

Análise espacial multivariada do transporte público do município de Natal por meio de indicadores socioeconômicos

Maikon Roberth de Novaes ¹
Cláudia Maria Almeida ²

¹ Instituto Brasileiro de Geografia e Estatística – IBGE/UE-RN
Av. Prudente de Moraes, 161- SBT, Petrópolis - 59020-400 – Natal - RN, Brasil
maikon.novaes@ibge.gov.br

² Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
almeida@dsr.inpe.br

Abstract. The city of Natal, capital of Rio Grande do Norte state, northeast of Brazil, has been severely criticized for relying solely on two modes of transport - bus and train – with no interconnection between them. Natal contains 85 daily bus lines and their planning does not consider a spatially explicit analysis of the current and envisaged demand. Public transportation should serve with priority those places which show a greater concentration of inhabitants, or at least serve the people belonging to the less wealthy social strata, whose purchasing power does not allow them to count on private cars for the daily displacements. This paper is committed to investigate whether a spatial autocorrelation exists between the bus routes and socio-economic characteristics (amount of inhabitants and income) of the local population, based on the use of spatial analysis techniques, such as the global and local Moran's indices and the local indicator of spatial association, conducted at the census tract level. The obtained results demonstrated that, on the one hand, the supply of bus lines in Natal is inversely correlated to the concentration of population and, on the other hand, is directly proportional to income in several tracts of the city.

Palavras-chaves: urban mobility, global and local Moran's indices, local indicators of spatial association (LISA), mobilidade urbana, índice global e local de Moran, indicadores locais de associação espacial.

1. Introdução

O atendimento às necessidades sociais e econômicas das pessoas requer seu deslocamento no espaço, seja ele a pé, por meio de veículos de transporte motorizados ou não motorizados. Em países em desenvolvimento como o Brasil, pessoas que moram nas cidades realizam, em média, dois deslocamentos por dia, valor correspondente à metade dos deslocamentos de pessoas em países desenvolvidos (IPEA, 2011). Estes deslocamentos são feitos com maior ou menor nível de conforto, conforme as condições específicas em que se realizam, e implicam consumos de tempo, espaço, energia e recursos financeiros e a geração de externalidades negativas, como a poluição do ar, os acidentes de trânsito e os congestionamentos.

Devido ao intenso crescimento urbano no Brasil a partir da década de 1950, muitas cidades – e regiões metropolitanas (RMs) – passaram a apresentar sistemas de mobilidade de baixa qualidade e de alto custo, com impactos negativos na vida das pessoas e nos custos econômicos e ambientais para a sociedade. Em especial nas grandes cidades, à semelhança do que ocorreu nos EUA, assistiu-se ao declínio da oferta do transporte público em decorrência da individualização da resolução do problema, por meio do uso do transporte individual (Pucher, 2004). O Brasil vivencia hoje uma situação contraditória em que, de um lado, surgem políticas de incentivo para a aquisição de transporte individual, haja vista a elevação do poder aquisitivo e a facilidade de acesso ao crédito experienciada pelas classes menos abastadas e, por outro lado, aprova-se a Lei de Mobilidade Urbana (Lei 12.587/12), a qual passa a exigir que municípios com população acima de 20 mil habitantes elaborem e apresentem plano de mobilidade urbana com o intuito de planejar o crescimento das cidades de forma ordenada (Brasil, 2012).

Desta forma, torna-se fundamental analisar as condições efetivas de mobilidade por extrato social, bem como do ponto de vista dos consumos e das externalidades a elas associadas. a fim de se avaliar a qualidade da vida nas cidades no país e identificar ações de políticas públicas que possam reduzir os problemas urbanos de mobilidade (IPEA, 2011), como forma de se assegurar maior eficiência na movimentação de indivíduos e mercadorias e garantir às pessoas o seu direito à cidade. Segundo o Instituto de Desenvolvimento e Informação em Transporte – ITRANS – o transporte é apontado como um dos principais problemas associados a camadas de baixa renda em regiões metropolitanas como São Paulo, Rio de Janeiro, Belo Horizonte e Recife (ITRANS, 2004).

