes a partir das combinações de variáveis foram feitos (Tabela 9 e Tabela 10). Além disso, vale destacar que a escolha do uso da regressão através do efeito fixo foi feita para que os efeitos estruturais da função de demanda por transporte público fossem englobados no modelo. Um efeito estrutural desta função de demanda que pode ser exposto é a existência do vale transporte em todas as cidades do estudo. Como os trabalhadores são beneficiados com o vale transporte, a escolha da utilização do serviço pelo fator preço acaba sendo reduzida, tendo assim uma influência na elasticidade-preço da renda. Porém, como esse é um efeito estrutural de todas as metrópoles do estudo, o parâmetro está sendo englobado no modelo através do efeito fixo.

A Tabela 9 e Tabela 10 exibem as dez regressões com melhores resultados da busca pela função de estimação ideal com os dados disponíveis. Além das variáveis quantitativas, também foi testada uma variável binária que representa a existência ou não do Uber nas cidades estudadas em cada ano. Para começar as regressões, foram testadas a tarifa e renda com a adição da variável de qualidade do serviço, testando assim a melhor opção de normatização pela população e pela área. Neste caso, a opção com melhor resultado foi a normatização pela área, sendo esta usada do terceiro modelo em diante para definição das próximas variáveis.

A idade da frota é um fator que também pode ser considerado como uma *proxy* da qualidade do serviço, quanto maior a idade da frota, menor será o conforto e portanto, menor a qualidade. Nas regressões, essa variável também apresenta significância e foi adicionada aos modelos a partir do quarto. A variável preço da gasolina, pelo contrário, além de não apresentar significância no modelo, ainda apresentou sinal contrário ao esperado. Esperava-se que com o aumento do preço da gasolina, as pessoas deixariam de utilizar o modo privado e utilizassem mais o público, aumentando a demanda com elasticidade positiva. Porém, este resultado pode ter ocorrido pela tendência de redução dos preços da gasolina apresentados no Gráfico 11, concomitantemente com a redução da demanda em partes do período estudado.

Tabela 9 – Resultado dos modelos de regressão mais relevantes testados

Variáveis Explicativas	Coeficiente parcial (erro padrão)				
	(1)	(2)	(3)	(4)	(5)
Tarifa (em log)	-1,669*** (0,329)	-0,551* (0,224)	-0,543* (0,224)	-0,498* (0,209)	-0,488* (0,208)
Renda (em log)	-0,489* (0,194)	-0,336** (0,120)	-0,269* (0,120)	-0,278* (0,112)	-0,334** (0,119)
Km percorrida per capita (em log)		0,779*** (0,068)			
Km percorrida/área (em log)			0,782*** (0,068)	0,759*** (0,064)	0,759*** (0,064)
Idade da frota (em log)				-0,122*** (0,034)	-0,127*** (0,034)
Preço da gasolina (em log)					-0,424 (0,313)
<i>Tendência</i>					
2008	0,125* (0,057)	0,063. (0,035)	0,044 (0,035)	0,043 (0,033)	0,047 (0,033)
2009	0,268*** (0,077)	0,112* (0,049)	0,079 (0,050)	0,044 (0,048)	0,053 (0,048)
2010	0,473*** (0,120)	0,227** (0,077)	0,198* (0,078)	0,174* (0,073)	0,205** (0,076)
2011	0,588*** (0,136)	0,241** (0,089)	0,207* (0,090)	0,169* (0,085)	0,225* (0,094)
2012	0,766*** (0,181)	0,340** (0,117)	0,289* (0,119)	0,254* (0,111)	0,317** (0,120)
2013	0,896*** (0,206)	0,405** (0,133)	0,319* (0,136)	0,289* (0,127)	0,376** (0,141)
2014	0,910*** (0,221)	0,417** (0,142)	0,321* (0,145)	0,302* (0,135)	0,414* (0,158)
2015	1,062*** (0,265)	0,477** (0,171)	0,370* (0,173)	0,346* (0,162)	0,515* (0,203)
2016	1,199*** (0,306)	0,502* (0,198)	0,386. (0,201)	0,361. (0,187)	0,576* (0,244)
2017	1,237*** (0,337)	0,509* (0,216)	0,384. (0,219)	0,369. (0,205)	0,593* (0,262)
Observações	99	99	99	99	99
R ²	0,631	0,863	0,863	0,883	0,886
R ² ajustado	0,536	0,825	0,826	0,849	0,850

Fonte: a autora, 2018 (por meio da base de dados secundários).

Legenda: '***'p<0,001; '**'p<0,01; '*'p<0,05; '.'p<0,1; ' 'p<1

Tabela 10 – Resultado dos modelos de regressão mais relevantes testados (continuação)

Variáveis Explicativas	Coeficiente parcial (erro padrão)				
	(6)	(7)	(8)	(9)	(10)
Tarifa (em log)	-0,415* (0,205)	-0,502* (0,211)	-0,553* (0,210)	-0,403. (0,203)	-0,451* (0,206)
Renda (em log)	-0,407** (0,119)	-0,261* (0,116)	-0,246* (0,113)	-0,470*** (0,126)	-0,435** (0,128)
Km percorrida/área (em log)	0,780*** (0,062)	0,750*** (0,066)	0,725*** (0,067)	0,780*** (0,062)	0,752*** (0,065)
Idade da frota (em log)	-0,112** (0,033)	-0,121*** (0,035)	-0,119*** (0,034)	-0,117*** (0,033)	-0,115*** (0,033)
Frota de Moto (em log)	0,208* (0,082)			0,212* (0,081)	0,202* (0,081)
Frota de Automóvel (em log)		-0,105 (0,185)			
Preço da gasolina (em log)				-0,456 (0,302)	-0,424 (0,302)
Uber			0,060 (0,038)		0,046 (0,037)
<i>Tendência</i>					
2008	0,021 (0,033)	0,048 (0,034)	0,042 (0,033)	0,025 (0,033)	0,025 (0,033)
2009	0,004 (0,049)	0,055 (0,052)	0,046 (0,047)	0,012 (0,049)	0,015 (0,048)
2010	0,137. (0,072)	0,188 (0,077)	0,171* (0,072)	0,169* (0,074)	0,166* (0,074)
2011	0,102 (0,086)	0,188 (0,092)	0,171* (0,084)	0,160. (0,093)	0,162. (0,093)
2012	0,191. (0,110)	0,276 (0,118)	0,254* (0,110)	0,257* (0,118)	0,255* (0,117)
2013	0,221. (0,125)	0,315 (0,135)	0,289* (0,125)	0,313* (0,138)	0,310* (0,138)
2014	0,232. (0,133)	0,331* (0,144)	0,286* (0,134)	0,350* (0,154)	0,333* (0,154)
2015	0,266. (0,159)	0,376* (0,171)	0,325* (0,161)	0,445* (0,198)	0,421* (0,198)
2016	0,273 (0,184)	0,392* (0,196)	0,304 (0,189)	0,502* (0,237)	0,446. (0,240)
2017	0,276 (0,201)	0,400* (0,213)	0,311 (0,206)	0,515* (0,255)	0,459. (0,258)
Observações	99	99	99	99	99
R ²	0,892	0,883	0,886	0,895	0,897
R ² Ajustado	0,859	0,847	0,852	0,861	0,862

Fonte: a autora, 2018 (por meio da base de dados secundários).

Legenda: ‘***’p<0,001; ‘**’p<0,01; ‘*’p<0,05; ‘.’p<0,1; ‘ ’p<1

A frota de motos também foi testada e obteve resultados significativos, porém o sinal resultante é contrário ao esperado. O sinal positivo nessa variável não é apropriado, pois um aumento na demanda de um serviço substituto não aumentaria a demanda do transporte público. De forma análoga, o crescimento da frota de automóveis também não apresentou resultado satisfatório. Neste caso, mesmo apesar do sinal resultante estar condizente com a literatura, o valor da elasticidade encontrada não apresenta significância. Por fim, a variável Uber foi testada gerando também resultados sem significância e com sinal oposto ao esperado

para um serviço substituto. Sendo assim, a estimativa com resultados adequados para definição dos parâmetros influenciadores da demanda é o Modelo (4) com tarifa, renda, quilometragem percorrida pela área e idade da frota como variáveis explicativas.

Como a cidade de São Paulo apresenta certa imprecisão nos dados da quilometragem percorrida e esse é um dos parâmetros significativos, é necessário estimar o modelo excluindo os dados da cidade para verificar se haveria melhoria nos resultados. A Tabela 11 expõe as elasticidades da demanda para as oito metrópoles brasileiras e apresenta resultados com maior R^2 e R^2 ajustado, indicando melhores parâmetros.

Tabela 11 – Resultado da regressão mais apropriada sem São Paulo

Variáveis Explicativas	Coeficiente parcial (erro padrão)	
	Efeito Fixo	
Tarifa (em log)	-0,604**	(0,220)
Renda (em log)	-0,288*	(0,109)
Km percorrida/área (em log)	0,554***	(0,087)
Idade da frota (em log)	-0,113***	(0,032)
<i>Tendência</i>		
2008	0,062.	(0,032)
2009	0,090.	(0,050)
2010	0,211**	(0,075)
2011	0,215*	(0,086)
2012	0,320**	(0,116)
2013	0,332*	(0,132)
2014	0,342*	(0,141)
2015	0,389*	(0,170)
2016	0,419*	(0,198)
2017	0,414.	(0,220)
Observações	88	
R^2	0,900	
R^2 Ajustado	0,869	

Fonte: a autora, 2018 (por meio da base de dados secundários).
 Legenda: ‘***’ $p < 0,001$; ‘**’ $p < 0,01$; ‘*’ $p < 0,05$; ‘.’ $p < 0,1$; ‘ ’ $p < 1$

A partir dos modelos estimados, os testes de hipóteses foram feitos para verificar a consistência dos mesmos. O primeiro teste realizado foi para verificar se existe correlação serial nos erros, sendo feito, neste estudo, através de dois testes clássicos: Breusch-

Godfrey/Wooldridge e Durbin Watson. Os resultados de todos os testes de hipóteses estão apresentados no Apêndice D. Para o caso das regressões com as nove ou com as oito cidades, os dois testes apontam a presença de correlação serial nos erros idiossincráticos.

A segunda hipótese é da multicolinearidade, geralmente determinada pelo Fator de Inflação de Variância (FIV) pela sua simplicidade de cálculo e de interpretação. Porém este parâmetro não se aplica a regressões sem intercepto, como é o caso do efeito fixo. Dessa forma, a determinação da multicolinearidade foi feita através do cálculo da correlação entre as variáveis. Para este teste, o valor padrão para a multicolinearidade ser considerada um problema sério, a correlação entre os pares de regressões tem que ser maior que 0,80. Neste caso, os resultados são todos menores que 0,60, tanto para o modelo com nove como para o modelo com oito cidades.

A terceira hipótese testada é a heterocedasticidade através do teste de Wald. Para as duas estimativas testadas, o resultado de F apresenta p-valor muito baixo, indicando a presença de heterocedasticidade nos modelos. Como esta é uma hipótese que gera inconsistência na definição dos erros padrão do modelo, uma alternativa para minimizar a heterocedasticidade é a utilização da correção robusta de White. White (1980) aponta que os verdadeiros valores dos parâmetros são estimados a partir de inferências estatísticas válidas pelo ajuste do erro padrão. Assim sendo, os resultados corrigidos são apresentados na Tabela 12 e as linhas de código podem ser visualizadas no Apêndice E.

A Tabela 13 resume assim os resultados das elasticidades estimadas através de um modelo de painel estático com os coeficientes todos com significância menor que 5%. É possível observar que a elasticidade-preço da demanda tem resultado dentro do exposto pela literatura e próximo da referência padrão de -0,30 para o modelo com as nove metrópoles. A elasticidade-renda da demanda resultou em um valor próximo aos resultados de Balcombe *et al.* (2004), Tsai *et al.* (2014), Tsai e Mulley (2014) e Jia *et al.* (2016). Ademais, a qualidade do serviço resultou em um valor ligeiramente mais alto do que Crotte *et al.* (2011) para o painel com efeito fixo.

Tabela 12 – Modelos de regressão com correção robusta de White

Variáveis Explicativas	Coeficiente parcial (erro padrão)	
	Nove cidades	Sem São Paulo
Tarifa (em log)	-0,498* (0,213)	-0,604* (0,238)
Renda (em log)	-0,278* (0,133)	-0,288 (0,185)
Km percorrida/área (em log)	0,759*** (0,103)	0,554*** (0,136)
Idade da frota (em log)	-0,122*** (0,018)	-0,113*** (0,019)
<i>Tendência</i>		
2008	0,043. (0,022)	0,062** (0,019)
2009	0,044 (0,060)	0,090* (0,044)
2010	0,174* (0,070)	0,211** (0,073)
2011	0,169* (0,081)	0,215** (0,077)
2012	0,254* (0,114)	0,320** (0,119)
2013	0,289* (0,113)	0,332* (0,140)
2014	0,302* (0,124)	0,342* (0,163)
2015	0,346* (0,161)	0,389. (0,213)
2016	0,361. (0,191)	0,419. (0,245)
2017	0,369. (0,204)	0,414 (0,275)

Fonte: a autora, 2018 (por meio da base de dados secundários).
 Legenda: '***'p<0,001; '**'p<0,01; '*'p<0,05; '.'p<0,1; ' 'p<1

Tabela 13 – Resumo das elasticidades obtidas através do painel estático

Elasticidade	Modelo com nove cidades	Modelo sem São Paulo
Tarifa principal	-0,498*	-0,604*
Renda média anual	-0,278*	Sem significância
Qualidade do serviço (km/área)	0,759***	0,554***
Idade da Frota	-0,122***	-0,113***

Fonte: a autora, 2018 (por meio da base de dados secundários).
 Legenda: '***'p<0,001; '**'p<0,01; '*'p<0,05; '.'p<0,1; ' 'p<1

Os parâmetros obtidos apresentam sinal conforme a literatura, tendo a tarifa um efeito negativo na quantidade demandada juntamente com aumento da idade da frota de veículos do sistema público. Além do mais, a renda também possui efeito negativo, podendo indicar uma tendência da definição do transporte público como bem inferior, do mesmo modo que é indicado na literatura. A qualidade do serviço pela questão da abrangência de atendimento também apresentou sinal condizente com a literatura, sendo este o parâmetro com maior intensidade do modelo.

Dessa forma, as elasticidades encontradas indicam uma importância maior para políticas públicas voltadas para a melhoria da qualidade do serviço. Como segundo aspecto, a elasticidade preço aponta que uma redução nas tarifas tem potencial de atrair novos passageiros para o sistema. Estes dois aspectos são importantes para nortear as políticas públicas a fim de obter resultados mais efetivos de frear a perda de demanda no transporte público.

O modelo estático resultou em informações relevantes sobre o comportamento da demanda por transporte público nas metrópoles brasileiras de forma geral, trazendo a indicação de fatores que influenciam significativamente a demanda nessas cidades. No entanto, esse modelo traz apenas as intensidades de variação da demanda de maneira imediata, ou seja, as elasticidades no curto prazo, não apresentando assim o efeito de determinada ação com o passar de certo período. Dessa forma, a estimação de um painel dinâmico é necessária para verificar a existência de influências no longo prazo e constatar as intensidades das elasticidades no curto prazo, como nos resultados apresentados na seção 5.3.

