



**UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE GEOCIÊNCIAS**



**PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS**

**WEEBERB JOÃO RÉQUIA JÚNIOR**

**MODELAGEM ESPACIAL DA EXPOSIÇÃO HUMANA ÀS  
FONTES DE POLUIÇÃO DO AR NO DISTRITO FEDERAL:  
o uso e ocupação do solo como variável preditora**

**Tese de Doutorado**

**Nº 25**

**Brasília**

**2015**

WEEBERB JOÃO RÉQUIA JÚNIOR

**MODELAGEM ESPACIAL DA EXPOSIÇÃO HUMANA ÀS  
FONTES DE POLUIÇÃO DO AR NO DISTRITO FEDERAL:  
o uso e ocupação do solo como variável preditora**

Tese apresentada ao Instituto de Geociências da Universidade de Brasília, como requisito parcial para obtenção do título de Doutor em Geociências Aplicadas.

Orientador: Prof. Dr. Henrique Llacer Roig (Universidade de Brasília)

Co-orientador: Prof. Dr. Petros Koutrakis (Universidade de Harvard)

Brasília

2015

**MODELAGEM ESPACIAL DA EXPOSIÇÃO HUMANA ÀS FONTES DE  
POLUIÇÃO DO AR NO DISTRITO FEDERAL:  
o uso e ocupação do solo como variável preditora**

WEEBERB JOÃO RÉQUIA JÚNIOR

BANCA EXAMINADORA

Prof. Dr. Henrique Llacer Roig – Orientador  
(Instituto de Geociências – Universidade de Brasília)

Prof. Dra. Helen da Costa Gurgel – Examinadora interna  
(Departamento de Geografia – Universidade de Brasília)

Prof. Dr. Walter Massa Ramalho – Examinador interno  
(Faculdade de Ceilândia – Universidade de Brasília)

Prof. Dra. Ligia Vizeu Barrozo – Examinadora externa  
(Departamento de Geografia – Universidade de São Paulo)

Prof. Dr. Paulo Hilário Nascimento Saldiva – Examinador externo  
(Faculdade de Medicina – Universidade de São Paulo)

BRASÍLIA

2015

## **FICHA CATALOGRÁFICA**

Réquia Júnior, Weeberb J.

Modelagem espacial da exposição humana às fontes de poluição do ar no Distrito Federal: o uso e ocupação do solo como variável preditora / Weeberb João Réquia Júnior; orientação de Henrique Llacer Roig. Brasília, 2015.

316p.

Tese de Doutorado (D) – Universidade de Brasília / Instituto de Geociências, 2015.

1. Exposição humana; 2. Doenças cardiorrespiratórias; 3. Poluição do ar; 4. Modelagem espacial; 5. Uso do solo.

## **CESSÃO DE DIREITOS**

NOME DO AUTOR: Weeberb João Réquia Júnior

TÍTULO DA TESE DE DOUTORADO: Modelagem espacial da exposição humana às fontes de poluição do ar no Distrito Federal: o uso e ocupação do solo como variável preditora

GRAU: Doutor

ANO: 2015

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese de doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. Esse direito poderá ocorrer somente após a publicação dos artigos contidos no documento. O autor reserva-se a outros direitos de publicação e nenhuma parte desta tese de doutorado pode ser reproduzida sem a autorização por escrito do autor.

---

Weeberb João Réquia Júnior  
weeberb@gmail.com



## PREFÁCIO

Este prefácio visa apresentar as instituições envolvidas no desenvolvimento da tese, as instituições que financiaram diretamente o desenvolvimento e as normas usadas para a elaboração do texto.

Esta tese foi desenvolvida entre a Universidade de Brasília (Instituto de Geociências) e a Universidade de Harvard (School of Public Health). Três instituições financiaram diretamente o desenvolvimento desta tese:

1- Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES)

Número de processo: 99999.004511/2014-00

2- Universidade de Harvard

Number ID: 20965134

3- United States Environmental Protection Agency (EPA)

Grant RD: 83479801

A elaboração do texto da tese foi baseada nas seguintes normas (NBR) da Associação Brasileira de Normas e Técnicas (ABNT):

- NBR 6023 (Apresentação de referências)
- NBR 10520 (Apresentação de citações em documentos)
- NBR 14724 (Apresentação de trabalhos acadêmicos)
- NBR 14714 (Apresentação das seções)
- NBR 6027 (Apresentação de sumário)

À minha família.

## AGRADECIMENTOS

Agradeço a Deus pelo dom da inteligência. Sem esse dom, não teria a oportunidade de me divertir fazendo ciência.

Muitas pessoas e instituições contribuíram para o desenvolvimento deste trabalho. Esta tese não existiria sem essas contribuições, ou no mínimo, eu teria percorrido um caminho muito mais árduo.

Para obedecer um sentido lógico, os agradecimentos serão mencionados conforme as contribuições que eu recebi nos períodos da minha vida. Pois este trabalho não é um fruto apenas dos últimos quatro anos, é o fruto de um processo longo de ensinamento, observação, obediência, respeito, correção, castigo, carinho, amor, dedicação, perseverança, determinação, companheirismo, amizade, confiança, presença, abdicção, apoio e, é claro, um pouquinho de sorte.

Agradeço profundamente aos meus pais pelos ensinamentos, exemplos, correções e apoio. A base familiar dos meus pais é a sustentação de todas as minhas conquistas. Obrigado pai e mãe por tudo! Pai, obrigado pelo exemplo de viver simples. Foi com muita simplicidade que eu fiz este trabalho! Mãe, obrigado pelo exemplo de que a emoção é o que determina certas coisas da vida. Foi uma emoção fazer este trabalho!