No tocante ao planejamento de transportes, o uso de Sistemas de Informações Geográficas (SIG, ou GIS em inglês) pode colaborar bastante para o tratamento de variáveis, como caminho mínimo entre pontos, matriz de origem e destino de viagens, bem como modelos específicos de transporte (Silva et al. 2003, Silva, 1998). Modelos de transporte que utilizam SIG são conhecidos pelo nome de *Geographic Information Systems for Transportation* – GIS-T – os quais permitem visualização, planejamento de trabalho, programação e monitoramento de dados digitais relativos ao transporte, o que pode colaborar no embasamento de políticas públicas urbanas (Nyerges, 2004; Waters, 1999; Goodchild, 1998). Técnicas de análise espacial utilizando estatística espacial são formas de se realizar análise exploratória de fenômenos em ambiente SIG ou GIS-T e que provaram ser muito úteis para se estudar variáveis socioeconômicas relacionadas ao planejamento do transporte público (Lopes, 2005; Krempi, 2004 e Teixeira, 2003).

A cidade de Natal, capital do Rio Grande do Norte, tem características semelhantes às das capitais de médio porte do país, a qual passou por intensas migrações intra-regionais nas últimas décadas, elevando, assim, a sua população urbana de 606.887 habitantes em 1991 para 817.590 habitantes em 2012 (Natal, 2013). Segundo dados do DENATRAN¹, em agosto de 2014, sua frota de veículos é majoritariamente composta por automóveis (58,48%), seguida por motocicletas (22,75%) enquanto a frota de ônibus, corresponde a apenas 1,07% do total de veículos. Neste quesito, Natal dispõe de 87 linhas de ônibus e 26 linhas opcionais, com uma frota de 720 veículos, além de uma frota de 177 táxis e uma precária linha de trem que atende, principalmente, aos municípios vizinhos, mas possui grande deficiência em serviços intra-municipais (Natal, 2013). Ausente de outros modais como metrô, trens internos, VLT (Veículo Leve sobre Trilhos), o transporte público de Natal é centrado no ônibus como meio mobilidade da população.

Diante destas características, a hipótese deste trabalho é que a oferta das linhas de transporte público – modal ônibus - possui forte dependência espacial e que os itinerários destas linhas não se encontram compatíveis com a distribuição da população que majoritariamente demanda tal serviço e que há uma forte correlação espacial referente ao poder aquisitivo da população. O objetivo deste trabalho é testar esta hipótese por meio de análise espacial utilizando o índice de autocorrelação espacial I de Moran e a análise de correlação espacial local bivariada do fluxo de linhas por meio de dados socioeconômicos, como população e renda por unidade de setores censitários do IBGE.

2. Metodologia de Trabalho

2.1 Material

A área de análise deste trabalho é o município de Natal, capital do Rio Grande do Norte, Brasil. Foram selecionadas e tratadas 85 linhas de ônibus que correspondem aos itinerários de ida e volta adquiridos por meio de GPS pela própria equipe da Secretaria Municipal de Mobilidade Urbana de Natal (SEMOB) com dados de número de viagens de cada uma delas

1 Disponível em <http://www.denatran.gov.br/frota2014.htm>, acessado em outubro de 2014.

em período regular (06:00 - 23:00) em dias úteis. A malha de setores censitários de 2010² e dados de população e renda³ foram extraídos dos resultados do CENSO 2010 (IBGE, 2010). Para a confecção do projeto e geoprocessamento foi utilizado o software ESRI ArcGIS 10.2 (ESRI, 2011). Para a análise espacial de áreas e representação de autocorrelação global e local bivariada foi utilizado o software GeoDa 1.6 (Anselin, 2005).

2.2 Métodos

As linhas de itinerários foram inseridas no projeto sobrepostas à malha digital de setores censitários do IBGE. Estes últimos foram reprojatados para o sistema de coordenadas UTM 24S *datum* SAD69 para obedecer ao *datum* original correspondente aos itinerários dos ônibus. Os atributos de número de viagem, extraídos de ordens de serviço da SEMOB, foram atribuídos às respectivas feições de linhas de ônibus. As linhas adquiridas por GPS foram utilizadas sem tratamento de ajustes posicionais ou mescla de feições.