5.3 RESULTADOS DO PAINEL DINÂMICO

Na estimação de um modelo com painel dinâmico, não é possível utilizar a regressão com dados empilhados, efeito fixo ou aleatório, visto que a adição de uma variável defasada da demanda como regressor geraria um efeito de endogeneidade no modelo. Isso ocorre porque a demanda defasada possui correlação com o termo do erro e gera inconsistência na estimativa. Por isso, quando se tem regressores endógenos ou possíveis erros de medição, a estimativa do método dos momentos generalizados (MGM) é uma boa alternativa. A justificativa é que esse estimador produz estimativas de parâmetros consistentes, removendo os efeitos individuais e permite que a relação da demanda possua heterogeneidade não observada e o período de ajuste. Dessa forma, é pertinente usar para estimativas de demanda de transporte (GRAHAM *et al.*, 2009; DEB; FILIPPINI, 2013).

Como no painel estático existe este obstáculo para definição das elasticidades em longo prazo e devido à possibilidade da existência de endogeneidade neste modelo, o painel dinâmico foi escolhido para a segunda etapa de estimativas. A endogeneidade ocorre como resultado da relação das variáveis independentes com o termo do erro. No entanto, esta particularidade pode ser minimizada com a utilização do método dos momentos generalizados, já utilizado no estudo da demanda por transporte público, por exemplo, por Graham *et al.*, (2009), Deb e Filippini, (2013) e Daldoul *et al.*, (2016). Por isso, a estimativa

para o modelo mais adequado do painel estático foi refeita para o painel dinâmico com o objetivo de buscar resultados mais consistentes. Estes coeficientes estão exibidos na Tabela 14.

Tabela 14 – Resultado da regressão pelo MGM

Variáveis Explicativas	Coeficiente parcial (erro padrão)	
	Nove cidades	Sem São Paulo
Tarifa (em log)	-0,466** (0,161)	-0,416* (0,158)
Renda (em log)	-0,122 (0,125)	-0,108 (0,097)
Km percorrida/área (em log)	0,741*** (0,069)	0,469*** (0,074)
Idade da frota (em log)	-0,091*** (0,026)	-0,087*** (0,020)
<i>Tendência</i>		
2008	-0,119 (0,081)	-0,093 (0,075)
2009	-0,130. (0,065)	-0,104. (0,058)
2010	-0,035 (0,038)	-0,023 (0,037)
2011	-0,041 (0,031)	-0,032 (0,030)
2012	0,014 (0,014)	0,026* (0,013)
2013	0,036. (0,019)	0,017 (0,016)
2014	0,028 (0,027)	0,022 (0,022)
2015	0,065 (0,043)	0,045 (0,039)
2016	0,086 (0,062)	0,075 (0,060)
2017	0,096 (0,077)	0,067 (0,078)
Demanda Defasada	0,215** (0,061)	0,396** (0,074)
Observações	81	72
R ²	0,664	0,607

Fonte: a autora, 2018 (por meio da base de dados secundários).

Legenda: ‘***’ p<0,001; ‘**’ p<0,01; ‘*’ p<0,05; ‘.’ p<0,1; ‘ ’ p<1

Como a renda não apresentou significância para nenhum dos dois modelos e o R² do modelo das nove cidades foi maior desta vez, outros modelos foram testados e os dez mais relevantes estão apresentados nas Tabela 15 e Tabela 16 e as linhas de código no Apêndice F. Os quatro testes iniciais e o décimo teste são feitos com a renda no modelo para verificar se a mesma apresenta significância em alguma das situações. Porém, em nenhuma das situações, a renda se apresentou como relevante.

Sobre a variável qualidade do serviço, mais uma vez, foram testadas as normatizações pela população e área, sendo novamente a divisão pela área o melhor resultado. Assim, a partir do sexto modelo, as estimativas foram feitas para a qualidade do serviço representada pela quilometragem percorrida dividida pela área. Do modelo (6) ao (10) foram testadas as variáveis: idade da frota, frota de motos, preço da gasolina e o Uber.

Tabela 15 – Resultados dos modelos dinâmicos mais relevantes

Variáveis Explicativas	Coeficiente parcial (erro padrão)				
	(1)	(2)	(3)	(4)	(5)
Tarifa (em log)	-0,860** (0,272)	-0,540** (0,179)	-0,543** (0,179)	-0,494** (0,179)	-0,521** (0,176)
Renda (em log)	-0,144 (0,221)	-0,068 (0,143)	-0,067 (0,143)	-0,040 (0,142)	
Km percorrida per capita (em log)		0,706*** (0,077)			0,706*** (0,077)
Km percorrida per capita/área (em log)			0,702*** (0,077)		
Km percorrida/área (em log)				0,712*** (0,077)	
<i>Tendência</i>					
2008	-0,246. (0,141)	-0,141 (0,092)	-0,142 (0,092)	-0,099 (0,092)	-0,104. (0,053)
2009	-0,209. (0,113)	-0,122 (0,074)	-0,123 (0,074)	-0,092 (0,074)	-0,091* (0,040)
2010	-0,105 (0,065)	-0,062 (0,042)	-0,062 (0,043)	-0,023 (0,043)	-0,047 (0,032)
2011	-0,057 (0,054)	-0,047 (0,035)	-0,047 (0,035)	-0,016 (0,035)	-0,033 (0,021)
2012	0,011 (0,023)	0,002 (0,015)	0,002 (0,015)	0,020 (0,015)	0,002 (0,019)
2013	0,090** (0,032)	0,045* (0,022)	0,046* (0,022)	0,034 (0,022)	0,038* (0,015)
2014	0,054 (0,046)	0,029 (0,030)	0,029 (0,030)	0,011 (0,030)	0,017 (0,015)
2015	0,101 (0,075)	0,074 (0,049)	0,075 (0,049)	0,043 (0,049)	0,055. (0,030)
2016	0,179 (0,108)	0,106 (0,070)	0,107 (0,070)	0,063 (0,070)	0,080. (0,048)
2017	0,182 (0,133)	0,114 (0,086)	0,115 (0,086)	0,060 (0,086)	0,083 (0,060)
Demanda Defasada	0,565*** (0,091)	0,269*** (0,068)	0,271*** (0,068)	0,256*** (0,068)	0,267*** (0,067)
Observações	81	81	81	81	81
R ²	0,137	0,583	0,581	0,586	0,584

Fonte: a autora, 2018 (por meio da base de dados secundários).

Legenda: '***'p<0,001; '**'p<0,01; '*'p<0,05; '.'p<0,1; ' 'p<1

Tabela 16 – Resultados dos modelos dinâmicos mais relevantes (continuação)

Variáveis Explicativas	Coeficiente parcial (erro padrão)				
	(6)	(7)	(8)	(9)	(10)
Tarifa (em log)	-0,479** (0,176)	-0,444*** (0,158)	-0,448** (0,160)	-0,426** (0,153)	-0,485** (0,163)
Renda (em log)					-0,213 (0,135)
Km percorrida/área (em log)	0,712*** (0,077)	0,754*** (0,068)	0,752*** (0,069)	0,760*** (0,068)	0,737*** (0,070)
Idade da frota (em log)		-0,088** (0,025)	-0,088** (0,026)	-0,086** (0,025)	-0,089** (0,026)
Frota de Moto (em log)				0,073 (0,064)	0,132. (0,074)
Preço da gasolina (em log)			0,074 (0,246)		0,023 (0,243)
Uber					0,011 (0,028)
<i>Tendência</i>					
2008	-0,076 (0,053)	-0,056 (0,048)	-0,045 (0,059)	-0,023 (0,055)	-0,110 (0,091)
2009	-0,073. (0,040)	-0,077* (0,035)	-0,066 (0,050)	-0,053 (0,040)	-0,127 (0,078)
2010	-0,014 (0,033)	-0,011 (0,029)	-0,002 (0,043)	0,003 (0,031)	-0,026 (0,051)
2011	-0,008 (0,021)	-0,016 (0,019)	-0,011 (0,025)	-0,010 (0,020)	-0,046 (0,038)
2012	0,020 (0,015)	0,014 (0,013)	0,020 (0,023)	0,014 (0,013)	0,017 (0,025)
2013	0,030. (0,015)	0,022 (0,014)	0,025 (0,017)	0,016 (0,015)	0,039. (0,022)
2014	0,003 (0,015)	0,006 (0,014)	0,005 (0,014)	-0,004 (0,016)	0,028 (0,026)
2015	0,031 (0,030)	0,032 (0,027)	0,022 (0,042)	0,016 (0,029)	0,062 (0,056)
2016	0,046 (0,048)	0,042 (0,043)	0,026 (0,069)	0,022 (0,045)	0,076 (0,089)
2017	0,040 (0,060)	0,044 (0,054)	0,026 (0,078)	0,019 (0,057)	0,086 (0,101)
Demanda Defasada	0,254*** (0,067)	0,206** (0,060)	0,209** (0,062)	0,198** (0,060)	0,200** (0,064)
Observações	81	81	81	81	81
R ²	0,587	0,669	0,665	0,672	0,662

Fonte: a autora, 2018 (por meio da base de dados secundários).

Legenda: ‘***’p<0,001; ‘**’p<0,01; ‘*’p<0,05; ‘.’p<0,1; ‘ ’p<1

A idade da frota apresenta sinal contrário à demanda e é significativa, como no modelo com painel estático, continuando relevância para o modelo. Em contrapartida, a frota de motos continua com o sinal contrário ao esperado e perdeu a significância, sendo esta uma variável novamente excluída do modelo. O preço da gasolina, da mesma forma, está com o sinal positivo e sem significância, resultando também na exclusão do modelo. Enfim, a variável Uber continua com efeito contrário ao esperado e sem significância.

Portanto, a estimativa com resultado mais adequado é o Modelo (7) com três variáveis significativas: tarifa, quilometragem percorrida pela área e idade da frota. A Tabela

17 apresenta os resultados em curto e longo prazo das elasticidades da demanda. Estes coeficientes reportados estão na faixa dos valores definidos para elasticidade-preço e possuem valores ligeiramente mais altos que Wang (2009) e Crotte *et al.* (2011) para qualidade do serviço pela quilometragem, mesmo com o intervalo de confiança menor que 0,1%. Esta variação na intensidade do fator qualidade pode ter ocorrido pela diferença entre a estimação dos autores feita com a quilometragem dividida pela população e a desta pesquisa sendo a quilometragem normatizada pela área.

Tabela 17 – Resumo das elasticidades obtidas através do MGM com painel dinâmico

Elasticidade	Curto Prazo	Longo Prazo
Tarifa principal	-0,444***	-0,559**
Qualidade do serviço (km/área)	0,754***	0,950**
Idade da Frota	-0,088**	-0,111**

Fonte: a autora, 2018 (por meio da base de dados secundários).

Legenda: ‘***’ $p < 0,001$; ‘**’ $p < 0,01$; ‘*’ $p < 0,05$; ‘.’ $p < 0,1$; ‘ ’ $p < 1$

Os resultados encontrados apontam, em primeiro lugar, que a demanda por transporte público nas metrópoles brasileiras é inelástica. Isto é, os valores das elasticidades estão todos entre zero e um. Ainda assim, estes são valores condizentes com a literatura e com os valores padrões de elasticidade. O parâmetro mais inelástico do modelo é a idade da frota, com valor muito próximo a zero. Esse indicador pode ser considerado também como fator de qualidade do serviço, já que uma redução na idade da frota através da aquisição de novos ônibus pode resultar em uma sensação para os usuários de maior conforto. Entretanto, na literatura estudada não foi identificado um fator semelhante.

O segundo aspecto é que as elasticidades encontradas, tanto pelos MQO como pelo MGM estão próximas à literatura pesquisada. Os valores encontrados no segundo modelo não apresentam uma diferença expressiva entre as estimativas em curto e longo prazo, mesmo ainda sendo significantes. Este fato também é visível na literatura no estudo de Deb e Filippini (2013) na Índia, por exemplo, para o sistema também de ônibus que apresenta valores de elasticidade-preço de -0,37 e -0,52 no curto e no longo prazo, respectivamente. A intensidade da elasticidade preço no longo prazo foi aproximadamente 12% maior que no curto prazo, indicando que existe pouca adaptação dos passageiros usuários do sistema público num período maior. Esta característica pode indicar também a necessidade da implantação ou do aumento do subsídio tarifário a fim de atrair novos passageiros, dado que a quase totalidade dos sistema são praticamente custeados exclusivamente com o valor da tarifa cobrada aos usuários.

Ainda no aspecto do longo prazo, o cálculo desse parâmetro torna possível aos planejadores definirem as metas das políticas públicas a partir não somente do efeito imediato de certas estratégias, mas também da adaptação ao que ocorre com o passar do tempo. Neste caso, se o efeito considerado fosse apenas do curto prazo, existiria uma diferença de aproximadamente 12% para o caso de modificações na tarifa, aproximadamente 20% na qualidade do serviço e 2% para ações relativas a aquisição de veículos novos. Ademais, os parâmetros de longo prazo indicam a tendência das ações que devem ser feitas para que a demanda seja sustentável para os próximos anos. Sendo assim, a orientação é a ação conjunta da melhoria de atendimento do sistema, diminuição da idade da frota de transportes públicos e redução das tarifas através de subsídios.

Um terceiro resultado com relevância para discussão é a perda de significância da elasticidade-renda da demanda no painel dinâmico. Uma possibilidade para ocorrência deste fato é, como explicitado no item 5.1, as características dos dados de renda disponíveis para o período estudado. A forma agregada da média do salário de todos os trabalhos possivelmente ocultou o efeito da renda da população em geral e principalmente da faixa de pessoas que utilizam o transporte público, fazendo assim com que a renda, mesmo sendo uma variável clássica de previsão de demanda, fosse excluída do modelo.

Por fim, a quarta constatação relevante do estudo refere-se à intensidade das elasticidades. De modo geral, as elasticidades encontradas apontam que a melhoria na qualidade do serviço possui maior influência na demanda que a redução de tarifas, como mostrado também pela literatura. Assim sendo, as ações referentes ao transporte público que podem ser sugeridas a partir dos resultados encontrados são voltadas para a melhoria da qualidade do serviço de transporte público de forma geral. Coerentemente, as especificidades de cada localidade irão indicar os pontos onde devem ser implantadas as melhorias, contudo pode-se concluir genericamente que a qualidade do serviço deve ser enfocada.

6 CONSIDERAÇÕES FINAIS

Análises sobre a demanda por transporte público é um tema recorrente na literatura especializada, tendo em vista à necessidade crescente da percepção dos fatores que podem influenciar o uso desse tipo de transporte. Os primeiros estudos catalogados sobre o tema foram voltados para o atendimento das necessidades de uma diminuição da demanda por transporte público em países desenvolvidos, sendo seguidos por pesquisas que buscavam a melhoria do sistema e a atração de novos passageiros. Atualmente, grande parte dos estudos tem com cenário os países em desenvolvimento e visa buscar soluções para os sistemas existentes ou prever a viabilidade da implantação de novos sistemas.

Em vista disso, este estudo analisou a sensibilidade da demanda dos sistemas de transportes públicos por ônibus urbanos das nove metrópoles brasileiras através das variáveis estudadas na literatura e disponíveis neste cenário para aplicação em modelos econométricos. Dados em painel foram obtidos para as cidades de Belo Horizonte, Curitiba, Fortaleza, Goiânia, Porto Alegre, Recife, Rio de Janeiro, Salvador e São Paulo num período de 11 anos para a estimativa da demanda agregada através do modelo direto de estimação das elasticidades. Os modelos aplicados foram em painel estático e dinâmico pelos MQO e MGM, o último para considerar o efeito da endogeneidade na função e as elasticidades da tarifa, renda, quilometragem percorrida e idade da frota foram encontradas. O intuito principal foi buscar fatores comuns que podem estar influenciando a diminuição da demanda por transporte público em metrópoles brasileiras nos últimos anos.