Agradeço imensamente à minha irmã que sempre teve um papel que se estende ao amor de uma irmã. Isso sempre me deu um conforto a mais nos momentos que exigiram muita energia. Sem ela, provavelmente eu não teria terminado o ensino fundamental, não teria concluído o ensino médio, e com certeza não estaria escrevendo este agradecimento. Ia (a forma como eu a chamo), obrigado por ter me ensinado que para conquistar, tem que se esforçar. Foi com muito esforço que eu fiz este trabalho!

Agradeço também ao Paulo, meu cunhado, e aos meus sobrinhos, Liana e Pedro. O Paulo foi o que me disse quando eu terminei o ensino médio que eu deveria fazer uma graduação e uma pós-graduação, pois isso seria importante para mim. Sem perceber, eu segui os conselhos dele. Aos meus sobrinhos Liana e Pedro, pois são jovens que me motivam a ser um exemplo para eles, mesmo eu sabendo que eu não tenho esse perfil.

Agradeço enormemente a minha amada esposa, Aline. Ela foi companheira, atenciosa e compreensiva em toda minha vida acadêmica, desde o meu mestrado. Eu prometo que o doutorado será o último momento! A presença da Aline ao meu lado deixou o caminho mais fácil, mesmo sabendo que eu estava passando por momentos complicados. Tudo era mais fácil pois ela estava lá, apoiando-me e se mostrando presente. As minhas ausências e as dificuldades nos Estados Unidos durante o meu período na Universidade de Harvard (o inverno, a solidão, as limitações financeiras etc.) não foram o suficiente para fazê-la desanimar. Pelo ao contrário, ela que me animava quando eu caía. Obrigado por me mostrar o que é ser forte nos momentos turbulentos, sobretudo, ser forte quando nos abdicamos para ajudar o próximo. Este doutorado foi fruto dessa sua característica!

Agradeço à minha filha, Ana Clara. Mesmo ela ainda não tendo idade para entender o que é este momento na minha vida, mas as energias e as motivações que eu precisei eu encontrei com ela. A Ana Clara é como a mãe dela, é forte mesmo quando tem que se abdicar para ajudar o próximo. Ela compartilhou muitas dificuldades decorrentes do doutorado, minhas ausências e a vida nos EUA são alguns exemplos. Neste exato momento eu estou tentando escrever este texto com ela no meu colo, pois ela não aguenta mais as minhas desculpas, do tipo – “filha, não posso brincar agora com você, pois tenho que trabalhar no meu doutorado”.

Agradeço ao meu orientador da Universidade de Brasília, Professor Henrique Roig. O Roig (ele me deu essa liberdade de chamá-lo dessa forma) foi muito mais que um orientador. Além das orientações sábias e o papel de um extraordinário mentor, ele foi um grande amigo nesta minha jornada. Em muitas de nossas reuniões, as perguntas eram divididas em duas – “Weeberb, como está o experimento? E, Weeberb, como está a sua vida? ”. Tive muita sorte em tê-lo como orientador, pois de brinde, ganhei um grande amigo!

Agradeço imensamente ao Professor Paulo Saldiva da Universidade de São Paulo. Ele foi fundamental por ter feito minha indicação à Universidade de Harvard. Obrigado Prof. Saldiva por sua confiança!

Agradeço ao meu orientador da Universidade de Harvard, Professor Petros Koutrakis. *Prof. Petros, thank you so much for your confidence and steady disposition to advice and support me in US. Thank you for the constructive discussions, comment, and continuous*

*enthusiasm. I am very grateful! Thank you for give me a scholarship, which helped me a lot to survive in Boston (an amazing city, but very expensive!!!).*

Agradeço também aos meus colegas que me apoiaram na Universidade de Harvard. *I wish to thank all my colleagues from Harvard, Alice Smith, Rose West, Whan-Chen, Jessie Tang, Sharir, Souza Achilleos, Mike Wolfson, Antonella Zanobeti. Alice, thank you so much for help me to find a place to live. Whan-Chen, thank you so much for our friendship.*

Agradeço às pessoas que me ajudaram financeiramente enquanto estive nos EUA. A vida na América não é nada fácil! Obrigado mãe, Ia (minha irmã), Tina (minha sogra) e Sandra (tia da minha esposa).

Agradeço ao meu tio Eurípedes. Pois ele me ajudou de uma forma muito generosa para provar ao governo americano que eu tinha condições financeiras de ir para os EUA.

Agradeço às pessoas que me ajudaram na revisão do texto, Aline (minha esposa) e Raylton Carvalho.

Por fim, agradeço às instituições que me apoiaram. À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) por ter me apoiado com uma bolsa de estudo no Brasil e nos EUA; Ao Instituto de Geociências da Universidade de Brasília, por ter apoiado a publicação de um artigo; À Universidade de Harvard por ter me apoiado com uma bolsa de estudo; À agência americana *United States Environmental Protection Agency* (EPA) por ter apoiado o desenvolvimento das pesquisas, sobretudo, a publicação dos artigos; À Fundação de Apoio às Pesquisas do DF (FAPDF) por ter apoiado a apresentação de um dos resultados em um congresso em Toronto, Canadá.

“What’s the use of having developed a science well enough to make predictions if, in the end, all we’re willing to do is stand around and wait for them to come true?”