Foi realizada uma agregação espacial das linhas de itinerários dos ônibus com seus atributos de número de viagens para a camada-alvo de setores censitários 2010, por meio da ferramenta *spatial join*. Foi considerado um buffer de 30 m como limiar para este procedimento, a fim de considerar o erro posicional da diferença de datum original entre as camadas, além de considerar que é uma distância de influência entre um setor e seu vizinho quando o limite entre eles se trata de uma via de acesso contendo uma ou mais linhas de ônibus. Ainda neste procedimento, foram definidas regras de soma (SUM) do atributo "número de viagens" e a contagem (COUNT) de "ID", relativa ao número de linhas que estão contidas em cada setor censitário.

O fluxo do transporte público foi calculado por meio do número de linhas e do número de viagens que estas fazem. Uma vez que para cada setor censitário obtiveram-se estes dois parâmetros, foi realizada uma multiplicação entre ambos, normalizando-se o resultado em um índice de fluxo que varia entre 0 e 1 segundo a equação 1.

$$Flx = A \times B, \quad (1)$$

$$Flx_n = (Flx - Flx_{min}) / (Flx_{max} - Flx_{min}).$$

Em que:

Flx = corresponde ao fluxo de linhas de ônibus em determinado setor;

A = soma de linhas de ônibus que passam em determinado setor;

B = somatório do número de viagens de todas as linhas que passam em determinado setor;

Flx_n = fluxo de linhas de ônibus normalizado com valores entre 0 e 1, em que valores mais próximos de 0 indicam um fluxo de presença de ônibus menos intensa, enquanto valores próximos de 1 apontam o contrário.

Duas tabelas oriundas dos resultados do CENSO 2010 foram utilizadas para obter o dado, por setor censitário, de população e renda (IBGE, 2013) - planilhas Domicilio02_RN e Domicilio01_RN + ResponsavelRenda_RN – respectivamente. A população foi extraída a partir da variável “Moradores em domicílios particulares e domicílios coletivos”, enquanto a renda foi obtida a partir da razão entre as variáveis “Total do rendimento nominal mensal das pessoas responsáveis” e “Domicílios particulares e domicílios coletivos” resultando, desta forma, no dado de renda média por domicílio, em reais. Ao final, obtém-se uma camada de setores censitários com as seguintes informações: 1) Fluxo de linhas de ônibus normalizado, 2) População e 3) Renda.

2 Disponível em http://downloads.ibge.gov.br/downloads_geociencias.htm, acessado em setembro de 2014.

3 Disponível em http://downloads.ibge.gov.br/downloads_estatisticas.htm, acessado em setembro de 2014.

Em uma análise exploratória espacial, é fundamental verificar a caracterização da dependência espacial, identificando como atributos de um fenômeno estudado estão correlacionados no espaço. Índices globais de autocorrelação espacial se mostram eficientes em áreas de estudos socioeconômicos (Ramos, 2002) e de planejamento de transportes como apresentam Lopes (2005) e Krempi (2004). Um índice que expressa autocorrelação espacial considerando apenas o primeiro vizinho é o índice global de Moran, o qual indica a existência ou não de áreas agrupadas (*clusters*), cujos atributos se apresentam de maneira semelhante no espaço (Bailey e Gatrell, 1995). O índice expressa a autocorrelação de atributos entre pares em função de suas respectivas distâncias. Quando o dado não é estacionário, a função decresce muito lentamente (Souza et al., 2007). O índice global de Moran I é expresso de acordo com a fórmula a seguir:

$$I = \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (z_i - \bar{z})(z_j - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})^2} \quad (2)$$

em que,

n corresponde ao número de áreas;

z_i é o valor do atributo considerado na área i ;

\bar{z} é o valor médio do atributo na região de estudo, e

w_{ij} são os pesos atribuídos conforme a conexão entre as áreas i e j .

O índice de Moran testa a hipótese nula de independência espacial. Caso a hipótese se confirme, o valor deste índice tende a 0. Valores positivos (entre 0 e +1) indicam uma correlação direta, e valores negativos (entre 0 e -1), correlação inversa; ambos, entretanto, apontam para a dependência espacial. Para observar graficamente as relações entre W_z e Z podem ser construídos gráficos, denominados de Diagramas de Espalhamento de Moran, o que permite uma comparação visual entre os valores do atributo e de seus vizinhos de maneira indutiva (Anselin, 1995). A divisão deste tipo de gráfico em quadrantes (Figura 1) permite observar quatro combinações possíveis de valores para W_z e Z . Os pontos localizados nos quadrantes Q1 e Q2 indicam as zonas onde o valor medido do atributo se assemelha à média dos vizinhos (Q1 valor positivo e média positiva – HH, e Q2, valor negativo e média negativa – LL), indicando uma autocorrelação positiva. Por outro lado, pontos localizados nos quadrantes Q3 e Q4, indicam uma autocorrelação negativa, onde Q3 aponta para valores negativos e médias positivas – LH e Q4 aponta para valores positivos e médias negativas – HL (Anselin, 1995). Os resultados de correlação entre esses quadrantes podem ser espacializados tematicamente, facilitando a visualização do fenômeno, por meio do mapa de Indicadores Locais de Associação Espacial - LisaMap (Anselin, 1995).