Os resultados encontrados mostraram que a demanda é inelástica aos fatores que a influenciam, sendo todas as elasticidades entre zero e um. Ainda, as elasticidades encontradas tanto pelos MQO como pelo MGM são condizentes com a literatura estudada em intensidade e sinal. Para o painel estático, o modelo testado com as nove metrópoles incluídas trouxe melhor resultado do que o modelo com a exclusão de São Paulo e resultou em elasticidades significativas do preço, renda, qualidade do serviço por meio da disponibilidade de acesso das pessoas ao transporte, e a idade da frota de ônibus urbanos.

Os fatores encontrados apontam que a atuação das políticas públicas voltadas para qualidade do serviço terão resultados mais expressivos que ajustes na tarifa, como visto também na literatura estudada, mesmo o preço ainda sendo o segundo fator mais significativo do modelo. Outra questão importante da pesquisa é que o modelo estático traz resultados relevantes no curto prazo com intensidades adequadas, no entanto existe uma lacuna na definição do efeito no longo prazo. Dessa forma, o painel dinâmico confirma a tendência e as

intensidades dos fatores no curto prazo e apresenta o impacto em um período maior de tempo. Contudo, este modelo gerou a perda na significância da elasticidade renda, resultando assim na não influência da renda na demanda por transporte público no modelo dinâmico, provavelmente devido ao tipo do dado secundário utilizado.

Transcorrendo para a discussão do modelo e dados secundários utilizados, as ressalvas a serem feitas estão relacionadas à agregação das informações. O painel composto de informações de transporte com agregação anual e junção das metrópoles brasileiras com portes diferentes tendem a resultar em regressões com parâmetros mais genéricos. Isto é, os resultados podem apresentar atributos importantes superestimados, como aponta Rahman e Balijepalli (2016) e características específicas das cidades ou regiões camufladas. Mesmo assim, a estimativa resultante dos modelos é válida para indicar as tendências gerais do cenário brasileiro através de estudo anual, podendo apontar para a formulação de políticas de abrangência nacional.

Por último, a indicação para trabalhos futuros é de análise mais aprofundada dos sistemas de transportes públicos brasileiros através de informações operacionais mais detalhadas. A primeira sugestão é a obtenção de dados desagregados por período do dia, enfatizando assim as necessidades da demanda nos horários de pico. O segundo aspecto é o estudo com amostras maiores por metrópole, para obtenção dos dados individualizados das cidades que possam dar conta das peculiaridades locais. A terceira indicação é do estudo que agregue os dados dos sistemas de metrô para as cidades onde essa infraestrutura existe, visto que este é um serviço complementar ao sistema de ônibus urbanos. Como última indicação, é importante ressaltar a necessidade de buscar novas variáveis que possam atuar fortemente as nove metrópoles brasileiras do estudo, como por exemplo, a taxa de desemprego. A contínua diminuição da quantidade demandada por transporte público a partir do ano de 2014 em todas as nove metrópoles do estudo pode também ter influenciado o aumento da taxa de desemprego, visto que a partir do ano de 2013 o Brasil se encontra em um cenário de crise econômica. Sendo assim, busca por dados secundários relativos à taxa de desemprego no país é uma indicação relevante para o período estudado.

REFERÊNCIAS

- ANP – Agência Nacional do Petróleo, Gás Natural e Biocombustíveis. **Série histórica do levantamento de preços e de margens de comercialização de combustíveis**. Brasília, 2018. Disponível em: <http://www.anp.gov.br/precos-e-defesa/234-precos/levantamento-de-precos/868-serie-historica-do-levantamento-de-precos-e-de-margens-de-comercializacao-de->. Acesso em: 19 jul. 2018.
- ANTP – Associação Nacional dos Transportes Públicos. **Custos dos Serviços de Transporte Público por Ônibus: Método de Cálculo**. São Paulo: ANTP, 2017. Disponível em: <http://files.antp.org.br/2017/8/21/1.-metodo-de-calculo--final-impresso.pdf>. Acesso em: 07 jan. 2019.
- ANUÁRIO DE FORTALEZA. **Mobilidade Urbana – Transporte Público**. Fortaleza: O Povo, 2013. Disponível em: <http://www.anuariodefortaleza.com.br/infraestrutura/transporte-publico.php>. Acesso em: 28 nov. 2018.
- ARELLANO, M.; BOND, S. Some tests of specification for panel data: Monte Carlo evidence and an application to employment equations. **The Review of Economic Studies**, v. 58, n. 2, p. 277-297, 1991. DOI: <https://doi.org/10.2307/2297968>. Disponível em: <https://academic.oup.com/restud/article-abstract/58/2/277/1563354?redirectedFrom=fulltext>. Acesso em: 12 set. 2018.
- BALCOMBE, R.; MACKETT, R.; PAULLEY, N.; PRESTON, J.; SHIRES, J.; TITHERIDGE, H.; WARDMAN, M.; WHITE, P. **The Demand for Public Transport: A Practical Guide**. TRL Report TRL593. Wokingham, UK: Transport Research Laboratory, 2004. Disponível em: <https://trl.co.uk/sites/default/files/TRL593%20-%20The%20Demand%20for%20Public%20Transport.pdf>. Acesso em: 30 maio 2017.
- BALTAGI, B. **Econometric Analysis of Panel Data**. 3. ed. Chichester: Wiley & Sons, 2005.
- BELO HORIZONTE. **Empresa De Transportes E Trânsito De Belo Horizonte**. Belo Horizonte, 2018. Disponível em: <https://prefeitura.pbh.gov.br/bhtrans>. Acesso em: 28 nov. 2018.
- BELO HORIZONTE. **Plano Diretor de Mobilidade Urbana de Belo Horizonte – PLANMOB-BH 2030 – Relatório Síntese**. Belo Horizonte: BHTRANS, 2017. Disponível em: http://www.bhtrans.pbh.gov.br/portal/pls/portal/!PORTAL.wwpob_page.show?_docname=10830274.PDF. Acesso em: 28 nov. 2018.
- BRASIL. **Cálculo de Tarifas de Ônibus Urbanos: Instruções Práticas Atualizadas**. Brasília, Ministério dos Transportes, 1996. Disponível em: http://www.geipot.gov.br/estudos_realizados/cartilha/instrucoes/pag1.htm. Acesso em: 24 jan. 2019.
- BRECHAN, I. Effect of Price Reduction and Increased Service Frequency on Public Transport Travel. **Journal of Public Transportation**. Florida, v. 20, n. 1, p. 139-156, 2017. DOI: <https://doi.org/10.5038/2375-0901.20.1.8>. Disponível em: <https://scholarcommons.usf.edu/jpt/vol20/iss1/8/>. Acesso em: 13 nov. 2017.

BRESSON, G.; DARGAY, J.; MADRE, J. L.; PIROTTE, A. The main determinants of the demand for public transport: a comparative analysis of England and France using shrinkage estimators. **Transportation Research Part A: Policy and Practice**, v. 37, n.7, p. 605-627, 2003. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0965856403000090>. Acesso em: 30 maio 2017.

BRTRIO. **Conheça o BRT**. Rio de Janeiro (Município): BRT Rio, 2018. Disponível em: <http://www.brtrio.com/conheca>. Acesso em: 28 nov. 2018.

BURGUILLO, M.; ROMERO-JORDÁN, D.; SANZ-SANZ, J. F. The new public transport pricing in Madrid Metropolitan Area: A welfare analysis. **Research in Transportation Economics**, v. 62, p. 25-36, 2017. DOI: <https://doi.org/10.1016/j.retrec.2017.02.005>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0739885917300264>. Acesso em 31 maio 2017.

CARVALHO, C. H. R.; PEREIRA, R. H. M. **Efeitos da variação da tarifa e da renda da população sobre a demanda de transporte público coletivo urbano no Brasil**. Texto para Discussão - TD 1595. Brasília, Instituto de Pesquisa Econômica Aplicada (IPEA), 2011. Disponível em: http://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=9767. Acesso em: 06 jun. 2017.

CBTU – Companhia Brasileira de Trens Urbanos. **O Metrô de Belo Horizonte**. Belo Horizonte: CBTU, 2018a. Disponível em: <https://www.cbtu.gov.br/index.php/pt/empresa-bh/historia-bh>. Acesso em: 28 nov. 2018.

CBTU – Companhia Brasileira de Trens Urbanos. **Conhecendo a cidade do Recife**. Recife: CBTU, 2018b. Disponível em: <https://www.cbtu.gov.br/index.php/pt/empresa-recife/historia>. Acesso em: 28 nov. 2018.

CHAO, M.; HUANG, W.; JOU, R. The asymmetric effects of gasoline prices on public transportation use in Taiwan. **Transportation Research Part D: Transport and Environment**, v. 41, p. 75-87, 2015. DOI: <https://doi.org/10.1016/j.trd.2015.09.021>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1361920915001455>. Acesso em: 14 mar. 2018.

CORDERA, R.; CANALES, C.; DELL'OLIO, L.; IBEAS, A. Public transport demand elasticities during the recessionary phases of economic cycles. **Transport Policy**, v. 42, p. 173-179, 2015. DOI: <https://doi.org/10.1016/j.tranpol.2015.05.022>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0967070X15300184>. Acesso em: 01 jun. 2017.

CPTM – Companhia Paulista de Trens Metropolitanos. **Nossa História**. São Paulo (Estado): CPTM, 2018. Disponível em: <http://www.cptm.sp.gov.br/a-companhia/Pages/Nossa-Historia.aspx>. Acesso em: 28 nov. 2018.

CROISSANT, Y.; MILLO, G. Panel data econometrics in R: the plm package. **Journal of Statistical Software**, v.27, n. 2, 2008. DOI: <https://doi.org/10.18637/jss.v027.i02>. Disponível em: <https://www.jstatsoft.org/article/view/v027i02>. Acesso em: 20 set. 2018.

CROTTE, A.; GRAHAM, D. J.; NOLAND, R. B. The role of metro fares, income, metro quality of service and fuel prices for sustainable transportation in Mexico City. **International Journal of Sustainable Transportation**, v. 5, n. 1, p. 1-24, 2011. DOI:

<https://doi.org/10.1080/15568310903050073>. Disponível em:

<https://www.tandfonline.com/doi/abs/10.1080/15568310903050073>. Acesso em: 05 abr. 2018.

CURITIBA. **Plano Diretor de Curitiba** – Versão para Avaliação na Plenária Expandida do Concitiba. Curitiba: IPPUC , 2015. Disponível em:

<http://www.ippuc.org.br/planodiretor2014/arquivos/Resumo%20das%20Propostas%20A4.pdf> . Acesso em: 28 nov. 2018.

DALDOUL, M.; JARBOUI, S.; DAKHLAOUI, A. Public transport demand: dynamic panel model analysis. **Transportation**, v. 43, n.3, p. 491-505. 2016. DOI:

<https://doi.org/10.1007/s11116-015-9586-1>. Disponível em:

<https://link.springer.com/article/10.1007/s11116-015-9586-1>. Acesso em: 01 jun. 2017.

DE GRANGE, L.; GONZÁLEZ, F.; MUÑOZ, J. C.; TRONCOSO, R. Aggregate estimation of the price elasticity of demand for public transport in integrated fare systems: The case of Transantiago. **Transport Policy**, v. 29, p. 178-185, 2013. DOI:

<https://doi.org/10.1016/j.tranpol.2013.06.002>. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0967070X13000899>. Acesso em: 05 jun. 2017.

DEB, K.; FILIPPINI, M. Public bus transport demand elasticities in India. **Journal of Transport Economics and Policy (JTEP)**, v. 47, n. 3, p. 419-436, 2013. Disponível em:

https://www.jstor.org/stable/24396342?seq=1#page_scan_tab_contents. Acesso em: 06 abr. 2018.

DENATRAN - Departamento Nacional de Trânsito. **Relatórios Estatísticos da frota de veículos no Brasil**. Brasília, 2018. Disponível em:

<https://www.denatran.gov.br/estatistica/237-frota-veiculos>. Acesso em: 19 jul. 2018.

EFTHYMIU, D.; ANTONIOU, C. Understanding the effects of economic crisis on public transport users' satisfaction and demand. **Transport Policy**, v. 53, p. 89-97, 2017. DOI:

<https://doi.org/10.1016/j.tranpol.2016.09.007>. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0967070X16306163>. Acesso em: 06 abr. 2018.

FITZROY, F.; SMITH, I. The demand for public transport: some estimates from Zurich.

International Journal of Transport Economics/Rivista internazionale di economia dei trasporti, v.21, n.2, p. 197-207, 1994. Disponível em:

https://www.jstor.org/stable/42747491?seq=1#page_scan_tab_contents. Acesso em: 20 set. 2018.

FORTALEZA. **Canal Mobilidade**. Fortaleza: Prefeitura de Fortaleza, 2018. Disponível em:

<https://mobilidade.fortaleza.ce.gov.br/transporte/etufor.html>. Acesso em: 28 nov. 2018.

FULLERTON JR, T. M.; WALKE, A. G. Public transportation demand in a border metropolitan economy. **Applied Economics**, v. 45, n. 27, p. 3922-3931, 2013. DOI:

<https://doi.org/10.1080/00036846.2012.736945>. Disponível em:
<https://www.tandfonline.com/doi/abs/10.1080/00036846.2012.736945?journalCode=raec20>.
 Acesso em: 05 abr. 2018.

GOODWIN, P. B. A Review of New Demand Elasticities with Special Reference to Short and Long Run Effects of Price Changes. **Journal of Transport Economics and Policy**, v.26, n.2, p. 155-169, 1992. Disponível em:
https://www.jstor.org/stable/20052977?seq=1#page_scan_tab_contents. Acesso em: 12 set. 2018.

GRAHAM, D. J.; CROTTE, A.; ANDERSON, R. J. A dynamic panel analysis of urban metro demand. **Transportation Research Part E: Logistics and Transportation Review**, v. 45, n. 5, p. 787-794, 2009. DOI: <https://doi.org/10.1016/j.tre.2009.01.001>. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S1366554509000027>. Acesso em: 05 abr. 2018.

GRANDE RECIFE. **Sistema Estrutural Integrado – SEI**. Recife: Grande Recife Consórcio de Transporte, 2018. Disponível em: <http://www.granderecife.pe.gov.br/sitegrctm/transporte/>. Acesso em: 28 nov. 2018.

GUJARATI, D. N.; PORTER, D. C. **Econometria Básica**. 5. ed. Porto Alegre: Amgh, 2011.

HENSHER, D. A. Assessing systematic sources of variation in public transport elasticities: some comparative warnings. **Transportation Research Part A: Policy and Practice**, v. 42, n. 7, p. 1031-1042, 2008. DOI: <https://doi.org/10.1016/j.tra.2008.02.002>. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S0965856408000669>. Acesso em: 01 jun. 2017.

HOFFMANN, R. **Análise de Regressão: Uma Introdução à Econometria**. São Paulo: Biblioteca Digital da Produção Intelectual. Portal de Livros Abertos da USP DOI: <https://doi.org/10.11606/9788592105709>. Disponível em:
<http://www.livrosabertos.sibi.usp.br/portaldelivrosUSP/catalog/download/73/64/310-1?inline=1>. Acesso em: 4 out. 2018.

HOLMGREN, J. Meta-analysis of public transport demand. **Transportation Research Part A: Policy and Practice**, v. 41, n.10, p. 1021-1035, 2007. DOI: <https://doi.org/10.1016/j.tra.2007.06.003>. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S096585640700047X>. Acesso em: 2 maio 2017.

HOLMGREN, J.; JANSSON, J. O.; LJUNGBERG, A. Public transport in towns – Inevitably on the decline? **Research in Transportation Economics**, v. 23, n. 1, p. 65-74, 2008. DOI: <https://doi.org/10.1016/j.retrec.2008.10.011>. Disponível em:
<https://www.sciencedirect.com/science/article/abs/pii/S0739885908000449>. Acesso em: 05 abr. 2018.