Sherwood Rowland

## RESUMO

As fontes de poluição do ar são associadas com efeitos adversos na saúde humana. A ocorrência de doenças relacionadas ao sistema cardiorrespiratório é exemplo de um indicador da exposição que as pessoas estão sujeitas quando estão em contato com as fontes de poluição atmosférica. A medição dessa exposição é usada como ferramenta colaborativa para o processo de controle e gestão das fontes, que visam, principalmente, a promoção da qualidade de vida para a população. Dentre os métodos de mensuração (estações de monitoramento, sensoriamento remoto, modelos em uso do solo, biomonitoramento, equipamentos portáteis), o desafio consiste no equilíbrio entre a finalidade da mensuração e o custo econômico envolvido. Diante desse desafio operacional e econômico, a grande maioria dos centros urbanos ainda carecem de um sistema eficiente para mensuramento da exposição humana à poluição do ar, por exemplo, o Distrito Federal (DF). O método que representa os modelos com variáveis relacionadas ao uso e ocupação do solo é proeminente para os desafios encontrados em centros urbanos como o DF, e até mesmo para áreas que já possuem um monitoramento consolidado e eficiente. No entanto, os modelos em uso do solo ainda estão em processo inicial de pesquisa, gerando assim uma necessidade de aperfeiçoamento. Por exemplo, ainda pouco se sabe sobre a relação espacial entre o uso do solo, as fontes de poluição do ar e a saúde humana. Portanto, a presente pesquisa testou a hipótese de que a exposição da população do DF às fontes de emissões de poluentes do ar pode ser estimada por meio da classificação e mensuração do uso e ocupação do solo. Considerou-se como uso do solo neste trabalho três categorias: o relacionado com o tráfego de veículos, os demais tipos de uso e o uso relacionado com as tipologias urbanas – Tipos de Estruturas Urbanas (UST). Esta pesquisa teve sete objetivos específicos: 1) estimar as emissões das vias de tráfego; 2) construir um banco de dados geográficos para os dados de saúde; 3) avaliar a relação entre saúde e emissões decorrentes das vias de tráfego; 4) avaliar os padrões de distribuição espacial da ocorrência de doenças cardiorrespiratórias; 5) identificar as áreas prioritárias para mensuração da exposição humana às fontes de poluição atmosférica; 6) estimar o risco da ocorrência de doenças cardiorrespiratórias com base no uso e ocupação do solo; e 7) avaliar a relação entre UST e o risco de doenças cardiorrespiratórias. Os métodos utilizados são resumidos em: *Bottom-up* para o cálculo de emissões veiculares; Modelagem em Sistemas de Informações Geográficas (SIG) para criação de um banco de dados; Análise geoestatística com Global Moran's I, Getis-Ord General G, semivariogramas e k-function; Analytic Hierarchy Process (AHP) para tomada de decisão em julgamento de valores, e; Regressão espacial do tipo Ordinary Least Square (OLS) e quantile regression para análise da relação entre fontes de poluição e saúde humana. Os resultados deste trabalho podem ser sintetizados em: Os veículos leves apresentam um comportamento espacial diferenciado nas emissões de poluentes; A ocorrência de doenças do sistema cardiorrespiratório possui um padrão espacial do tipo agrupado; O sistema atual de monitoramento no DF operado pelo governo (estações fixas) não monitora áreas que possuem nível de prioridade altíssimo; o número de veículos leves foi associado com o risco de ocorrência de internações por doenças cardiorrespiratórias (risco= 6 internações; 95% IC: 2,6; 14,6); Observou-se que um aumento de 2.500m de rodovias foi associado com um aumento de 46% no risco de doenças cardiorrespiratórias;

Um aumento de 6.000 m de ruas e avenidas esteve associado com um aumento de 51% do risco de doenças cardiorrespiratórias; Um aumento de 1 km<sup>2</sup> de áreas verdes intraurbana esteve associado com menos 2 internações por doenças cardiorrespiratórias; As pessoas que vivem  $\leq 500$  m dos pontos mais próximos de incêndios florestais possuem mais chances de terem doenças do sistema cardiorrespiratório que as pessoas que vivem  $> 500$  m; As áreas residenciais com UST que possuem característica de prédios baixos (até 5 andares) foram associadas com um aumento significativo na ocorrência de internações; As áreas residenciais com UST que possuem característica de prédios altos (até 34 andares) e as áreas rurais com UST que possuem característica de baixa densidade foram associadas com o decréscimo no risco de internações; As áreas com UST que possuem característica de áreas em urbanização, prédios públicos e áreas mistas entre residências e comércio foram associadas com um aumento no risco de internações por doenças cardiorrespiratórias. Por fim, com intuito de facilitar o acesso às descobertas desta tese, todos os resultados com formatos espaciais foram disponibilizados em uma plataforma GISWEB. Os resultados deste trabalho contribuem de forma prática e aplicada como ferramenta de apoio para a implantação de políticas que visam o planejamento e gestão da ocupação urbana, do meio ambiente e da saúde pública. Especificamente no DF, esta pesquisa pode contribuir diretamente para minimizar os desafios enfrentados pela região, quanto ao monitoramento da exposição humana às fontes de poluição (que é precário no DF), quanto ao crescimento acelerado da área urbana (em torno de 30% nos últimos 15 anos), quanto ao elevado número de veículos automotores (uma taxa de 0,6 veículos por habitante) e quanto ao alto número de pessoas que apresentaram doenças do sistema cardiorrespiratório (400 mil pessoas internadas e 15 mil óbitos nos últimos 5 anos).