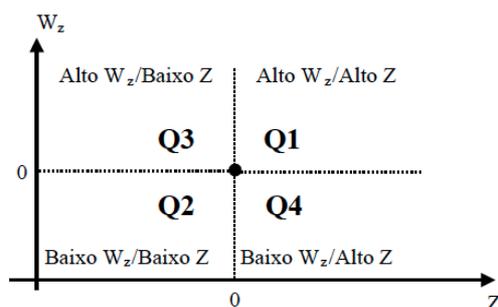


Figura 1 – Gráfico de espalhamento de Moran.

Fonte: Krempi (2004).

Já para se calcular a existência de autocorrelação entre uma dada variável observada em uma região, e uma outra variável observada em uma região vizinha, é requerida a adoção do I de Moran global multivariado. Essa estatística fornece de maneira formal o grau de relacionamento entre as duas variáveis.

Segundo destaca Anselin et al. (2002), assim como se pôde obter um coeficiente de autocorrelação espacial global num contexto bivariado, também é possível conseguir uma medida de autocorrelação espacial local multivariada. Logo, a idéia central é descobrir se valores de uma determinada variável em uma região guardam relação com valores de uma outra variável em regiões vizinhas. O coeficiente do I de Moran multivariado ou bivariado, com a matriz W já normalizada na linha, é dado pela seguinte equação:

$$I_{k,l} = \frac{Z_k' W Z_l}{n} \quad (3)$$

Em que n é a representação do número de observações e W a matriz de pesos espaciais. A soma dos quadrados no denominador é constante e igual a n independente de z_k ou de z_l . O diagrama de dispersão de Moran multivariado segue o mesmo padrão de análise do diagrama de dispersão de Moran univariado, só que no primeiro o eixo das ordenadas é representado por Wx , que é a variável x defasada para os vizinhos confrontada com a variável y no eixo das abscissas (Anselin et al., 2002)

De acordo com Anselin et al. (2002), no que tange à interpretação, essa estatística dá uma indicação do grau de associação linear (positiva ou negativa) entre o valor para uma variável em uma localização i e a média de outra variável nas localizações vizinhas. Além do mais, o autor destaca que é possível mapear os valores da probabilidade da medida, estatisticamente significantes, gerando o chamado mapa de significância bivariada do Moran local.

Com base nessas referências e de posse dos dados tratados, foi testada a hipótese inicial deste trabalho em analisar a presença ou não de autocorrelação espacial local bivariada entre as variáveis a) fluxo e população e b) fluxo e renda.