HOLMGREN, J. An analysis of the determinants of local public transport demand focusing the effects of income changes. **European Transport Research Review**, v. 5, n.2, p. 101-107, 2013. DOI: <https://doi.org/10.1007/s12544-013-0094-0>. Disponível em:
<https://link.springer.com/article/10.1007/s12544-013-0094-0>. Acesso em: 2 maio 2017.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Base de Dados das pesquisas e censos do IBGE**. Brasília, 2018. Disponível em: <https://www.ibge.gov.br/estatisticas-novoportal/downloads-estatisticas.html>. Acesso em: 11 out. 2017.

JIA, W.; CHEN, X.; SUN, C. Modeling the Impact of Macroeconomic Factors on Multimodal Transport Demand: A Cointegration Approach. *In: COTA International Conference of Transportation Professionals*, 16. 2016, Xangai. **CICTP 2016: Green and Multimodal Transportation and Logistics**. Xangai: ASCE, 2016. p. 2031-2043. DOI: <https://doi.org/10.1061/9780784479896.184>.

MADDALA, G.S. **Introduction to econometrics**. 3. ed. Nova Jersey: Wiley & Sons, 2001.

MARSHALL, A. **Principles of Economics**: Palgrave Classics in Economics. London: Palgrave Macmillan, 2013.

MAS-COLELL, A.; WHINSTON, M. D.; GREEN, J. R. **Microeconomic theory**. New York: Oxford University Press, 1995.

MATAS, A. Demand and revenue implications of an integrated public transport policy: the case of Madrid. **Transport Reviews**, v. 24, n. 2, p. 195-217, 2004. DOI: <https://doi.org/10.1080/0144164032000107223>. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/0144164032000107223>. Acesso em: 20 set. 2018.

METRO SÃO PAULO. **Empresa**. São Paulo (Estado): Portal do Governo, 2018. Disponível em: <http://www.metro.sp.gov.br/metro/index.aspx>. Acesso em: 28 nov. 2018.

METROFOR. **Sistema Metroviário**. Fortaleza: Secretaria de Infraestrutura, 2018. Disponível em: <https://www.metrofor.ce.gov.br/sistema-metroviario/>. Acesso em: 28 nov. 2018.

METRORIO. **Sobre o MetrôRio**. Rio de Janeiro (Município): Invepar, 2018. Disponível em: <https://www.metrorio.com.br/Empresa/Sobre>. Acesso em: 28 nov. 2018.

NTU – Associação Nacional das Empresas de Transportes Urbanos. **Anuário NTU: 2014 – 2015**. Brasília: NTU, 2015. Disponível em: <https://www.ntu.org.br/novo/upload/Publicacao/Pub635750751477026645.pdf>. Acesso em: 19 nov. 2018.

NTU – Associação Nacional das Empresas de Transportes Urbanos. **Anuário NTU: 2017 – 2018**. Brasília: NTU, 2018a. Disponível em: <https://www.ntu.org.br/novo/upload/Publicacao/Pub636687203994198126.pdf>. Acesso em: 24 jan. 2019.

NTU – Associação Nacional das Empresas de Transportes Urbanos. **Recorte de Dados do Transporte Público para o Período de 2007-2017**. Brasília, 2018b. 1 mensagem eletrônica.

PAULLEY, N.; BALCOMBE, R.; MACKETT R.; TITHERIDGE, H.; PRESTON, J.; WARDMAN M.; SHIRES, J.; WHITE, P. The demand for public transport: The effects of fares, quality of service, income and car ownership. **Transport Policy**, v. 13, n.4, p. 295-306, 2006. DOI: <https://doi.org/10.1016/j.tranpol.2005.12.004>. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0967070X05001587>. Acesso em: 3 abr. 2017.

PINDYCK, R. S.; RUBINFELD, D. L. **Econometria: Modelos & Previsões**. Tradução da 4. ed. São Paulo: Campus, 2004.

PINDYCK, R. S.; RUBINFELD, D. L. **Microeconomics**. 8. ed. Edição Global: Pearson, 2015.

PORTO ALEGRE. **Empresa Pública de Transporte e Circulação – EPTC**. Porto Alegre: Prefeitura de Porto Alegre, 2018. Disponível em: <http://www2.portoalegre.rs.gov.br/eptc>. Acesso em: 28 nov. 2018.

PRESTON, J. Public transport demand. *In*: NASH, C. **Handbook of Research Methods and Applications in Transport Economics and Policy**. Leeds: Edward Elgar, 2015. p. 192-211.

RAHMAN S.; BALIJEPALLI, C. Understanding the determinants of demand for public transport: Evidence from suburban rail operations in five divisions of Indian Railways. **Transport Policy**, v. 48, p. 13-22, 2016. DOI: <https://doi.org/10.1016/j.tranpol.2016.02.006>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0967070X16300518>. Acesso em: 05 abr. 2017.

RIO DE JANEIRO (Município). **Serviço de Transporte Público Local – STPL**. Rio de Janeiro (Município): Secretaria Municipal de Transportes – SMTR, 2018. Disponível em: <http://www.rio.rj.gov.br/web/smtr/stpl-online>. Acesso em: 28 nov. 2018.

RIO ÔNIBUS. **História**. Rio de Janeiro (Município): Rio Ônibus, 2018. Disponível em: <http://www.rioonibus.com/o-rio-onibus/historia/>. Acesso em: 28 nov. 2018.

RMTC – Rede Metropolitana de Transporte Coletivo. **Informações Institucionais**. Goiânia: RMTC, 2018. Disponível em: <http://www.rmtcgoiania.com.br/sobrea-a-rmtc/informacoes-institucionais>. Acesso em: 28 nov. 2018.

SALVADOR. **Anuário de Transportes Urbanos 2017**. Salvador: Secretaria de Mobilidade, 2018. Disponível em: <http://www.mobilidade.salvador.ba.gov.br/images/anuario/2017/ANUARIO2017.pdf>. Acesso em: 28 nov. 2018.

SCHIMEK, P. Dynamic estimates of fare elasticity for US public transit. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2538, p. 96-101, 2015. DOI: <https://doi.org/10.3141/2538-11>. Disponível em: <https://trjournalonline.trb.org/doi/abs/10.3141/2538-11>. Acesso em: 12 abr. 2018.

SMALL, K. A.; VERHOEF, E. T. **The economics of urban transportation**. 1.ed. Abingdon: Routledge, 2007.

SOUICHE, S. Measuring the structural determinants of urban travel demand. **Transport Policy**, v. 17, n.3, p. 127-134, 2010. DOI: <https://doi.org/10.1016/j.tranpol.2009.12.003>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0967070X09001449>. Acesso em: 11 abr. 2017.

SPTRANS. **A SPTrans**. São Paulo (Município): Prefeitura de São Paulo, 2018. Disponível em: http://www.sptrans.com.br/a_sptrans/. Acesso em: 28 nov. 2018.

STOCK, J. H. WATSON, M. W. **Introduction to econometrics**. 2. ed. Boston: Addison Wesley, 2008.

TSAI, C.; MULLEY, C. Identifying Short-Run and Long-Run Public Transport Demand Elasticities in Sydney A Pseudo Panel Approach. **Journal of Transport Economics and Policy**, v. 48, n. 2, p. 241-259, 2014. Disponível em: <https://www.jstor.org/stable/24396328?seq=1/analyze>. Acesso em: 13 jul. 2018.

TSAI, C.; MULLEY, C.; CLIFTON, G. A review of pseudo panel data approach in estimating short-run and long-run public transport demand elasticities. **Transport Reviews**, v. 34, n.1, p. 102-121, 2014. DOI: <https://doi.org/10.1080/01441647.2013.875079>. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/01441647.2013.875079>. Acesso em: 18 maio 2017.

URBS – Urbanização de Curitiba. **Rede Integrada de Transporte**. Curitiba: URBS, 2018. Disponível em: <https://www.urbs.curitiba.pr.gov.br/transporte/rede-integrada-de-transporte>. Acesso em: 28 nov. 2018.

VTLRIO. **Sobre o VLT**. Rio de Janeiro (Município): VLT Carioca, 2018. Disponível em: <http://www.vltrio.com.br>. Acesso em: 28 nov. 2018.

WANG, J. Y. T. Appraisal of factors influencing public transport patronage in New Zealand. *In*: Australasian Transport Research Forum, 32. 2009, Auckland. **Archive of previous ATRF papers**. Auckland: ATRF, 2009. Disponível em: https://atrf.info/papers/2009/2009_Wang.pdf. Acesso em 15 ago. 2018.

WARDMAN, M.; LYTHGOE, W.; WHELAN, G. Rail passenger demand forecasting: cross-sectional models revisited. **Research in Transportation Economics**, v. 20, p. 119-152, 2007. DOI: [https://doi.org/10.1016/S0739-8859\(07\)20005-8](https://doi.org/10.1016/S0739-8859(07)20005-8). Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0739885907200058>. Acesso em: 20 set. 2018.

WARDMAN, M. Review and meta-analysis of U.K. time elasticities of travel demand. **Transportation**, v. 39, n. 3, p. 465-490, 2012. DOI: <https://doi.org/10.1007/s11116-011-9369-2>. Disponível em: <https://link.springer.com/article/10.1007/s11116-011-9369-2>. Acesso em: 15 mar. 2018.

WARDMAN, M. Price elasticities of surface travel demand a meta-analysis of UK evidence. **Journal of Transport Economics and Policy**, v. 48, n. 3, p. 367-384, 2014. Disponível em: https://www.jstor.org/stable/24396293?seq=1#page_scan_tab_contents. Acesso em: 15 mar. 2018.

WEBSTER, F. V.; BLY, P. H. The demand for public transport: Part I. the changing environment in which public transport operates. **Transport Reviews**, v. 1, n. 4, p. 323-351, 1981. DOI: <https://doi.org/10.1080/01441648108716470>. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/01441648108716470>. Acesso em: 28 mar. 2017.

WEBSTER, F. V.; BLY, P. H. The demand for public transport. Part II. Supply and demand factors of public transport. **Transport Reviews**, v. 2, n. 1, p. 23-46, 1982. DOI: <https://doi.org/10.1080/01441648208716480>. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/01441648208716480>. Acesso em: 28 mar. 2017.

WHITE, H. A Heteroskedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroskedasticity. **Econometrica**, v.48, n. 4, p. 817-838, 1980. DOI: <https://doi.org/10.2307/1912934>. Disponível em: https://www.jstor.org/stable/1912934?seq=1#page_scan_tab_contents. Acesso em: 15 nov. 2018.

WOOLDRIDGE, J. M. **Econometric Analysis of Cross Section and Panel Data**. Cambridge; Londres: MIT press, 2001.

APÊNDICE A – BASE DE DADOS SECUNDÁRIOS

Metrópole	Ano	MUN/RM	Demanda Equivalente Anual (pass.)	Demanda Equiv. Anual per capita	Tarifa Principal (R\$)	Quilometragem Percorrida (km)	Idade da Frota (anos)	População
Belo Horizonte	2007	MUN	411.809.916	170,67	2,00	187.085.304	4,7	2.412.937
Belo Horizonte	2008	MUN	425.808.282	174,90	2,10	188.400.353	4,7	2.434.642
Belo Horizonte	2009	MUN	410.402.586	167,33	2,30	191.734.140	4,3	2.452.617
Belo Horizonte	2010	MUN	407.581.044	171,60	2,30	190.918.021	3,8	2.375.151
Belo Horizonte	2011	MUN	408.003.468	171,02	2,45	201.057.846	3,5	2.385.639
Belo Horizonte	2012	MUN	412.598.436	172,22	2,65	205.569.036	3,7	2.395.785
Belo Horizonte	2013	MUN	419.798.076	169,33	2,73	203.466.228	4,2	2.479.165
Belo Horizonte	2014	MUN	395.321.604	158,69	2,78	190.856.604	4,2	2.491.109
Belo Horizonte	2015	MUN	338.872.308	135,41	3,20	180.849.336	4,6	2.502.557
Belo Horizonte	2016	MUN	305.618.466	121,59	3,70	176.450.838	4,8	2.513.451
Belo Horizonte	2017	MUN	266.524.230	105,60	4,05	156.092.478	5,3	2.523.794
Curitiba	2007	MUN	323.408.262	179,93	1,87	151.882.590	5,9	1.797.408
Curitiba	2008	MUN	347.518.446	190,10	1,90	156.308.732	5,7	1.828.092
Curitiba	2009	MUN	317.125.344	171,31	2,20	153.257.686	6,0	1.851.215
Curitiba	2010	MUN	311.839.428	178,00	2,20	152.639.334	6,8	1.751.907
Curitiba	2011	MUN	312.844.524	177,30	2,45	151.437.744	3,7	1.764.540
Curitiba	2012	MUN	308.250.264	173,49	2,58	153.632.160	4,6	1.776.761
Curitiba	2013	MUN	324.079.665	175,28	2,73	150.442.656	5,0	1.848.946
Curitiba	2014	MUN	310.738.862	166,67	2,73	150.466.437	5,0	1.864.416
Curitiba	2015	MUN	221.442.980	117,83	3,26	102.927.359	6,0	1.879.355
Curitiba	2016	MUN	203.655.084	107,53	3,70	100.595.965	7,1	1.893.997
Curitiba	2017	MUN	176.930.760	92,71	4,20	97.645.026	8,1	1.908.359
Fortaleza	2007	MUN	252.525.402	103,86	1,60	129.752.547	5,1	2.431.415
Fortaleza	2008	MUN	273.374.373	110,52	1,60	133.036.149	4,8	2.473.614
Fortaleza	2009	MUN	270.910.626	108,12	1,72	127.653.319	4,5	2.505.552
Fortaleza	2010	MUN	260.317.530	106,16	1,80	129.823.322	4,2	2.452.185
Fortaleza	2011	MUN	258.352.110	104,32	1,97	128.711.376	4,3	2.476.589
Fortaleza	2012	MUN	263.348.688	105,33	2,00	128.898.902	4,0	2.500.194
Fortaleza	2013	MUN	268.209.150	105,11	2,20	130.954.090	3,7	2.551.806
Fortaleza	2014	MUN	271.197.828	105,45	2,20	130.205.895	4,0	2.571.896