**Palavras chave:** Exposição humana, Doenças cardiorrespiratórias, Poluição do ar, Modelagem espacial, Uso do solo.



## ABSTRACT

Air pollution sources are associated with harmful effects on human health. Cardiorespiratory diseases occurrence are indicators of human exposure to air pollutants. The measurement of this exposure is used as collaborative tool for sources control and management in order to promote quality of life to population. Among the methods for measurement (monitoring station, remote sensing, land use models, biomonitoring, portables devices), the challenge is related to the equilibrium between the aim of the measurement and the cost. Faced with this operational and economic challenge, most of the urban centers still have a gap to measure human exposure to air pollution, for example, the Federal District (FD). The method which represents the land use models is prominent for the challenges in urban areas as the FD, and also for urban areas which already have a monitoring system consolidated. However, the land use models are in initial process of research, which need more development. For instance, it is still unclear the understanding of the spatial relationship between land use, air pollution sources and human health. Therefore, this research tested the hypothesis that in the FD human exposure to air pollution sources can be estimated by classification and measurement of land use. It was considered as land use in this study three categories: vehicular traffic, conventional land use, and land use related to urban typology – Urban Structure Types (UST). It was addressed seven specific objectives in this research: 1) to estimate emissions from the roads; 2) to create a geodatabase for health data; 3) to assess the relationship between health and vehicle emissions; 4) to evaluate spatial patterns of cardiorespiratory diseases; 5) to identify high-priority areas to measure human exposures to air pollution sources; 6) to estimate the cardiorespiratory disease risk related to land use; and 7) to evaluate the relationship between UST and cardiorespiratory diseases risk. The methods are as follows: bottom-up to calculate vehicular emissions; Modeling in Geographic Information System (GIS) for geodatabase creation; Geostatistical analysis with Global Moran's I, Getis-Ord General G, semivariogram analysis and k-function; Analytic Hierarchy Process (AHP) for decision making and values judgment, and; Ordinary Least Square regression (OLS) and quantile regression for assessment of the relationship between sources and human health. The findings are as follows: the light vehicles presented a different (cluster) spatial patters of air pollution emissions; Spatial patterns of cardiorespiratory diseases are clustered; There are no air pollution monitoring stations in areas which were identified with high priorities levels to measure human exposures; the number of light vehicles was associated with hospital admissions risk (risk = 6 admissions; 95% CI: 2.6; 14.6); A 2,500 m increase in highways was associated with a 46% increase in cardiorespiratory diseases; A 6,000 m increase in streets and avenues was associated with a 51% increase in cardiorespiratory diseases. A 1km<sup>2</sup> increase in green areas intra urban was associated with less 2 hospital admissions. Individuals who live ≤500 m from the nearest point of wildfire are more likely to have cardiorespiratory diseases than those living >500 m. Residential areas with UST - low buildings (up to 5 floors) were associated with increases in hospital admissions risk. Residential areas with UST – high buildings (up to 34 floors) and rural areas with UST – low density – were associated with decreased hospital admissions risk. UST classified in urbanization areas, public buildings and mixed areas (residences and commerce) were associated with

increases in hospital admissions risk. Finally, in order to make easy the access to the results from this study, all findings with spatial format are available in a GISWEB platform. The results from this study contribute to create public policies in urban planning, land use, environment and public health. Specifically in the FD, this research can minimize the challenges present on the region, such as, human exposure monitoring to air pollution sources (which is inefficient); rapid urban growth (30% on the last 15 years); high number of vehicles (0.6 vehicles per inhabitants); and high number of people with cardiorespiratory diseases (400,000 hospital admissions and 15,000 deaths on the last 5 years).

**Keywords:** Human exposure, Cardiorespiratory diseases, Air pollution, Spatial modelling, Land use.

## LISTA DE FIGURAS

Figura 1 - Modelo conceitual da pesquisa. ....	33
Figura 2 - Evolução do número de veículos no Brasil. ....	44
Figura 3 - Distribuição espacial da concentração de MP <sub>2,5</sub> na região nordeste dos EUA. .....	53
Figura 4 - Número de mortes, emissões de SO <sub>2</sub> e fuligem em Londres - dezembro de 1952. ....	58
Figura 5 - Harvard six cities, expectativa de vida e concentração de MP <sub>2,5</sub> . ....	59
Figura 6 - Patologias do sistema respiratório decorrentes da poluição do ar. ....	60
Figura 7 - Relação entre atividades antrópicas e efeitos sobre a saúde. ....	63
Figura 8 - Modelo fonte-receptor que define exposição. ....	68
Figura 9 - Agrupamento espacial da ocorrência de cólera em Londres, 1855. ....	69
Figura 10 - Exposição humana à poluição atmosférica nos Estados Unidos. ....	69
Figura 11 - Esquema simplificado das funções básicas do SIG. ....	70
Figura 12 - Variograma experimental para a exposição ao O <sub>3</sub> . ....	71
Figura 13 - Área de estudo. ....	77
Figura 14 - Objetivos específicos da tese (separados por Capítulos) e dados de entrada. .....	83
Figura 15 - Consolidação dos dados de veículos em um único geodatabase. ....	89
Figura 16 - Etapas utilizadas na análise do inventário. ....	92
Figura 17 - Método de classificação utilizado para a distribuição espacial dos dados. .	94
Figura 18 - Gráfico boxplot sobre a frota de veículos e representação espacial dos outliers. ....	95
Figura 19 - Gráficos da variação espacial da emissão de poluentes entre as 233 vias estudadas e conforme o tipo de veículo (toneladas/ano). ....	97
Figura 20 - Mapas da variação espacial da emissão de poluentes entre as vias estudadas e conforme o tipo de veículo (toneladas/ano). ....	98
Figura 21 - Gráfico boxplot sobre a taxa de emissão total de poluentes (toneladas/ano). .....	99