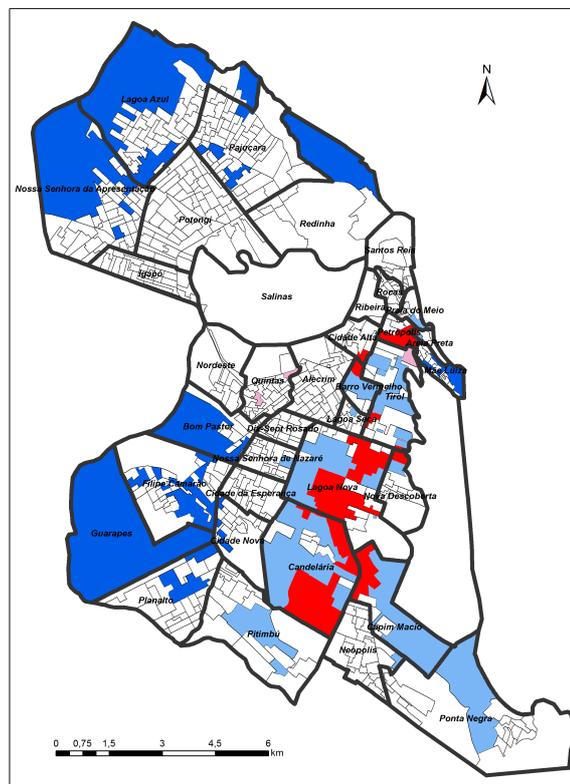
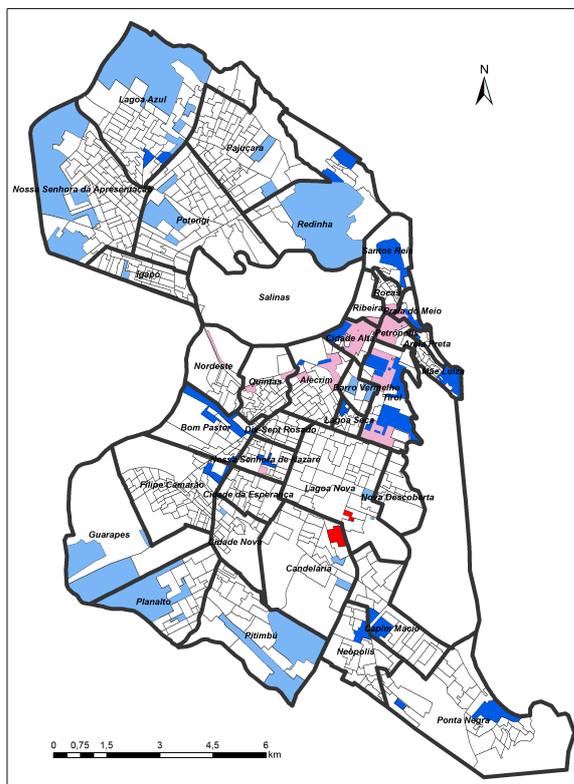
3. Resultados e Discussão

3.1 Fluxo e População

A população do município de Natal tem maior concentração na Zona Norte (38,30%) face às Zonas Oeste (27,06%), Sul (20,55%) e Leste (14,06%). Os bairros Nossa Senhora da Apresentação, Lagoa Azul, Pajuçara e Potengi, situados na Zona Norte do município, concentram grande parte desta população. Estes bairros apresentaram alto crescimento entre 2000 e 2010 (Natal, 2013), por volta de 3%, e um vetor de expansão de moradias da cidade com taxas de crescimento acima de 5% (IBGE, 2010). Outros vetores recentes de crescimento populacional são os bairros de Felipe Camarão e Planalto (Zona Oeste); Pitimbu e Neópolis (Zona Sul).

A análise bivariada de Moran resulta, segundo a Figura 2, em autocorrelação global negativa, o que evidencia que em certas áreas da cidade, não há grande oferta de transporte público face ao grande número de pessoas demandantes. Ainda que globalmente, o indicador reduzido I de Moran pode indicar que não há grande dependência espacial entre essas variáveis; uma análise do mapa de autocorrelação local (LISAMap) ressalta áreas em que o fenômeno ocorre conforme a hipótese levantada. As áreas em azul claro (LH) indicam uma baixa concentração de linhas de ônibus, ao passo que uma grande parcela da população se concentra nesses locais. Logo, sugere-se que essas áreas demandam uma maior oferta de linhas de transporte público. Destacam-se nessa classificação áreas dos bairros dos Guarapes e Planalto (Zona Oeste), considerados bairros de ocupação recente e intensificada por novos loteamentos. Áreas dos bairros de Nossa Senhora da Apresentação, Lagoa Azul e Potengi

(Zona Norte) também se enquadram nessa categoria, bem como dos bairros de Pitimbu e Neópolis (Zona Sul).



LisaMap (Fluxo x População)

□ Bairros □ não-significante ■ HH ■ LL ■ LH ■ HL

LisaMap (Fluxo x Renda)

□ Bairros □ não-significante ■ HH ■ LL ■ LH ■ HL

Figura 2 – Mapa de autocorrelação local (LISAMap) das variáveis fluxo e população.

Figura 3 – Mapa de autocorrelação local (LISAMap) das variáveis fluxo e renda.