Metrópole	Ano	MUN/RM	Demanda Equivalente Anual (pass.)	Demanda Equiv. Anual per capita	Tarifa Principal (R\$)	Quilometragem Percorrida (km)	Idade da Frota (anos)	População
Fortaleza	2015	MUN	259.714.860	100,23	2,46	133.992.043	4,2	2.591.188
Fortaleza	2016	MUN	242.715.384	93,00	2,75	136.928.602	4,7	2.609.716
Fortaleza	2017	MUN	205.676.298	78,28	3,20	132.198.535	5,3	2.627.482
Goiânia	2007	RMR	170.351.160	84,66	1,80	103.219.290	8,3	2.012.215
Goiânia	2008	RMR	170.351.160	82,36	1,93	103.219.290	8,3	2.068.490
Goiânia	2009	RMR	190.187.256	90,26	2,19	101.392.428	1,4	2.107.066
Goiânia	2010	RMR	180.117.606	85,85	2,25	101.602.884	3,2	2.098.060
Goiânia	2011	RMR	154.250.640	72,40	2,40	99.274.374	3,9	2.130.522
Goiânia	2012	RMR	151.037.526	69,86	2,62	96.717.552	5,3	2.161.932
Goiânia	2013	RMR	148.451.083	65,47	2,70	96.815.044	5,3	2.267.613
Goiânia	2014	RMR	141.293.682	61,30	2,77	93.149.442	7,6	2.304.920
Goiânia	2015	RMR	149.580.336	63,88	3,26	90.575.544	7,2	2.341.558
Goiânia	2016	RMR	132.905.700	55,91	3,67	76.829.784	7,1	2.377.189
Goiânia	2017	RMR	130.346.652	54,04	3,70	66.136.392	8,3	2.411.877
Porto Alegre	2007	MUN	246.515.332	173,52	1,99	113.546.153	5,0	1.420.667
Porto Alegre	2008	MUN	253.878.669	177,51	2,09	118.689.482	5,4	1.430.220
Porto Alegre	2009	MUN	247.404.607	172,27	2,28	116.087.419	4,4	1.436.123
Porto Alegre	2010	MUN	244.192.068	173,27	2,44	116.617.575	4,7	1.409.351
Porto Alegre	2011	MUN	238.397.240	168,71	2,68	116.389.954	4,2	1.413.094
Porto Alegre	2012	MUN	240.328.319	169,64	2,84	119.715.084	4,2	1.416.714
Porto Alegre	2013	MUN	241.808.634	164,74	2,84	125.074.898	4,5	1.467.816
Porto Alegre	2014	MUN	226.155.227	153,59	2,91	122.132.899	5,8	1.472.482
Porto Alegre	2015	MUN	208.016.959	140,85	3,20	118.414.310	6,0	1.476.867
Porto Alegre	2016	MUN	194.939.034	131,62	3,63	118.348.080	5,1	1.481.019
Porto Alegre	2017	MUN	167.845.704	113,03	3,98	106.200.186	6,3	1.484.941
Recife	2007	RMR	386.147.646	105,55	1,75	226.365.252	4,6	3.658.318
Recife	2008	RMR	406.991.094	109,06	1,75	241.469.115	4,4	3.731.719
Recife	2009	RMR	398.324.142	105,69	1,84	230.122.920	4,0	3.768.902
Recife	2010	RMR	439.222.830	119,01	1,85	239.690.490	3,9	3.690.547
Recife	2011	RMR	438.544.296	117,96	2,00	238.690.014	3,8	3.717.640
Recife	2012	RMR	443.685.522	118,51	2,15	252.846.589	3,7	3.743.854
Recife	2013	RMR	429.860.013	111,38	2,20	258.129.355	3,9	3.859.339
Recife	2014	RMR	402.346.848	103,50	2,15	237.097.014	4,3	3.887.261

Metrópole	Ano	MUN/RM	Demanda Equivalente Anual (pass.)	Demanda Equiv. Anual per capita	Tarifa Principal (R\$)	Quilometragem Percorrida (km)	Idade da Frota (anos)	População
Recife	2015	RMR	366.971.340	93,75	2,45	228.386.050	4,2	3.914.317
Recife	2016	RMR	346.810.176	88,01	2,80	221.000.364	4,5	3.940.456
Recife	2017	RMR	300.276.324	75,72	3,20	207.002.958	4,8	3.965.699
Rio de Janeiro	2007	MUN	803.024.556	131,78	2,00	706.452.828	4,8	6.093.472
Rio de Janeiro	2008	MUN	850.865.142	138,10	2,10	770.815.986	4,7	6.161.047
Rio de Janeiro	2009	MUN	838.782.594	135,58	2,20	747.220.428	4,9	6.186.710
Rio de Janeiro	2010	MUN	818.460.000	129,49	2,35	691.200.000	4,5	6.320.446
Rio de Janeiro	2011	MUN	980.280.048	154,23	2,40	786.185.352	3,4	6.355.949
Rio de Janeiro	2012	MUN	986.781.534	154,42	2,75	743.938.620	3,6	6.390.290
Rio de Janeiro	2013	MUN	928.514.418	144,41	2,77	733.329.204	3,6	6.429.923
Rio de Janeiro	2014	MUN	939.343.392	145,55	2,98	768.088.740	4,1	6.453.682
Rio de Janeiro	2015	MUN	925.528.770	142,90	3,40	714.571.002	4,3	6.476.631
Rio de Janeiro	2016	MUN	869.661.402	133,82	3,80	686.352.324	4,3	6.498.837
Rio de Janeiro	2017	MUN	766.364.076	117,54	3,89	645.667.524	4,7	6.520.266
Salvador	2007	MUN	369.316.056	127,68	2,00	223.009.934	5,0	2.892.625
Salvador	2008	MUN	393.182.178	133,34	2,00	236.771.191	4,8	2.948.733
Salvador	2009	MUN	368.504.676	122,91	2,20	234.398.364	4,8	2.998.056
Salvador	2010	MUN	365.531.790	136,61	2,30	223.348.557	4,6	2.675.656
Salvador	2011	MUN	355.979.430	132,16	2,50	233.598.372	4,7	2.693.605
Salvador	2012	MUN	341.869.122	126,11	2,68	199.176.168	4,8	2.710.968
Salvador	2013	MUN	330.029.208	114,45	2,80	196.205.496	4,8	2.883.682
Salvador	2014	MUN	312.208.254	107,55	2,80	188.248.689	4,7	2.902.927
Salvador	2015	MUN	301.965.138	103,37	3,00	174.084.689	3,7	2.921.087
Salvador	2016	MUN	286.618.944	97,55	3,30	173.863.041	3,9	2.938.092
Salvador	2017	MUN	255.604.320	86,53	3,60	170.486.802	4,9	2.953.986
São Paulo	2007	MUN	926.367.552	85,09	2,30	502.468.176	5,2	10.886.518
São Paulo	2008	MUN	926.367.552	84,29	2,30	502.468.176	5,2	10.990.249
São Paulo	2009	MUN	935.073.432	84,72	2,30	611.236.920	4,8	11.037.593
São Paulo	2010	MUN	921.923.772	81,92	2,70	546.972.858	5,5	11.253.503
São Paulo	2011	MUN	941.192.736	83,17	3,00	586.368.000	5,4	11.316.149
São Paulo	2012	MUN	866.950.782	76,20	3,00	553.207.896	5,0	11.376.685
São Paulo	2013	MUN	1.589.243.454	134,43	3,02	868.519.818	5,0	11.821.873
São Paulo	2014	MUN	1.589.243.454	133,60	3,00	868.519.818	4,8	11.895.893

Metrópole	Ano	MUN/RM	Demanda Equivalente Anual (pass.)	Demanda Equiv. Anual per capita	Tarifa Principal (R\$)	Quilometragem Percorrida (km)	Idade da Frota (anos)	População
São Paulo	2015	MUN	1.402.669.758	117,20	3,50	850.072.644	4,9	11.967.825
São Paulo	2016	MUN	1.248.633.492	103,72	3,80	850.599.564	5,4	12.038.175
São Paulo	2017	MUN	1.198.505.100	98,99	3,80	760.243.356	5,6	12.106.920

Metrópole	Ano	Área (km²)	Renda Média (R\$)	Frota de Moto	Frota de Automóvel	Frota Total	Preço da Gasolina (R\$)	Operação do Uber
Belo Horizonte	2007	331,401	762	112.975	730.723	1.018.501	2,36	0
Belo Horizonte	2008	331,401	848	132.869	798.171	1.122.936	2,34	0
Belo Horizonte	2009	331,401	908	149.128	871.446	1.227.917	2,33	0
Belo Horizonte	2010	331,401	1132	163.913	944.897	1.340.071	2,41	0
Belo Horizonte	2011	331,401	1132	178.480	1.005.634	1.438.723	2,73	0
Belo Horizonte	2012	331,401	1335	188.445	1.055.190	1.519.438	2,74	0
Belo Horizonte	2013	331,401	1453	197.150	1.101.919	1.596.081	2,77	0
Belo Horizonte	2014	331,401	1589	204.016	1.141.458	1.664.487	2,86	0
Belo Horizonte	2015	331,401	1679	209.963	1.173.626	1.714.233	3,28	1
Belo Horizonte	2016	331,401	1770	214.263	1.223.305	1.783.961	3,59	1
Belo Horizonte	2017	331,401	1844	219.840	1.317.214	1.907.891	3,74	1
Curitiba	2007	435,036	970	91.431	776.584	1.068.738	2,41	0
Curitiba	2008	435,036	1045	102.907	818.104	1.136.462	2,39	0
Curitiba	2009	435,036	1125	109.337	856.292	1.193.580	2,43	0
Curitiba	2010	435,036	1322	114.729	889.980	1.247.998	2,45	0
Curitiba	2011	435,036	1335	120.220	928.521	1.311.962	2,61	0
Curitiba	2012	435,036	1598	125.172	964.433	1.371.431	2,62	0
Curitiba	2013	435,036	1741	128.882	1.000.903	1.429.534	2,78	0
Curitiba	2014	435,036	1899	131.679	1.045.454	1.496.240	2,90	0
Curitiba	2015	435,036	2062	134.514	1.053.481	1.515.749	3,20	0
Curitiba	2016	435,036	2153	136.751	1.048.938	1.516.468	3,53	1
Curitiba	2017	435,036	2266	140.521	1.048.538	1.524.246	3,56	1
Fortaleza	2007	314,93	452	94.467	347.623	543.634	2,58	0
Fortaleza	2008	314,93	530	110.659	370.783	591.375	2,53	0
Fortaleza	2009	314,93	575	129.447	396.774	645.765	2,49	0
Fortaleza	2010	314,93	789	156.026	425.211	712.996	2,60	0
Fortaleza	2011	314,93	739	186.738	454.150	785.370	2,69	0
Fortaleza	2012	314,93	928	208.184	483.448	848.297	2,67	0
Fortaleza	2013	314,93	1058	229.154	511.109	908.074	2,79	0
Fortaleza	2014	314,93	1104	247.794	536.895	964.724	2,96	0
Fortaleza	2015	314,93	1188	265.237	556.100	1.009.695	3,44	0
Fortaleza	2016	314,93	1289	278.172	566.423	1.039.062	3,90	1
Fortaleza	2017	314,93	1378	286.946	578.962	1.066.829	3,92	1

Metrópole	Ano	Área (km²)	Renda Média (R\$)	Frota de Moto	Frota de Automóvel	Frota Total	Preço da Gasolina (R\$)	Operação do Uber
Goiânia	2007	5957,962	885	183.067	461.268	844.045	2,48	0
Goiânia	2008	5957,962	944	212.303	502.653	939.061	2,47	0
Goiânia	2009	5957,962	1012	232.548	548.456	1.028.092	2,57	0
Goiânia	2010	5957,962	1272	255.502	596.238	1.126.209	2,49	0
Goiânia	2011	5957,962	1280	281.320	641.923	1.228.238	2,84	0
Goiânia	2012	5957,962	1453	299.725	692.625	1.326.046	2,70	0
Goiânia	2013	5959,158	1588	316.568	733.793	1.412.692	2,85	0
Goiânia	2014	5959,158	1690	331.445	767.813	1.488.018	3,11	0
Goiânia	2015	5981,735	1791	343.536	786.188	1.534.734	3,36	0
Goiânia	2016	5981,735	1880	353.456	803.174	1.571.802	3,82	1
Goiânia	2017	5981,735	2004	363.516	823.201	1.613.884	3,95	1
Porto Alegre	2007	496,682	871	56.001	450.867	601.665	2,50	0
Porto Alegre	2008	496,682	993	62.221	475.355	639.097	2,51	0
Porto Alegre	2009	496,682	1067	67.384	495.915	672.624	2,52	0
Porto Alegre	2010	496,682	1294	71.809	510.987	701.273	2,55	0
Porto Alegre	2011	496,682	1267	75.681	529.906	733.871	2,70	0
Porto Alegre	2012	496,682	1590	79.946	550.289	768.069	2,68	0
Porto Alegre	2013	496,682	1786	83.947	571.299	802.932	2,79	0
Porto Alegre	2014	496,682	1901	87.216	587.143	832.115	2,90	0
Porto Alegre	2015	496,682	2024	90.112	596.446	850.305	3,32	0
Porto Alegre	2016	496,682	2229	91.902	601.323	861.621	3,88	1
Porto Alegre	2017	496,682	2342	92.985	604.385	869.854	3,89	1
Recife	2007	2742,40	509	104.515	453.084	673.092	2,59	0
Recife	2008	2742,40	596	127.142	479.944	733.244	2,58	0
Recife	2009	2742,40	652	152.780	513.367	803.887	2,56	0
Recife	2010	2742,40	901	183.590	557.904	895.915	2,62	0
Recife	2011	2770,45	855	217.120	599.712	991.718	2,66	0
Recife	2012	2770,45	1237	242.270	640.970	1.075.909	2,71	0
Recife	2013	2770,45	1410	264.994	675.200	1.148.564	2,80	0
Recife	2014	2770,45	1557	284.935	702.315	1.211.061	2,90	0
Recife	2015	2770,45	1482	298.984	716.895	1.257.837	3,39	0
Recife	2016	2770,45	1536	308.662	725.404	1.288.394	3,64	1
Recife	2017	2770,45	1655	317.966	740.494	1.320.091	3,62	1

Metrópole	Ano	Área (km²)	Renda Média (R\$)	Frota de Moto	Frota de Automóvel	Frota Total	Preço da Gasolina (R\$)	Operação do Uber
Rio de Janeiro	2007	1200,278	1105	123.612	1.396.083	1.746.836	2,49	0
Rio de Janeiro	2008	1200,278	1202	145.266	1.451.087	1.841.274	2,51	0
Rio de Janeiro	2009	1200,278	1339	161.306	1.521.716	1.947.622	2,54	0
Rio de Janeiro	2010	1200,278	1546	179.368	1.593.150	2.063.521	2,62	0
Rio de Janeiro	2011	1200,278	1522	200.037	1.666.108	2.190.395	2,81	0
Rio de Janeiro	2012	1200,278	1559	219.279	1.750.539	2.326.286	2,82	0
Rio de Janeiro	2013	1200,278	1722	238.855	1.824.803	2.451.155	2,96	0
Rio de Janeiro	2014	1200,278	1796	260.849	1.894.528	2.576.947	3,11	1
Rio de Janeiro	2015	1200,278	2053	277.715	1.943.456	2.667.780	3,53	1
Rio de Janeiro	2016	1200,278	2274	287.883	1.979.632	2.730.992	3,91	1
Rio de Janeiro	2017	1200,278	2295	296.098	2.006.416	2.775.279	4,09	1
Salvador	2007	693,276	506	47.419	378.240	508.793	2,58	0
Salvador	2008	693,276	577	58.121	400.713	549.111	2,59	0
Salvador	2009	693,276	623	68.251	429.930	597.039	2,61	0
Salvador	2010	693,276	822	78.319	458.599	648.323	2,72	0
Salvador	2011	693,276	803	87.891	483.488	694.309	2,74	0
Salvador	2012	693,276	1005	97.110	512.032	744.590	2,69	0
Salvador	2013	693,276	1079	105.207	533.990	785.257	2,89	0
Salvador	2014	693,276	1172	111.731	551.687	819.237	3,04	0
Salvador	2015	693,276	1277	117.765	564.606	846.102	3,57	0
Salvador	2016	693,276	1319	122.555	573.138	866.032	3,75	1
Salvador	2017	693,276	1443	127.230	583.805	886.703	3,73	1
São Paulo	2007	1521,101	1178	506.660	4.009.301	5.392.692	2,39	0
São Paulo	2008	1521,101	1258	600.117	4.251.685	5.804.566	2,38	0
São Paulo	2009	1521,101	1306	652.733	4.475.032	6.140.189	2,38	0
São Paulo	2010	1521,101	1617	704.702	4.617.635	6.390.092	2,44	0
São Paulo	2011	1521,101	1638	749.803	4.739.236	6.622.324	2,64	0
São Paulo	2012	1521,101	1861	774.570	4.839.921	6.795.228	2,62	0
São Paulo	2013	1521,101	2034	799.411	4.971.813	7.010.508	2,71	0
São Paulo	2014	1521,101	2223	833.664	5.160.727	7.323.775	2,83	1
São Paulo	2015	1521,101	2471	866.524	5.318.961	7.590.181	3,14	1
São Paulo	2016	1521,101	2621	895.211	5.442.775	7.805.127	3,45	1
São Paulo	2017	1521,101	2768	924.175	5.582.546	8.036.824	3,53	1

APÊNDICE B – RESULTADOS DA REGRESSÃO DO PAINEL ESTÁTICO

Apêndice B.1 – Regressão da função demanda para dados empilhados.