Figura 22 - Mapas da variação espacial da emissão total de poluentes (toneladas/ano). .....	100
Figura 23 - Padrão de endereçamento adotado na maior parte das áreas urbanas no DF. .....	108
Figura 24 - Fluxograma da avaliação entre poluição e saúde.....	109
Figura 25 - Fluxo dos processos para a primeira parte da criação do BDGeo. ....	111
Figura 26 - Fluxo dos processos para a segunda parte da criação do BDGeo.....	112
Figura 27 - Distribuição espacial do número de pacientes de todas as idades no DF. .	113
Figura 28 - Exemplo de um semivariograma. ....	124
Figura 29 - Exemplo dos resultados da análise multi-distance spacial cluster.....	125
Figura 30 - Gráfico da distribuição dos pacientes nos setores residenciais.....	127
Figura 31 - Distribuição espacial – pacientes de todas as idades por população. ....	128
Figura 32 - Distribuição espacial para os grupos etários – taxa de incidência.....	129
Figura 33 - Resultados do teste Global Moran's I. ....	130
Figura 34 - Resultados do teste Getis-Ord General G. ....	131
Figura 35 - Gráficos de semivariogramas (grupos etários de até 59 anos).....	132
Figura 36 - Gráficos de semivariogramas (grupo etário acima de 59 anos e grupo de todas as idades). ....	133
Figura 37 - Resultados da análise de distância - k function. ....	134
Figura 38 - Área urbana do DF.....	139
Figura 39 - Estruturação hierárquica genérica do AHP.....	140
Figura 40 - Etapas para indicação de áreas prioritárias para o monitoramento da poluição do ar. ....	144
Figura 41 - Meta e critérios primários do AHP. ....	145
Figura 42 - Sub-critérios da exposição humana. ....	145
Figura 43 - Sub-critério das fontes de poluição.....	148
Figura 44 - Sub-critérios das fontes de poluição. ....	150
Figura 45 - Mapas de áreas prioritárias segundo os critérios de exposição humana....	161
Figura 46 - Mapas de áreas prioritárias segundo os critérios de fontes de poluição. ...	162
Figura 47 - Mapa de áreas prioritárias segundo o critério características do ambiente.	163
Figura 48 - Mapa final de áreas prioritárias para monitoramento da poluição atmosférica.....	163

Figura 49 - Principais regiões identificadas como prioridade muito alta. ....	164
Figura 50 - Mapa final de prioridade e a localização das estações de monitoramento do DF. ....	165
Figura 51 - Etapas do estudo - análise entre saúde e características ambientais dos bairros. ....	169
Figura 52 – Exemplo da estimação de variáveis preditoras dentro de diferentes tamanhos de <i>buffers</i> . ....	173
Figura 53 - Gráfico scatterplot (modelo de regressão OLS e quantile regression). ....	176
Figura 54 – Variação dos coeficientes ao decorrer dos quantis (modelo de regressão OLS e quantile regression). ....	177
Figura 55 - Bloxplot com o IQR e a função de densidade de probabilidade. ....	178
Figura 56 - Variação do risco entre os quantiles (considerando as rodovias dentro do <i>buffer</i> de 500 m). ....	181
Figura 57 – Variação do risco no decorrer dos <i>buffers</i> – rodovias, ruas e avenidas. ...	185
Figura 58 - Variação do risco no decorrer dos <i>buffers</i> – veículos leves, pesados e motocicletas. ....	186
Figura 59 - Variação do risco no decorrer dos <i>buffers</i> – áreas industriais e comerciais. ....	187
Figura 60 - Variação do risco no decorrer dos <i>buffers</i> – áreas de solo exposto, verde intraurbana e rios. ....	188
Figura 61 - Variação do risco no decorrer dos <i>buffers</i> – CO e NOx. ....	189
Figura 62 - Variação do risco no decorrer dos <i>buffers</i> – renda. ....	190
Figura 63 - Variação do risco no decorrer dos <i>buffers</i> – altimetria. ....	190
Figura 64 - Variação do risco no decorrer dos <i>buffers</i> – incêndios florestais. ....	191
Figura 65 – Mapas de risco considerando o quantile 0,90. ....	192
Figura 66 - Mapas de risco considerando o quantile 0,95. ....	193
Figura 67 - Etapas do estudo - análise entre saúde e UST. ....	199
Figura 68 - Análise das USTs com base na escala. ....	201
Figura 69 - Comparação entre o método convencional de classificação do uso do solo e UST. ....	202
Figura 70 - Chave de classificação das USTs no DF. ....	204
Figura 71 - USTs do DF. ....	205

Figura 72 – Quantidade de USTs em termos de IQR (m2) ao longo dos <i>buffers</i> – áreas residenciais e áreas verdes.....	209
Figura 73 - Quantidade de USTs em termos de IQR (m2) ao longo dos <i>buffers</i> – áreas públicas e áreas comerciais, industriais e mistas.....	210
Figura 74 - Risco (taxa de internações hospitalares).....	213
Figura 75 - Distribuição espacial das internações hospitalares no DF.....	268
Figura 76 – Sistema de endereçamento do DF.....	269
Figura 77 - Distribuição espacial da malha viária do DF.....	270
Figura 78 - Distribuição espacial dos veículos automotores nas principais vias do DF (233 vias).....	271
Figura 79 - Distribuição espacial da população do DF (total de pessoas por setor censitário). ....	272
Figura 80 - Distribuição espacial da renda (R\$) por setor censitário no DF.....	272
Figura 81 – Distribuição espacial da quantidade de alunos nas instituições de ensino no DF.....	273
Figura 82 - Distribuição espacial da média do consumo de água no DF (m <sup>3</sup> ). ....	274
Figura 83 – Distribuição espacial de todos os focos de queimadas no DF durante 2010 a 2012.....	274
Figura 84 – Uso do solo no DF.....	275
Figura 85 - Distribuição espacial do número de linhas por rodoviárias e terminais de ônibus no DF.....	276
Figura 86 - Localização do aeroporto do DF.....	276
Figura 87 - Altimetria no DF.....	277
Figura 88 – Umidade relativa do ar no DF.....	277
Figura 89 – Temperatura no DF.....	278
Figura 90 - Mosaico de ortofotos do DF.....	278
Figura 91 - Tipos de estruturas urbanas no DF.....	279
Figura 92 - Pessoas com até 5 anos - período noturno (habitantes / km <sup>2</sup> ).....	281
Figura 93 - Pessoas entre 6 e 17 anos - período noturno (habitantes / km <sup>2</sup> ). ....	281
Figura 94 - Pessoas entre 18 e 59 anos - período noturno (habitantes / km <sup>2</sup> ). ....	282
Figura 95 -Pessoas acima de 59 anos - período noturno (habitantes / km <sup>2</sup> ).....	282
Figura 96 - Pessoas com até 5 anos - período diurno (número de alunos / km <sup>2</sup> ). ....	283