As áreas em vermelho claro (HL) apresentam um comportamento inverso, baixa ocupação e grande oferta de linhas de transporte público. Destacam-se nessa categoria, setores no bairro da Ribeira (Zona Leste), por concentrarem dois terminais de ônibus; setores nos bairros Cidade Alta e Alecrim (Zona Leste), por abrigarem grande concentração comercial varejista e, por fim, setores ao redor do maior *shopping center* da cidade, o Midway Mall, o que reflete grande concentração de ônibus e integrações intra-urbanas e inter-urbanas. Vale desconsiderar a grande área a leste, que abriga a área do Parque Estadual conhecido como Parque das Dunas, que representa um *outlier* (valor anômalo) na análise realizada.

3.2 Fluxo e Renda

Segundo dados do IBGE (IBGE, 2010), a renda no município de Natal é bastante heterogênea e concentrada em bairros específicos. Bairros como Guarapes, Felipe Camarão e Bom Pastor (Zona Oeste), além de Nossa Senhora da Apresentação, Lagoa Azul e parte de Pajuçara e Redinha (Zona Norte), concentram baixos valores de rendimento médio com valores de até um salário mínimo (IBGE, 2010). Por outro lado, bairros como Petrópolis, Tirol, Areia Preta e Barro Vermelho (Zona Leste) e Capim Macio, Ponta Negra, Neópolis, Candelária e Lagoa Nova (Zona Sul) apresentam rendimentos médios acima de quatro salários mínimos (IBGE, 2010) e formam uma área homogênea de rendimentos mais altos da cidade.

A correlação entre disponibilidade de serviços de transporte e renda é positiva, portanto, em algumas áreas a relação entre renda e acesso a transporte público é diretamente proporcional, confirmando a hipótese inicial levantada neste trabalho. A Figura 3 ilustra que diversas áreas situadas nos bairros de Guarapes, Felipe Camarão, Bom Pastor (Zona Oeste) e Nossa Senhora da Apresentação, Lagoa Azul, Pajuçara e Redinha (Zona Norte) apresentam correlação negativa (LL), ou seja, a predominância de famílias de baixa renda sem grande oferta de transporte público.

Algumas das áreas citadas acima, por concentrarem famílias com renda superior à média, dividem o cenário em análise. Áreas de bairros como Petrópolis, Tirol, Lagoa Nova e Candelária apresentam uma correlação positiva (HH), evidenciando a presença de linhas de ônibus em áreas nobres. Por outro lado, bairros como Ponta Negra, Capim Macio, Neópolis e Pitimbu, apesar de serem classificados como bairros nobres, não dispõem de uma gama de linhas de transporte público necessária para fazer frente à demanda, como ilustra a Figura 3, em azul claro (LH).

4. Conclusões

A hipótese deste trabalho se confirmou para o município de Natal. O uso de geotecnologias, especificamente a análise espacial aliada a dados socioeconômicos, pode colaborar para o planejamento dos transportes. Este conjunto de técnicas mostrou que a oferta de linhas de ônibus é inversamente correlacionada à presença de concentração populacional e diretamente proporcional à renda em diversas partes da cidade.

A configuração das linhas de transporte público, modal ônibus, encontra-se desatualizada face à evolução da concentração de população, e isto é observável de modo mais significativo em áreas de bairros de recente e intenso crescimento na Zona Oeste (Planalto e Guarapes) e na Zona Norte (Nossa Senhora da Apresentação, Lagoa Azul e Potengi). Por outro lado, a oferta concentrada em bairros nobres favorece aqueles que dispõem de um nível de renda elevado, os quais, muitas vezes, dispensam a sua necessidade. Em contrapartida, bairros da Zona Oeste e Zona Norte carecem deste meio de transporte, comprovando, por meio de ferramentas de análise espacial, que a evolução da oferta de novas linhas ou do replanejamento destas poderiam atender melhor à mais recente configuração populacional do município.

As variáveis trabalhadas neste estudo são importantes, entretanto, é necessário avaliar outros dados inerentes ao uso do transporte público, a fim de se verificar a sua real demanda tanto em áreas nobres quanto em áreas menos favorecidas. Incentivos do governo nos últimos anos trouxeram facilidades de crédito para a aquisição de veículos particulares, e assim, uma avaliação acerca do fluxo de passageiros por linhas, bem como do custo de mobilidade devem ser consideradas em trabalhos futuros.

5. Referências

ANSELIN, L. Local indicators of spatial association — LISA. **Geographical Analysis**, v. 27, p. 93–115, 1995.