Pooling Model

Call:

```
plm(formula = modelo.m1, data = d9, model = "pooling",
     index = c("local", "ano"))
```

Balanced Panel: n = 9, T = 11, N = 99

Residuals:

Min.	1st Qu.	Median	3rd Qu.	Max.
-0.696448	-0.082398	0.025729	0.230638	0.399198

Coefficients:

	Estimate	Std. Error	t-value	Pr(> t)	
(Intercept)	4.583154	0.290560	15.7735	< 2.2e-16	***
log(tar.p)	0.391282	0.371307	1.0538	0.294928	
log(rend.an.tt)	0.053037	0.160981	0.3295	0.742606	
as.factor(ano)2008	0.011713	0.139105	0.0842	0.933093	
as.factor(ano)2009	-0.049312	0.141319	-0.3489	0.727988	
as.factor(ano)2010	-0.063382	0.146733	-0.4320	0.666858	
as.factor(ano)2011	-0.101419	0.151318	-0.6702	0.504503	
as.factor(ano)2012	-0.154242	0.159669	-0.9660	0.336745	
as.factor(ano)2013	-0.145764	0.164981	-0.8835	0.379418	
as.factor(ano)2014	-0.196935	0.168202	-1.1708	0.244905	
as.factor(ano)2015	-0.350377	0.186080	-1.8829	0.063089	.
as.factor(ano)2016	-0.486309	0.207825	-2.3400	0.021600	*
as.factor(ano)2017	-0.641930	0.224700	-2.8568	0.005365	**

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Total Sum of Squares: 8.9465

Residual Sum of Squares: 7.4267

R-Squared: 0.16988

Adj. R-Squared: 0.054052

F-statistic: 1.46665 on 12 and 86 DF, p-value: 0.15276

Apêndice B.2 – Regressão da função demanda com efeito fixo.

Oneway (individual) effect within Model

Call:

```
plm(formula = modelo.m1, data = d9, model = "within", index = c("local",
"ano"))
```

Balanced Panel: n = 9, T = 11, N = 99

Residuals:

Min.	1st Qu.	Median	3rd Qu.	Max.
-0.2821048	-0.0524294	-0.0068038	0.0473006	0.2606355

Coefficients:

	Estimate	Std. Error	t-value	Pr(> t)	
log(tar.p)	-1.668987	0.329229	-5.0694	2.623e-06	***
log(rend.an.tt)	-0.488596	0.193724	-2.5221	0.0137014	*
as.factor(ano)2008	0.124842	0.056603	2.2056	0.0303584	*
as.factor(ano)2009	0.267555	0.077146	3.4681	0.0008561	***
as.factor(ano)2010	0.473452	0.120434	3.9312	0.0001817	***
as.factor(ano)2011	0.588058	0.136450	4.3097	4.724e-05	***
as.factor(ano)2012	0.766274	0.181306	4.2264	6.391e-05	***
as.factor(ano)2013	0.895795	0.205592	4.3572	3.971e-05	***
as.factor(ano)2014	0.909866	0.220676	4.1231	9.258e-05	***
as.factor(ano)2015	1.061742	0.265258	4.0027	0.0001417	***
as.factor(ano)2016	1.198972	0.306470	3.9122	0.0001941	***
as.factor(ano)2017	1.236981	0.337091	3.6696	0.0004425	***

Signif. codes:

0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Total Sum of Squares: 2.4235

Residual Sum of Squares: 0.89515

R-Squared: 0.63064

Adj. R-Squared: 0.53594

F-statistic: 11.0981 on 12 and 78 DF, p-value: 1.5762e-12

Apêndice B.3 – Regressão da função demanda com efeito aleatório.

Oneway (individual) effect Random Effect Model
(Swamy-Arora's transformation)

Call:

```
plm(formula = modelo.m1, data = d9, model = "random", index = c("local",
"ano"))
```

Balanced Panel: n = 9, T = 11, N = 99

Effects:

	var	std.dev	share
idiosyncratic	0.01148	0.10713	0.114
individual	0.08959	0.29932	0.886

theta: 0.8927

Residuals:

Min.	1st Qu.	Median	3rd Qu.	Max.
-0.2622266	-0.0762337	-0.0063217	0.0772239	0.2661237

Coefficients:

	Estimate	Std. Error	t-value	Pr(> t)	
(Intercept)	5.576016	0.224495	24.8380	< 2.2e-16	***
log(tar.p)	-1.256690	0.309576	-4.0594	0.0001081	***
log(rend.an.tt)	-0.228531	0.174625	-1.3087	0.1941241	
as.factor(ano)2008	0.085769	0.056968	1.5055	0.1358481	
as.factor(ano)2009	0.176301	0.072943	2.4170	0.0177642	*
as.factor(ano)2010	0.303147	0.108327	2.7984	0.0063373	**
as.factor(ano)2011	0.389733	0.122050	3.1932	0.0019663	**
as.factor(ano)2012	0.493554	0.159953	3.0856	0.0027324	**
as.factor(ano)2013	0.583721	0.180646	3.2313	0.0017471	**
as.factor(ano)2014	0.573685	0.193501	2.9648	0.0039191	**
as.factor(ano)2015	0.654232	0.232342	2.8158	0.0060322	**
as.factor(ano)2016	0.727498	0.268662	2.7079	0.0081689	**

```

as.factor(ano)2017  0.718319  0.295660  2.4295 0.0171981 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Total Sum of Squares:    2.4986
Residual Sum of Squares: 1.0643
R-Squared:              0.57403
Adj. R-Squared:        0.5146
F-statistic: 9.65778 on 12 and 86 DF, p-value: 1.3457e-11

```

Apêndice B.4 – Regressão do Modelo (2)

oneway (individual) effect within Model

```

Call:
plm(formula = modelo.m1, data = d9, model = "within", index = c("local",
"ano"))

```

Balanced Panel: n = 9, T = 11, N = 99

Residuals:

	Min.	1st Qu.	Median	3rd Qu.	Max.
	-0.1560776	-0.0368431	0.0030779	0.0404900	0.1793053

Coefficients:

	Estimate	Std. Error	t-value	Pr(> t)	
log(tar.p)	-0.551060	0.224462	-2.4550	0.016343	*
log(rend.an.tt)	-0.335975	0.119589	-2.8094	0.006288	**
log(km.per/pop)	0.778933	0.068245	11.4137	< 2.2e-16	***
as.factor(ano)2008	0.063210	0.035140	1.7988	0.075972	.
as.factor(ano)2009	0.111810	0.049253	2.2701	0.025998	*
as.factor(ano)2010	0.227131	0.076967	2.9510	0.004195	**
as.factor(ano)2011	0.240592	0.089069	2.7012	0.008493	**
as.factor(ano)2012	0.340198	0.117319	2.8998	0.004864	**
as.factor(ano)2013	0.404513	0.133262	3.0355	0.003275	**
as.factor(ano)2014	0.417389	0.142083	2.9376	0.004361	**
as.factor(ano)2015	0.476714	0.170603	2.7943	0.006561	**
as.factor(ano)2016	0.502400	0.197661	2.5417	0.013039	*
as.factor(ano)2017	0.509023	0.216400	2.3522	0.021217	*

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Total Sum of Squares:    2.4235
Residual Sum of Squares: 0.33254
R-Squared:              0.86279
Adj. R-Squared:        0.82537
F-statistic: 37.2439 on 13 and 77 DF, p-value: < 2.22e-16

```

Apêndice B.5 – Regressão do Modelo (3)

oneway (individual) effect within Model

```

Call:
plm(formula = modelo.m1, data = d9, model = "within", index = c("local",
"ano"))

```

Balanced Panel: n = 9, T = 11, N = 99

Residuals:

	Min.	1st Qu.	Median	3rd Qu.	Max.
	-0.1390995	-0.0396403	-0.0010161	0.0387544	0.1578279

Coefficients:

	Estimate	Std. Error	t-value	Pr(> t)
log(tar.p)	-0.543440	0.224288	-2.4230	0.01774 *
log(rend.an.tt)	-0.269134	0.120157	-2.2399	0.02799 *
log(km.per/area)	0.782309	0.068339	11.4475	< 2e-16 ***
as.factor(ano)2008	0.043793	0.035374	1.2380	0.21948
as.factor(ano)2009	0.078938	0.050028	1.5779	0.11869
as.factor(ano)2010	0.198088	0.077566	2.5538	0.01263 *
as.factor(ano)2011	0.207261	0.089928	2.3048	0.02388 *
as.factor(ano)2012	0.288673	0.118595	2.4341	0.01725 *
as.factor(ano)2013	0.318708	0.135603	2.3503	0.02132 *
as.factor(ano)2014	0.321136	0.144577	2.2212	0.02928 *
as.factor(ano)2015	0.370214	0.173289	2.1364	0.03582 *
as.factor(ano)2016	0.385918	0.200644	1.9234	0.05813 .
as.factor(ano)2017	0.383605	0.219452	1.7480	0.08445 .

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Total Sum of Squares: 2.4235

Residual Sum of Squares: 0.3313

R-Squared: 0.8633

Adj. R-Squared: 0.82601

F-statistic: 37.4051 on 13 and 77 DF, p-value: < 2.22e-16

Apêndice B.6 – Regressão do Modelo (4)

Oneway (individual) effect within Model

Call:

```
plm(formula = modelo.m1, data = d9, model = "within", index = c("local",
"ano"))
```

Balanced Panel: n = 9, T = 11, N = 99

Residuals:

	Min.	1st Qu.	Median	3rd Qu.	Max.
	-0.12439822	-0.03353844	0.00070779	0.03296794	0.17149335

Coefficients:

	Estimate	Std. Error	t-value	Pr(> t)
log(tar.p)	-0.497721	0.209484	-2.3759	0.0200244 *
log(rend.an.tt)	-0.277827	0.112041	-2.4797	0.0153637 *
log(km.per/area)	0.758990	0.064045	11.8509	< 2.2e-16 ***
log(idad.f)	-0.121917	0.034343	-3.5500	0.0006649 ***
as.factor(ano)2008	0.042769	0.032978	1.2969	0.1985905
as.factor(ano)2009	0.043953	0.047668	0.9221	0.3594139
as.factor(ano)2010	0.174246	0.072621	2.3994	0.0188724 *
as.factor(ano)2011	0.168637	0.084536	1.9948	0.0496456 *
as.factor(ano)2012	0.254264	0.110982	2.2910	0.0247338 *
as.factor(ano)2013	0.288898	0.126692	2.2803	0.0253931 *
as.factor(ano)2014	0.302240	0.134884	2.2407	0.0279635 *
as.factor(ano)2015	0.345969	0.161689	2.1397	0.0355872 *
as.factor(ano)2016	0.361169	0.187177	1.9296	0.0573934 .

```

as.factor(ano)2017  0.368901  0.204622  1.8028  0.0753766 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Total Sum of Squares:    2.4235
Residual Sum of Squares: 0.28418
R-Squared:              0.88274
Adj. R-Squared:         0.8488
F-statistic: 40.867 on 14 and 76 DF, p-value: < 2.22e-16

```

Apêndice B.7 – Regressão do Modelo (5)

oneway (individual) effect within Model

```

Call:
plm(formula = modelo.m1, data = d9, model = "within", index = c("local",
"ano"))

```

Balanced Panel: n = 9, T = 11, N = 99

Residuals:

	Min.	1st Qu.	Median	3rd Qu.	Max.
	-0.1274882	-0.0385677	0.0040208	0.0312920	0.1818144

Coefficients:

	Estimate	Std. Error	t-value	Pr(> t)	
log(tar.p)	-0.488159	0.208461	-2.3417	0.021852	*
log(rend.an.tt)	-0.334186	0.118938	-2.8097	0.006320	**
log(km.per/area)	0.758532	0.063696	11.9085	< 2.2e-16	***
log(idad.f)	-0.127370	0.034392	-3.7035	0.000404	***
log(p.gas)	-0.424378	0.313169	-1.3551	0.179451	
as.factor(ano)2008	0.046917	0.032941	1.4243	0.158507	
as.factor(ano)2009	0.052549	0.047830	1.0987	0.275429	
as.factor(ano)2010	0.204773	0.075656	2.7066	0.008412	**
as.factor(ano)2011	0.224520	0.093644	2.3976	0.018993	*
as.factor(ano)2012	0.317208	0.119752	2.6489	0.009842	**
as.factor(ano)2013	0.375988	0.141444	2.6582	0.009597	**
as.factor(ano)2014	0.414155	0.157532	2.6290	0.010383	*
as.factor(ano)2015	0.514850	0.203446	2.5306	0.013481	*
as.factor(ano)2016	0.575782	0.244409	2.3558	0.021097	*
as.factor(ano)2017	0.593486	0.262453	2.2613	0.026639	*

```

---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

```

Total Sum of Squares:    2.4235
Residual Sum of Squares: 0.27739
R-Squared:              0.88554
Adj. R-Squared:         0.85044
F-statistic: 38.6847 on 15 and 75 DF, p-value: < 2.22e-16

```

Apêndice B.8 – Regressão do Modelo (6)

oneway (individual) effect within Model

```

Call:
plm(formula = modelo.m1, data = d9, model = "within", index = c("local",

```

"ano"))

Balanced Panel: n = 9, T = 11, N = 99

Residuals:

	Min.	1st Qu.	Median	3rd Qu.	Max.
	-0.1299417	-0.0328310	0.0010156	0.0355452	0.1753880

Coefficients:

	Estimate	Std. Error	t-value	Pr(> t)	
log(tar.p)	-0.4151267	0.2049379	-2.0256	0.046361	*
log(rend.an.tt)	-0.4065540	0.1194901	-3.4024	0.001074	**
log(km.per/area)	0.7797092	0.0623971	12.4959	< 2.2e-16	***
log(idad.f)	-0.1118141	0.0334099	-3.3467	0.001280	**
log(f.moto)	0.2076286	0.0817023	2.5413	0.013110	*
as.factor(ano)2008	0.0211239	0.0329731	0.6406	0.523710	
as.factor(ano)2009	0.0040566	0.0486459	0.0834	0.933763	
as.factor(ano)2010	0.1368596	0.0716717	1.9095	0.060018	.
as.factor(ano)2011	0.1019433	0.0857688	1.1886	0.238354	
as.factor(ano)2012	0.1910325	0.1100491	1.7359	0.086691	.
as.factor(ano)2013	0.2214714	0.1252174	1.7687	0.081011	.
as.factor(ano)2014	0.2316104	0.1332182	1.7386	0.086212	.
as.factor(ano)2015	0.2656917	0.1593408	1.6674	0.099597	.
as.factor(ano)2016	0.2730689	0.1840907	1.4833	0.142175	
as.factor(ano)2017	0.2759986	0.2009999	1.3731	0.173804	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Total Sum of Squares: 2.4235

Residual Sum of Squares: 0.26165

R-Squared: 0.89204

Adj. R-Squared: 0.85893

F-statistic: 41.3124 on 15 and 75 DF, p-value: < 2.22e-16

Apêndice B.9 – Regressão do Modelo (7)