Figura 97 - Pessoas entre 6 e 17 anos - período diurno (número de alunos / km <sup>2</sup> ). ....	283
Figura 98 - Pessoas entre 18 e 59 anos - período diurno (consumo de água, m <sup>3</sup> / km <sup>2</sup> ). .....	284
Figura 99 - Pessoas acima de 59 anos - período diurno (pessoas / km <sup>2</sup> ). ....	284
Figura 100 - Tipos de estruturas urbanas - áreas residenciais (rendimento mensal por domicílio – R\$). ....	285
Figura 101 - Pessoas com até 5 anos (número de internações). ....	285
Figura 102 - Pessoas entre 6 e 17 anos (número de internações). ....	286
Figura 103 - Pessoas entre 18 e 59 anos (número de internações). ....	286
Figura 104 - Pessoas acima de 59 anos (número de internações). ....	287
Figura 105 - Distribuição espacial das queimadas (focos de queimadas / km <sup>2</sup> ). ....	287
Figura 106 - Construção civil e/ou solo exposto (proximidade às áreas de construção e solo, metros). ....	288
Figura 107 – Indústrias (proximidade às indústrias, metros). ....	288
Figura 108 – Aeroporto (proximidade à área do aeroporto, metros). ....	289
Figura 109 - Rodoviárias e terminais urbanos (número de linhas de ônibus / km <sup>2</sup> ). ....	289
Figura 110 - Veículos leves (média diária de veículos / km <sup>2</sup> ). ....	290
Figura 111 - Veículos pesados (média diária de veículos / km <sup>2</sup> ). ....	290
Figura 112 – Relevo (declividade do terreno). ....	291
Figura 113 – Clima – temperatura (°C). ....	291
Figura 114 - Uso do solo. ....	292

## LISTA DE QUADROS

Quadro 1 - Variáveis da pesquisa. ....	81
Quadro 2 - Ferramentas da pesquisa. ....	84
Quadro 3 - Valores de Fator de Emissão (FE) para cada categoria de veículos (g/km). 91	
Quadro 4 - Áreas do território brasileiro que possuem rede de monitoramento. ....	107
Quadro 5 - Alternativas do modelo AHP e descrição da técnica utilizada.....	152
Quadro 6 – Expressões utilizadas para o procedimento de álgebra de mapas. ....	157
Quadro 7 - Descrição das variáveis preditoras. ....	172
Quadro 8 - Risco significativo diferente de zero em cada <i>buffer</i> (95% IC não contém o valor zero).....	211
Quadro 9 - Matriz com os principais pontos de comparação dos resultados entre cada um dos sete objetivos específicos (separados entre os Capítulos 3 e 8).....	220
Quadro 10 – Síntese dos resultados de todas as análises realizadas, considerando o ineditismo/inação, limitações e sugestões de novos estudos. ....	222



## LISTA DE TABELAS

Tabela 1 - Custo da poluição no Brasil por tonelada e poluente lançado.....	62
Tabela 2 - Temperatura no DF no decorrer dos meses (°C).....	78
Tabela 3 - Média mensal da umidade relativa do ar no Distrito Federal (%).....	79
Tabela 4 - Estatística descritiva da frota de veículos automotores presente nas vias de circulação do DF considerada pelo presente estudo.....	94
Tabela 5 - Estatística descritiva da carga de poluentes emitida conforme o tipo de veículo (toneladas/ano).....	96
Tabela 6 - Estatística descritiva do total da carga de poluentes lançadas (toneladas/ano). .....	99
Tabela 7 - Resultado do teste Global Moran's I. ....	101
Tabela 8 - Resultado do teste Getis-Ord General G. ....	101
Tabela 9 - Comparação dos inventários de emissões veiculares entre DF, Rio de Janeiro, Campinas e inventário nacional.....	103
Tabela 10 - Matriz de correlação entre saúde e poluentes inventariados (valores de coeficiente de Pearson). ....	114
Tabela 11 - Resultado da análise de regressão espacial OLS.....	115
Tabela 12 - Estatística descritiva da distribuição de pacientes - dados sem a taxa de incidência.....	126
Tabela 13 - Estatística descritiva da distribuição de pacientes - dados com a taxa de incidência (número de pacientes / população).....	127
Tabela 14 - Pesos atribuídos para cada critério e subcritério do modelo. ....	159
Tabela 15 - Dados de saúde.....	170
Tabela 16 - Resumo de estatística descritiva dos dados de saúde. ....	181
Tabela 17 - Coeficientes significantes diferentes de zero em cada <i>buffer</i> (95% IC contém valor igual a zero). ....	183
Tabela 18 - Resumo de estatística descritiva dos dados de saúde - Análise entre saúde e UST.....	208