ANSELIN, L. **Exploring spatial data with GeoDaTM: a workbook**. University of Illinois. 2005.

ANSELIN, L., SYABRI, I., SMIRNOV, O. Visualizing multivariate spatial correlation with dynamically linked windows. In Anselin, L. And Rey, S., editors, **New Tools for Spatial Data Analysis: Proceedings of the Specialist Meeting**. Center for Spatially Integrated Social Science (CSISS), University of California, Santa Barbara. CD-ROM, 2002.

BAILEY, C.; GATRELL, A. C. **Interactive spatial data analysis**. Upper Saddle River: Prentice Hall, 1995. 432p.

BRASIL. **Lei nº 12.587 de 03 de janeiro de 2012.** Lei de mobilidade urbana. Legislação Federal. Disponível em http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112587.htm. Acessado em setembro de 2014.

ESRI. **ArcGIS Desktop: Release 10.2.** Redlands, CA: Environmental Systems Research Institute, 2011.

GOODCHILD, M. F. Geographic information systems and disaggregate transportation modeling. **Geographical Systems**, v. 5, p. 19-44, 1998.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Sinopse do censo demográfico 2010.** Rio de Janeiro. Disponível em: http://www.ibge.gov.br/home/estatistica/populacao/default_censo_2000.shtm/default_sinopse.shtm, 2010. Acesso em: ago. De 2014.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Relatórios metodológicos v. 41: Metodologia do censo demográfico 2010.** Rio de Janeiro, 2013. 712 p.

IPEA. **Infraestrutura social e urbana no Brasil, subsídios para uma agenda de pesquisa e formulação de políticas públicas: a mobilidade urbana no Brasil.** Comunicados do IPEA N° 94. Série eixos do desenvolvimento brasileiro. Brasília, 2011.

ITRANS – Instituto de Desenvolvimento e Informação em Transporte. **Mobilidade e Pobreza.** Brasília: Itrans, 2004.

KREMPI, A. P. **Explorando recursos de estatística espacial para análise da acessibilidade na cidade de Bauru.** Dissertação (Mestrado em Engenharia Civil). USP. São Carlos, 2004.

LOPES, S. B. **Efeitos da dependência espacial em modelos de previsão de demanda por transporte.** Dissertação (Mestrado em Engenharia Civil). USP. São Carlos, 2005.

NATAL. Prefeitura Municipal de Natal. Secretaria Municipal de Meio Ambiente e Urbanismo. **Anuário 2013.** Natal: Departamento de Informação, Pesquisa e Estatística, 2013. 400p.

NYERGES, T. L. GIS in urban-regional transportation planning. **The geography of urban transportation.** 3rd. Ed. New York. 2004.

PUCHER, J. Public Transportation. In: HANSON, S. e GIULIANO, G. (Org). **The geography of urban transportation.** 3rd. Ed. New York. 2004.

RAMOS, F. R. **Análise espacial de estruturas intra-urbanas: o caso de São Paulo.** Dissertação (Mestrado em Sensoriamento Remoto). 2002, 139p.

SOUZA, S. M.; CARVALHO, M. S.; CRUZ, O. G.; RAGONI, V. Análise espacial de dados de áreas. In: SANTOS, S. M.; SOUZA, W. V. **Introdução à estatística espacial para a saúde pública.** Ministério da Saúde, Fundação Oswaldo Cruz., organizadores. - Brasília : Ministério da Saúde, 2007. 120 p.

SILVA, A. N. R. **Sistemas de informações geográficas para planejamento de transportes.** Texto sistematizado elaborado para concurso de Livre-Docência, Departamento de Transporte, Escola de Engenharia de São Carlos, Universidade de São Paulo. 112p, 1998.

SILVA, A. N. R.; ROSE, A.; RODRIGUES, D. S. An assesment method for GIS-T Software. **Proceedings of 8th International Conference on Computers in Urban Planning and Urban Management,** Sensai, Japão, em CD-ROM, 2003.

TEIXEIRA, G. L. **Uso de dados censitários para identificação de zonas homogêneas para planejamento de transportes utilizando estatística espacial.** Dissertação (Mestrado em Planejamento de Transportes), Universidade de Brasília, Brasília, 2003.

WATERS, Nigel M. Transportation GIS: GIS-T. **Geographical information systems**, v. 2, p. 827-844, 1999.