Oneway (individual) effect within Model

Call:

```
plm(formula = modelo.m1, data = d9, model = "within", index = c("local",
"ano"))
```

Balanced Panel: n = 9, T = 11, N = 99

Residuals:

	Min.	1st Qu.	Median	3rd Qu.	Max.
	-0.1278401	-0.0338293	0.0026339	0.0329697	0.1754600

Coefficients:

	Estimate	Std. Error	t-value	Pr(> t)	
log(tar.p)	-0.502050	0.210559	-2.3844	0.0196374	*
log(rend.an.tt)	-0.261274	0.116237	-2.2478	0.0275296	*
log(km.per/area)	0.749956	0.066259	11.3185	< 2.2e-16	***
log(idad.f)	-0.121245	0.034517	-3.5126	0.0007554	***
log(f.auto)	-0.105234	0.184826	-0.5694	0.5708066	
as.factor(ano)2008	0.047922	0.034340	1.3955	0.1669763	
as.factor(ano)2009	0.055029	0.051682	1.0648	0.2904021	
as.factor(ano)2010	0.187616	0.076632	2.4483	0.0166922	*
as.factor(ano)2011	0.188499	0.091801	2.0533	0.0435268	*

```

as.factor(ano)2012  0.276458  0.118098  2.3409  0.0218955 *
as.factor(ano)2013  0.314637  0.135050  2.3298  0.0225111 *
as.factor(ano)2014  0.330615  0.144362  2.2902  0.0248238 *
as.factor(ano)2015  0.375550  0.170520  2.2024  0.0307117 *
as.factor(ano)2016  0.391739  0.195530  2.0035  0.0487396 *
as.factor(ano)2017  0.400478  0.212888  1.8812  0.0638307 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Total Sum of Squares:    2.4235
Residual Sum of Squares: 0.28296
R-Squared:               0.88325
Adj. R-Squared:         0.84744
F-statistic: 37.825 on 15 and 75 DF, p-value: < 2.22e-16

```

Apêndice B.10 – Regressão do Modelo (8)

Oneway (individual) effect within Model

```

Call:
plm(formula = modelo.m1, data = d9, model = "within", index = c("local",
"ano"))

```

Balanced Panel: n = 9, T = 11, N = 99

```

Residuals:
      Min.      1st Qu.      Median      3rd Qu.      Max.
-0.1275318 -0.0312278  0.0037259  0.0333632  0.1612120

```

```

Coefficients:
              Estimate Std. Error t-value Pr(>|t|)
log(tar.p)      -0.553069   0.210470  -2.6278  0.010418 *
log(rend.an.tt) -0.246312   0.112778  -2.1840  0.032086 *
log(km.per/area)  0.724839   0.067064  10.8082 < 2.2e-16 ***
log(idad.f)     -0.118844   0.034073  -3.4879  0.000818 ***
uber            0.060131   0.038306   1.5697  0.120684
as.factor(ano)2008  0.042058   0.032668   1.2874  0.201897
as.factor(ano)2009  0.046121   0.047235   0.9764  0.332001
as.factor(ano)2010  0.170700   0.071967   2.3719  0.020262 *
as.factor(ano)2011  0.171160   0.083749   2.0437  0.044493 *
as.factor(ano)2012  0.253626   0.109929   2.3072  0.023806 *
as.factor(ano)2013  0.288606   0.125489   2.2998  0.024241 *
as.factor(ano)2014  0.285890   0.134009   2.1334  0.036165 *
as.factor(ano)2015  0.325419   0.160688   2.0252  0.046410 *
as.factor(ano)2016  0.303915   0.188953   1.6084  0.111945
as.factor(ano)2017  0.311236   0.205981   1.5110  0.134992
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

```

Total Sum of Squares:    2.4235
Residual Sum of Squares: 0.27514
R-Squared:               0.88647
Adj. R-Squared:         0.85166
F-statistic: 39.0416 on 15 and 75 DF, p-value: < 2.22e-16

```

Apêndice B.11 – Regressão do Modelo (9)

Oneway (individual) effect within Model

Call:
plm(formula = modelo.m1, data = d9, model = "within", index = c("local",
"ano"))

Balanced Panel: n = 9, T = 11, N = 99

Residuals:

Min.	1st Qu.	Median	3rd Qu.	Max.
-0.12851050	-0.03211810	-0.00046864	0.03223673	0.18656528

Coefficients:

	Estimate	Std. Error	t-value	Pr(> t)	
log(tar.p)	-0.402920	0.203371	-1.9812	0.0512838	.
log(rend.an.tt)	-0.470107	0.125734	-3.7389	0.0003618	***
log(km.per/area)	0.779703	0.061871	12.6021	< 2.2e-16	***
log(idad.f)	-0.117435	0.033337	-3.5227	0.0007360	***
log(f.moto)	0.212496	0.081078	2.6209	0.0106377	*
log(p.gas)	-0.455827	0.301830	-1.5102	0.1352476	
as.factor(ano)2008	0.025072	0.032800	0.7644	0.4470571	
as.factor(ano)2009	0.012355	0.048548	0.2545	0.7998208	
as.factor(ano)2010	0.168773	0.074143	2.2763	0.0257198	*
as.factor(ano)2011	0.160404	0.093441	1.7166	0.0902297	.
as.factor(ano)2012	0.257159	0.117578	2.1871	0.0318933	*
as.factor(ano)2013	0.313434	0.138290	2.2665	0.0263443	*
as.factor(ano)2014	0.350163	0.153660	2.2788	0.0255639	*
as.factor(ano)2015	0.445206	0.197718	2.2517	0.0273078	*
as.factor(ano)2016	0.501520	0.237072	2.1155	0.0377554	*
as.factor(ano)2017	0.515049	0.254515	2.0236	0.0466180	*

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Total Sum of Squares: 2.4235

Residual Sum of Squares: 0.25383

R-Squared: 0.89527

Adj. R-Squared: 0.8613

F-statistic: 39.5343 on 16 and 74 DF, p-value: < 2.22e-16

Apêndice B.12 – Regressão do Modelo (10)

Oneway (individual) effect within Model

Call:
plm(formula = modelo.m1, data = d9, model = "within", index = c("local",
"ano"))

Balanced Panel: n = 9, T = 11, N = 99

Residuals:

Min.	1st Qu.	Median	3rd Qu.	Max.
-0.1301259	-0.0343942	0.0052995	0.0301642	0.1776715

Coefficients:

Estimate	Std. Error	t-value	Pr(> t)
----------	------------	---------	----------

```

log(tar.p)          -0.450650    0.206219  -2.1853  0.0320764 *
log(rend.an.tt)    -0.434841    0.128436  -3.3857  0.0011461 **
log(km.per/area)   0.752322    0.065452  11.4943 < 2.2e-16 ***
log(idad.f)        -0.115197    0.033262  -3.4633  0.0008964 ***
log(f.moto)        0.201520    0.081259   2.4800  0.0154459 *
log(p.gas)         -0.424408    0.301775  -1.4064  0.1638560
uber               0.046343    0.037240   1.2445  0.2173136
as.factor(ano)2008 0.025361    0.032679   0.7761  0.4402156
as.factor(ano)2009 0.015499    0.048435   0.3200  0.7498868
as.factor(ano)2010 0.165757    0.073909   2.2427  0.0279521 *
as.factor(ano)2011 0.161737    0.093103   1.7372  0.0865714 .
as.factor(ano)2012 0.255351    0.117154   2.1796  0.0325122 *
as.factor(ano)2013 0.310325    0.137803   2.2519  0.0273339 *
as.factor(ano)2014 0.333010    0.153713   2.1664  0.0335427 *
as.factor(ano)2015 0.421109    0.197939   2.1275  0.0367593 *
as.factor(ano)2016 0.446164    0.240351   1.8563  0.0674459 .
as.factor(ano)2017 0.458891    0.257561   1.7817  0.0789613 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Total Sum of Squares:    2.4235
Residual Sum of Squares: 0.24855
R-Squared:               0.89744
Adj. R-Squared:          0.86232
F-statistic: 37.5757 on 17 and 73 DF, p-value: < 2.22e-16

```

Apêndice B.13 – Regressão do Modelo (4) sem São Paulo

Oneway (individual) effect within Model

```

Call:
plm(formula = modelo.m1, data = d9.ssp, model = "within",
     index = c("local", "ano"))

```

Balanced Panel: n = 8, T = 11, N = 88

Residuals:

```

      Min.      1st Qu.      Median      3rd Qu.      Max.
-0.1127163 -0.0332777 -0.0018534  0.0297238  0.1341543

```

Coefficients:

```

      Estimate Std. Error t-value Pr(>|t|)
log(tar.p)    -0.603746   0.219869  -2.7459  0.0077677 **
log(rend.an.tt) -0.287796   0.109153  -2.6366  0.0104292 *
log(km.per/area)  0.554222   0.086729   6.3903  1.936e-08 ***
log(idad.f)    -0.113474   0.031588  -3.5923  0.0006254 ***
as.factor(ano)2008  0.061651   0.032412   1.9021  0.0615252 .
as.factor(ano)2009  0.089743   0.050390   1.7810  0.0795173 .
as.factor(ano)2010  0.210632   0.074584   2.8241  0.0062632 **
as.factor(ano)2011  0.215297   0.086452   2.4904  0.0152857 *
as.factor(ano)2012  0.319722   0.116194   2.7516  0.0076479 **
as.factor(ano)2013  0.332127   0.131933   2.5174  0.0142582 *
as.factor(ano)2014  0.341703   0.140760   2.4275  0.0179370 *
as.factor(ano)2015  0.388890   0.169744   2.2910  0.0251614 *
as.factor(ano)2016  0.419020   0.198222   2.1139  0.0383079 *
as.factor(ano)2017  0.414313   0.220037   1.8829  0.0641188 .
---

```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Total Sum of Squares: 2.0119
Residual Sum of Squares: 0.20052
R-Squared: 0.90034
Adj. R-Squared: 0.86862
F-statistic: 42.5871 on 14 and 66 DF, p-value: < 2.22e-16

APÊNDICE C – TESTES PARA ESCOLHA DO MODELO

Apêndice C.1 – Testes para escolha do modelo entre dados empilhados, efeito fixo e efeito aleatório

```
> # LM test for random effects versus OLS  
> plmtest(plpool.m1)
```

Lagrange Multiplier Test - (Honda) for balanced panels

```
data: modelo.m1  
normal = 17.809, p-value < 2.2e-16  
alternative hypothesis: significant effects
```

```
>  
> # LM test for fixed effects versus OLS  
> pFtest(p1.m1, plpool.m1)
```

F test for individual effects

```
data: modelo.m1  
F = 71.141, df1 = 8, df2 = 78, p-value < 2.2e-16  
alternative hypothesis: significant effects
```

```
>  
> # Hausman test for fixed versus random effects model  
> phptest(p1ran.m1, p1.m1)
```

Hausman Test

```
data: modelo.m1  
chisq = 9.5523, df = 12, p-value = 0.6552  
alternative hypothesis: one model is inconsistent
```

APÊNDICE D – TESTES DE HIPÓTESES DO PAINEL ESTÁTICO

Apêndice D.1 – Teste de Breusch-Godfrey/Wooldridge

```
> # Breusch-Godfrey/Wooldridge test for serial correlation in panel models
> pbgttest(p1.m1)

Breusch-Godfrey/Wooldridge test for serial correlation in panel
models

data: modelo.m1
chisq = 38.522, df = 11, p-value = 6.385e-05
alternative hypothesis: serial correlation in idiosyncratic errors
```

Apêndice D.2 – Teste de Durbin-Watson

```
> #Durbin-watson Test for Panel Models (serial correlation)
>
> pdwtest(p1.m1)

Durbin-watson test for serial correlation in panel models

data: modelo.m1
DW = 1.0763, p-value = 1.442e-06
alternative hypothesis: serial correlation in idiosyncratic errors
```

Apêndice D.3 – Teste de Wald

```
> # wald-style Chi-square Test and F Test
> pwaldtest(p1.m1, test = "F")

F test

data: modelo.m1
F = 40.867, df1 = 14, df2 = 76, p-value < 2.2e-16
```

Apêndice D.4 – Teste de Multicolinearidade

```
> #Correlação entre as variáveis - multicolinearidade
>
> round(cor(d9.v),2)
      dem.epa tar.p km.per/area idad.f
dem.epa      1.00 -0.21      0.49 -0.27
tar.p        -0.21  1.00      0.09  0.29
km.per/area  0.49  0.09      1.00 -0.29
idad.f       -0.27  0.29     -0.29  1.00
```

Apêndice D.5 – Teste de Breusch-Godfrey/Wooldridge para modelo sem São Paulo

```
> # Breusch-Godfrey/Wooldridge test for serial correlation in panel models
> pbgtest(p1.m1)

Breusch-Godfrey/Wooldridge test for serial correlation in panel models

data: modelo.m1
chisq = 46.303, df = 11, p-value = 2.859e-06
alternative hypothesis: serial correlation in idiosyncratic errors
```

Apêndice D.6 – Teste de Durbin-Watson para modelo sem São Paulo

```
> #Durbin-watson Test for Panel Models (serial correlation)
>
> pdwtest(p1.m1)

Durbin-watson test for serial correlation in panel models

data: modelo.m1
DW = 0.81323, p-value = 2.294e-09
alternative hypothesis: serial correlation in idiosyncratic errors
```

Apêndice D.7 – Teste de Wald para modelo sem São Paulo

```
> # wald-style Chi-square Test and F Test
> pwaldtest(p1.m1, test = "F")

F test

data: modelo.m1
F = 42.587, df1 = 14, df2 = 66, p-value < 2.2e-16
```

Apêndice D.8 – Teste de Multicolinearidade para modelo sem São Paulo

```
> #Correlação entre as variáveis - multicolinearidade
>
> round(cor(d9.vsp), 2)
      dem.epa tar.p km.per/area idade.f
dem.epa    1.00 -0.21    0.56  -0.26
tar.p      -0.21  1.00    0.02   0.29
km.per/area 0.56  0.02    1.00  -0.32
idade.f   -0.26  0.29   -0.32   1.00
```

APÊNDICE E – CORREÇÃO ROBUSTA DE WHITE

Apêndice E.1 – Correção de White para modelo com as nove cidades

```
> coefTest(p1.m1, vcov = vcovHC(p1.m1, type = "HC4"))
t test of coefficients:

              Estimate Std. Error t value Pr(>|t|)
log(tar.p)      -0.497721   0.212559 -2.3416  0.02183 *
log(rend.an.tt) -0.277827   0.132568 -2.0957  0.03943 *
log(km.per/area) 0.758990   0.102675  7.3921 1.590e-10 ***
log(idad.f)     -0.121917   0.018151 -6.7166 2.987e-09 ***
as.factor(ano)2008 0.042769   0.021972  1.9465  0.05529 .
as.factor(ano)2009 0.043953   0.059938  0.7333  0.46563
as.factor(ano)2010 0.174246   0.069608  2.5033  0.01445 *
as.factor(ano)2011 0.168637   0.080516  2.0944  0.03955 *
as.factor(ano)2012 0.254264   0.114331  2.2239  0.02912 *
as.factor(ano)2013 0.288898   0.112892  2.5591  0.01248 *
as.factor(ano)2014 0.302240   0.124306  2.4314  0.01740 *
as.factor(ano)2015 0.345969   0.160903  2.1502  0.03472 *
as.factor(ano)2016 0.361169   0.190967  1.8913  0.06240 .
as.factor(ano)2017 0.368901   0.204460  1.8043  0.07515 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Apêndice E.2 – Correção de White para modelo sem São Paulo

```
> coefTest(p1.m1, vcov = vcovHC(p1.m1, type = "HC4"))
t test of coefficients:

              Estimate Std. Error t value Pr(>|t|)
log(tar.p)      -0.603746   0.238496 -2.5315 0.0137481 *
log(rend.an.tt) -0.287796   0.184774 -1.5576 0.1241199
log(km.per/area) 0.554222   0.136337  4.0651 0.0001302 ***
log(idad.f)     -0.113474   0.019341 -5.8671 1.57e-07 ***
as.factor(ano)2008 0.061651   0.019126  3.2233 0.0019703 **
as.factor(ano)2009 0.089743   0.044442  2.0193 0.0475170 *
as.factor(ano)2010 0.210632   0.073372  2.8708 0.0054981 **
as.factor(ano)2011 0.215297   0.077376  2.7825 0.0070272 **
as.factor(ano)2012 0.319722   0.118594  2.6959 0.0088969 **
as.factor(ano)2013 0.332127   0.140475  2.3643 0.0210147 *
as.factor(ano)2014 0.341703   0.163224  2.0935 0.0401539 *
as.factor(ano)2015 0.388890   0.213183  1.8242 0.0726480 .
as.factor(ano)2016 0.419020   0.245069  1.7098 0.0919998 .
as.factor(ano)2017 0.414313   0.274520  1.5092 0.1360131
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

APÊNDICE F – RESULTADOS DA REGRESSÃO DO PAINEL DINÂMICO

Apêndice F.1 – Regressão do Modelo final do painel estático em painel dinâmico com nove cidades

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.466260	0.160706	-2.9013	0.0057833	**
log(rend.an.tt)	-0.121969	0.125125	-0.9748	0.3350015	
log(km.per/area)	0.740914	0.069228	10.7025	7.896e-14	***
log(idad.f)	-0.091002	0.025619	-3.5521	0.0009256	***
d2008	-0.119214	0.080861	-1.4743	0.1475177	
d2009	-0.130312	0.065343	-1.9943	0.0523413	.
d2010	-0.035183	0.038191	-0.9212	0.3619444	
d2011	-0.040719	0.031289	-1.3014	0.1999031	
d2012	0.013883	0.013588	1.0218	0.3124820	
d2013	0.035795	0.019374	1.8475	0.0713985	.
d2014	0.028355	0.026673	1.0631	0.2935447	
d2015	0.064789	0.043211	1.4993	0.1409248	
d2016	0.086251	0.062327	1.3838	0.1733881	
d2017	0.096354	0.076695	1.2563	0.2156248	
LagDep	0.215477	0.061213	3.5201	0.0010169	**

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81

R-square : 0.6643748

Hansen's J-statistic: 88.55341 Pvalue: 7.888692e-05

Apêndice F.2 – Regressão do Modelo final do painel estático em painel dinâmico sem São Paulo

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.415691	0.158343	-2.6253	0.01186	*
log(rend.an.tt)	-0.108387	0.096701	-1.1208	0.26843	
log(km.per/area)	0.469062	0.073855	6.3511	1.027e-07	***
log(idad.f)	-0.087232	0.020260	-4.3057	9.167e-05	***
d2008	-0.092992	0.074591	-1.2467	0.21911	
d2009	-0.104233	0.058270	-1.7888	0.08054	.
d2010	-0.022764	0.037299	-0.6103	0.54480	
d2011	-0.031720	0.029799	-1.0645	0.29292	
d2012	0.026145	0.012628	2.0705	0.04431	*
d2013	0.016652	0.015786	1.0549	0.29725	
d2014	0.021868	0.021844	1.0011	0.32226	
d2015	0.045074	0.039376	1.1447	0.25851	
d2016	0.075275	0.060314	1.2480	0.21861	
d2017	0.066695	0.077536	0.8602	0.39435	
LagDep	0.396168	0.073601	5.3826	2.700e-06	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 8 Number of obs : 72
 R-square : 0.6078913
 Hansen's J-statistic: 96.69935 Pvalue: 7.990778e-06

Apêndice F.3 – Regressão do Modelo (1)

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.860424	0.271721	-3.1666	0.002801	**
log(rend.an.tt)	-0.144247	0.221203	-0.6521	0.517726	
d2008	-0.245776	0.140514	-1.7491	0.087242	.
d2009	-0.208626	0.113061	-1.8453	0.071736	.
d2010	-0.104771	0.065362	-1.6029	0.116104	
d2011	-0.057016	0.054047	-1.0549	0.297215	
d2012	0.010701	0.023276	0.4597	0.647974	
d2013	0.089846	0.032411	2.7721	0.008134	**
d2014	0.053757	0.046141	1.1651	0.250275	
d2015	0.100866	0.075495	1.3361	0.188401	
d2016	0.178583	0.107592	1.6598	0.104062	
d2017	0.182437	0.132781	1.3740	0.176412	
LagDep	0.564528	0.090628	6.2291	1.554e-07	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81
 R-square : 0.1366288
 Hansen's J-statistic: 65.9126 Pvalue: 0.01782364

Apêndice F.4 – Regressão do Modelo (2)

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.5398197	0.1785611	-3.0232	0.0041618	**
log(rend.an.tt)	-0.0679866	0.1426720	-0.4765	0.6360594	
log(km.per/pop)	0.7057169	0.0773214	9.1271	1.034e-11	***
d2008	-0.1413448	0.0915165	-1.5445	0.1296366	
d2009	-0.1218051	0.0736710	-1.6534	0.1053750	
d2010	-0.0615333	0.0424989	-1.4479	0.1547395	
d2011	-0.0473388	0.0348521	-1.3583	0.1813006	
d2012	0.0020749	0.0150536	0.1378	0.8909991	
d2013	0.0454567	0.0215406	2.1103	0.0405550	*
d2014	0.0293001	0.0299049	0.9798	0.3325522	
d2015	0.0744957	0.0488116	1.5262	0.1341199	
d2016	0.1063355	0.0699663	1.5198	0.1357126	
d2017	0.1143590	0.0860694	1.3287	0.1908023	
LagDep	0.2686203	0.0678746	3.9576	0.0002724	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81
 R-square : 0.5830499
 Hansen's J-statistic: 82.54006 Pvalue: 0.0003862876

Apêndice F.5 – Regressão do Modelo (3)

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.5429427	0.1790514	-3.0323	0.0040589	**
log(rend.an.tt)	-0.0669221	0.1430300	-0.4679	0.6421738	
log(km.per/pop/area)	0.7015404	0.0774530	9.0576	1.291e-11	***
d2008	-0.1422867	0.0917763	-1.5504	0.1282179	
d2009	-0.1226839	0.0738750	-1.6607	0.1038852	
d2010	-0.0624253	0.0426164	-1.4648	0.1500794	
d2011	-0.0471315	0.0349460	-1.3487	0.1843361	
d2012	0.0021938	0.0150982	0.1453	0.8851363	
d2013	0.0457072	0.0216066	2.1154	0.0400908	*
d2014	0.0293146	0.0299892	0.9775	0.3336637	
d2015	0.0749105	0.0489463	1.5305	0.1330613	
d2016	0.1071572	0.0701642	1.5272	0.1338602	
d2017	0.1152443	0.0863099	1.3352	0.1886656	
LagDep	0.2712375	0.0680304	3.9870	0.0002488	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81

R-square : 0.5805538

Hansen's J-statistic: 82.9239 Pvalue: 0.0003500284

Apêndice F.6 – Regressão do Modelo (4)

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.494264	0.178606	-2.7673	0.0082355	**
log(rend.an.tt)	-0.039919	0.141597	-0.2819	0.7793296	
log(km.per/area)	0.711865	0.077190	9.2223	7.635e-12	***
d2008	-0.099475	0.091621	-1.0857	0.2835124	
d2009	-0.092396	0.073662	-1.2543	0.2163482	
d2010	-0.023198	0.042951	-0.5401	0.5918465	
d2011	-0.016340	0.034926	-0.4678	0.6422118	
d2012	0.020133	0.014976	1.3443	0.1857259	
d2013	0.034049	0.021731	1.5668	0.1243152	
d2014	0.010721	0.029964	0.3578	0.7222178	
d2015	0.043480	0.048832	0.8904	0.3781012	
d2016	0.062609	0.070264	0.8911	0.3777469	
d2017	0.060418	0.086280	0.7003	0.4874568	
LagDep	0.255973	0.067871	3.7715	0.0004808	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81

R-square : 0.5860002

Hansen's J-statistic: 80.76544 Pvalue: 0.0006060703

Apêndice F.7 – Regressão do Modelo (5)

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.5209432	0.1762976	-2.9549	0.0050085	**
log(km.per/pop)	0.7061159	0.0769037	9.1818	8.683e-12	***
d2008	-0.1038757	0.0528050	-1.9672	0.0554901	.
d2009	-0.0908831	0.0395409	-2.2985	0.0263449	*
d2010	-0.0472392	0.0321957	-1.4673	0.1494190	
d2011	-0.0333678	0.0207841	-1.6054	0.1155498	
d2012	0.0022213	0.0150272	0.1478	0.8831591	
d2013	0.0381625	0.0149411	2.5542	0.0141816	*
d2014	0.0168832	0.0151147	1.1170	0.2700571	
d2015	0.0549762	0.0297338	1.8489	0.0711914	.
d2016	0.0802622	0.0477244	1.6818	0.0996959	.
d2017	0.0828605	0.0603532	1.3729	0.1767324	
LagDep	0.2665667	0.0672793	3.9621	0.0002687	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81

R-square : 0.5843651

Hansen's J-statistic: 81.62669 Pvalue: 0.000487603

Apêndice F.8 – Regressão do Modelo (6)

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.4791938	0.1761514	-2.7204	0.0093029	**
log(km.per/area)	0.7117291	0.0765522	9.2973	6.016e-12	***
d2008	-0.0762862	0.0529475	-1.4408	0.1567228	.
d2009	-0.0733597	0.0396143	-1.8518	0.0707648	.
d2010	-0.0141177	0.0325140	-0.4342	0.6662616	
d2011	-0.0077485	0.0207597	-0.3732	0.7107552	
d2012	0.0203434	0.0149524	1.3605	0.1805872	
d2013	0.0297679	0.0151138	1.9696	0.0552029	.
d2014	0.0033792	0.0152011	0.2223	0.8251091	
d2015	0.0314062	0.0296975	1.0575	0.2960376	
d2016	0.0461821	0.0479297	0.9635	0.3405434	
d2017	0.0404334	0.0604326	0.6691	0.5069487	
LagDep	0.2544693	0.0671759	3.7881	0.0004572	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81

R-square : 0.5871622

Hansen's J-statistic: 78.88017 Pvalue: 0.000968417

Apêndice F.9 – Regressão do Modelo (7)

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.4438922	0.1581174	-2.8074	0.007417	**
log(km.per/area)	0.7536217	0.0683206	11.0307	2.976e-14	***
log(idad.f)	-0.0882784	0.0252819	-3.4918	0.001105	**
d2008	-0.0557933	0.0478476	-1.1661	0.249871	
d2009	-0.0769052	0.0354406	-2.1700	0.035450	*
d2010	-0.0112346	0.0291171	-0.3858	0.701475	
d2011	-0.0164118	0.0187048	-0.8774	0.385027	
d2012	0.0141651	0.0134990	1.0493	0.299750	
d2013	0.0222525	0.0136581	1.6293	0.110399	
d2014	0.0059491	0.0136228	0.4367	0.664464	
d2015	0.0317453	0.0265592	1.1953	0.238385	
d2016	0.0424357	0.0429137	0.9889	0.328138	
d2017	0.0437971	0.0540512	0.8103	0.422135	
LagDep	0.2058294	0.0604785	3.4033	0.001429	**

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81

R-square : 0.6687089

Hansen's J-statistic: 90.00053 Pvalue: 5.310373e-05

Apêndice F.10 – Regressão do Modelo (8)

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.4477298	0.1600370	-2.7977	0.007608	**
log(km.per/area)	0.7524464	0.0689399	10.9145	4.197e-14	***
log(idad.f)	-0.0875950	0.0255406	-3.4296	0.001324	**
log(p.gas)	0.0740613	0.2463475	0.3006	0.765107	
d2008	-0.0448690	0.0594022	-0.7553	0.454069	
d2009	-0.0659879	0.0500483	-1.3185	0.194164	
d2010	-0.0017006	0.0425004	-0.0400	0.968263	
d2011	-0.0113341	0.0249433	-0.4544	0.651778	
d2012	0.0199849	0.0234842	0.8510	0.399381	
d2013	0.0250345	0.0166171	1.5065	0.139073	
d2014	0.0050636	0.0140093	0.3614	0.719496	
d2015	0.0218903	0.0417417	0.5244	0.602618	
d2016	0.0257014	0.0692633	0.3711	0.712367	
d2017	0.0262169	0.0783965	0.3344	0.739656	
LagDep	0.2085925	0.0618431	3.3729	0.001560	**

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81

R-square : 0.664682

Hansen's J-statistic: 88.86171 Pvalue: 7.253857e-05

Apêndice F.11 – Regressão do Modelo (9)

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.4258374	0.1531437	-2.7806	0.007955	**
log(km.per/area)	0.7600247	0.0675468	11.2518	1.554e-14	***
log(idad.f)	-0.0855087	0.0252563	-3.3856	0.001504	**
log(f.moto)	0.0730005	0.0639851	1.1409	0.260084	
d2008	-0.0229538	0.0547759	-0.4190	0.677220	
d2009	-0.0530019	0.0403606	-1.3132	0.195920	
d2010	0.0034597	0.0311322	0.1111	0.912020	
d2011	-0.0103338	0.0190982	-0.5411	0.591177	
d2012	0.0137098	0.0133948	1.0235	0.311657	
d2013	0.0160955	0.0146172	1.1011	0.276826	
d2014	-0.0042394	0.0162306	-0.2612	0.795157	
d2015	0.0161646	0.0293342	0.5510	0.584387	
d2016	0.0218569	0.0453950	0.4815	0.632561	
d2017	0.0192424	0.0566868	0.3395	0.735885	
LagDep	0.1981572	0.0604820	3.2763	0.002056	**

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81

R-square : 0.6719993

Hansen's J-statistic: 89.57931 Pvalue: 5.961812e-05

Apêndice F.12 – Regressão do Modelo (10)

GMM-Estimation of the Dynamic Panel Data Models:

Instruments according to method:

Arellano Bond (1991)

	Estimate	SE	t-value	Pvalue	
log(tar.p)	-0.484828	0.162722	-2.9795	0.004687	**
log(rend.an.tt)	-0.212900	0.134649	-1.5812	0.121006	
log(km.per/area)	0.737085	0.069976	10.5334	1.313e-13	***
log(idad.f)	-0.088539	0.025857	-3.4242	0.001345	**
log(f.moto)	0.132431	0.073685	1.7973	0.079160	.
log(p.gas)	0.023364	0.243046	0.0961	0.923854	
uber	0.011344	0.027839	0.4075	0.685635	
d2008	-0.109828	0.091244	-1.2037	0.235149	
d2009	-0.126925	0.077558	-1.6365	0.108867	
d2010	-0.025742	0.051415	-0.5007	0.619096	
d2011	-0.045718	0.038000	-1.2031	0.235362	
d2012	0.017138	0.024547	0.6982	0.488742	
d2013	0.039273	0.021586	1.8194	0.075659	.
d2014	0.028072	0.026493	1.0596	0.295121	
d2015	0.062083	0.056317	1.1024	0.276285	
d2016	0.075539	0.088511	0.8534	0.398035	
d2017	0.086108	0.101343	0.8497	0.400107	
LagDep	0.199535	0.063741	3.1304	0.003098	**

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Number of groups : 9 Number of obs : 81

R-square : 0.6624356

Hansen's J-statistic: 85.52277 Pvalue: 0.0001777294