# SUMÁRIO

<b>INTRODUÇÃO .....</b>	<b>28</b>
<b>CAPÍTULO 1 - REVISÃO DA LITERATURA .....</b>	<b>35</b>
<b>1.1 POLUIÇÃO ATMOSFÉRICA .....</b>	<b>35</b>
1.1.1 TIPOS DE POLUENTES .....	36
1.1.1.1 Particulados.....	36
1.1.1.2 Gases .....	38
1.1.2 FONTES DE POLUIÇÃO.....	40
1.1.2.1 Fontes naturais .....	41
1.1.2.2 Fontes antrópicas.....	42
1.1.2.2.1 Meios de transporte.....	43
1.1.2.2.2 Indústrias e outras fontes.....	46
1.1.2.3 Fontes fixas e móveis .....	48
1.1.2.4 Fontes conforme o ambiente – outdoor e indoor.....	48
1.1.3 MONITORAMENTO DA POLUIÇÃO DO AR .....	50
1.1.3.1 Tipos de monitoramento .....	50
1.1.3.2 Redes de monitoramento.....	54
1.1.4 EFEITOS DA POLUIÇÃO ATMOSFÉRICA .....	55
1.1.4.1 Efeitos nos sistemas ambientais e nas estruturas urbanas .....	56
1.1.4.2 Efeitos na saúde humana .....	57
1.1.4.3 Efeitos na economia .....	61
<b>1.2 SAÚDE AMBIENTAL.....</b>	<b>63</b>
1.2.1 EPIDEMIOLOGIA AMBIENTAL .....	63
1.2.1.1 Co-variáveis em epidemiologia (variáveis controle).....	65
1.2.1.1.1 Faixa etária.....	65
1.2.1.1.2 Gênero .....	66
1.2.1.1.3 Renda .....	66
1.2.1.1.4 Densidade demográfica.....	66
1.2.1.1.5 Predisposição genética .....	67
1.2.1.2 Avaliação da exposição humana em epidemiologia.....	67
1.2.1.3 Epidemiologia espacial .....	68
1.2.1.3.1 SIG nas análises em epidemiologia espacial .....	70
<b>1.3 MODELAGEM AMBIENTAL.....</b>	<b>72</b>

1.3.1	MODELAGEM EM POLUIÇÃO DO AR E SAÚDE HUMANA .....	73
1.3.1.1	Modelos de Proximidade.....	73
1.3.1.2	Modelos de interpolação estatística ou dispersão.....	74
1.3.1.3	Modelos de inalação humana .....	74
1.3.1.4	Modelos land use regression .....	75
1.3.1.5	Modelos híbridos.....	76
 <b>CAPÍTULO 2 - ÁREA DE ESTUDO, VARIÁVEIS E FERRAMENTAS.....</b>		<b>77</b>
2.1	ÁREA DE ESTUDO .....	77
2.2	VARIÁVEIS DA PESQUISA.....	79
2.3	FERRAMENTAS.....	84
 <b>CAPÍTULO 3 - DISTRIBUIÇÃO ESPACIAL DO INVENTÁRIO DE EMISSÕES VEICULARES .....</b>		<b>85</b>
3.1	APRESENTAÇÃO.....	85
3.2	MÉTODO .....	86
3.2.1	CONSOLIDAÇÃO DOS VEÍCULOS AUTOMOTORES .....	86
3.2.1.1	Espacialização dos pontos de contagem.....	87
3.2.1.2	Operações algébricas dos pontos de contagem .....	88
3.2.1.3	Transferência da informação pontual para o segmento de via .....	89
3.2.2	INVENTÁRIO ESPACIAL.....	90
3.2.3	ANÁLISE DO COMPORTAMENTO ESPACIAL .....	92
3.3	RESULTADOS.....	94
3.4	DISCUSSÃO.....	102
 <b>CAPÍTULO 4 - AVALIAÇÃO ESPACIAL ENTRE POLUIÇÃO DO AR E SAÚDE EM ÁREAS COM LIMITAÇÃO DE DADOS .....</b>		<b>105</b>
4.1	APRESENTAÇÃO.....	105
4.2	MÉTODO .....	106
4.2.1	LIMITAÇÃO DE DADOS NA ÁREA DE ESTUDO .....	106
4.2.2	DADOS .....	107
4.2.3	ANÁLISES.....	109

<b>4.3</b>	<b>RESULTADOS.....</b>	<b>110</b>
4.3.1	BANCO DE DADOS EM SIG .....	110
4.3.2	AVALIAÇÃO DA RELAÇÃO ENTRE SAÚDE E POLUIÇÃO .....	114
<b>4.4</b>	<b>DISCUSSÃO.....</b>	<b>116</b>
<b>CAPÍTULO 5 - ANÁLISE ESPACIAL DA OCORRÊNCIA DE DOENÇAS CARDIORRESPIRATÓRIAS .....</b>		<b>119</b>
<b>5.1</b>	<b>APRESENTAÇÃO.....</b>	<b>119</b>
<b>5.2</b>	<b>MÉTODO .....</b>	<b>120</b>
5.2.1	DADOS .....	120
5.2.2	ANÁLISES.....	121
5.2.2.1	Global Moran's I.....	121
5.2.2.2	Getis-Ord General G .....	122
5.2.2.3	Análises de semivariogramas .....	123
5.2.2.4	Multi-distance spatial cluster – K function .....	124
<b>5.3</b>	<b>RESULTADOS.....</b>	<b>126</b>
5.3.1	ANÁLISE EXPLORATÓRIA.....	126
5.3.2	AUTOCORRELAÇÃO ESPACIAL – GLOBAL MORAN'S I .....	130
5.3.3	GRAU DE AGRUPAMENTO PARA VALORES ALTOS E BAIXOS – GETIS-ORD GENERAL G.....	131
5.3.4	DEPENDÊNCIA ESPACIAL – ANÁLISES DE SEMIVARIOGRAMAS.....	131
5.3.5	ANÁLISE DA VARIAÇÃO CONFORME A DISTÂNCIA – K FUNCTION .....	134
<b>5.4</b>	<b>DISCUSSÃO.....</b>	<b>135</b>
<b>CAPÍTULO 6 - ÁREAS PRIORITÁRIAS PARA MENSURAÇÃO DA EXPOSIÇÃO HUMANA À POLUIÇÃO ATMOSFÉRICA .....</b>		<b>138</b>
<b>6.1</b>	<b>APRESENTAÇÃO.....</b>	<b>138</b>
<b>6.2</b>	<b>MÉTODO .....</b>	<b>139</b>
6.2.1	DELIMITAÇÃO DA ÁREA DE ESTUDO .....	139
6.2.2	ANÁLISE MULTICRITÉRIO DO TIPO AHP.....	140
6.2.3	ETAPAS PARA IDENTIFICAÇÃO DAS ÁREAS PRIORITÁRIAS .....	144
6.2.3.1	Modelo conceitual, dados e bases geográficas .....	144
6.2.3.1.1	Exposição humana .....	145
6.2.3.1.2	Fontes de poluição .....	147

6.2.3.1.3	Característica do ambiente .....	150
6.2.3.2	Espacialização dos dados e definição dos pesos pelo AHP.....	151
6.2.3.3	Modelagem em SIG e mapa de áreas prioritárias.....	156
<b>6.3</b>	<b>RESULTADOS.....</b>	<b>159</b>
<b>6.4</b>	<b>DISCUSSÃO.....</b>	<b>165</b>

**CAPÍTULO 7 - DECAIMENTO DO RISCO DE DOENÇAS  
CARDIORRESPIRATÓRIAS RELACIONADO COM AS CARACTERÍSTICAS  
AMBIENTAIS DO BAIRRO ..... 168**

<b>7.1</b>	<b>APRESENTAÇÃO.....</b>	<b>168</b>
<b>7.2</b>	<b>MÉTODO .....</b>	<b>169</b>
7.2.1	DESIGN DO ESTUDO .....	169
7.2.2	PROCESSAMENTO DOS DADOS DE SAÚDE.....	170
7.2.3	VARIÁVEIS PREDITORAS .....	171
7.2.4	TÉCNICAS EM SIG PARA MENSURAMENTO DAS VARIÁVEIS PREDITORAS .	172
7.2.5	ANÁLISE ESTATÍSTICA.....	174
7.2.5.1	Quantile regression .....	174
7.2.5.2	Interquantile range .....	177
7.2.5.3	Risco .....	178
7.2.6	MODELAGEM EM SIG PARA CONSTRUÇÃO DOS MAPAS DE RISCO.....	179
<b>7.3</b>	<b>RESULTADOS.....</b>	<b>180</b>
7.3.1	ANÁLISE DESCRITIVA .....	180
7.3.2	DECAIMENTO DO RISCO DE DOENÇAS CARDIORRESPIRATÓRIAS.....	181
7.3.3	MAPAS DE RISCO .....	191
<b>7.4</b>	<b>DISCUSSÃO.....</b>	<b>194</b>

**CAPÍTULO 8 - UMA NOVA ABORDAGEM DO USO DO SOLO PARA  
AVALIAÇÃO DA SAÚDE HUMANA: A RELAÇÃO ENTRE TIPOS DE  
ESTRUTURAS URBANAS E RISCO DE DOENÇAS  
CARDIORRESPIRATÓRIAS ..... 198**

<b>8.1</b>	<b>APRESENTAÇÃO.....</b>	<b>198</b>
<b>8.2</b>	<b>MÉTODO .....</b>	<b>199</b>
8.2.1	DESIGN DO ESTUDO .....	199
8.2.2	PROCESSAMENTO DOS DADOS DE SAÚDE.....	200

8.2.3	CLASSIFICAÇÃO DAS UST .....	200
8.2.4	TÉCNICAS EM SIG PARA CONSOLIDAÇÃO DOS DADOS .....	206
8.2.5	ANÁLISE ESTATÍSTICA .....	206
8.2.6	ANÁLISE DE SENSIBILIDADE .....	207
<b>8.3</b>	<b>RESULTADOS.....</b>	<b>208</b>
8.3.1	ANÁLISE DESCRITIVA .....	208
8.3.2	UST E RISCO DE DOENÇAS CARDIORRESPIRATÓRIAS .....	211
<b>8.4</b>	<b>DISCUSSÃO.....</b>	<b>214</b>
<b>CONCLUSÃO.....</b>		<b>218</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>		<b>224</b>
<b>APÊNDICES.....</b>		<b>256</b>
<b>APÊNDICE A – PUBLICAÇÃO EM EVENTOS .....</b>		<b>256</b>
A.1.	ENVIRONMENTAL HEALTH, BOSTON, USA, 2013 .....	257
A.1.1.	Geographic Information System (GIS) and environmental health .....	257
A.2.	URBAN ENVIRONMENTAL POLLUTION, TORONTO, CANADÁ, 2014 .....	258
A.2.1.	Multi-criteria model in GIS for determination of sampling points of air pollution .....	258
A.2.2.	Spatial assessment of occurrence of diseases related to air pollution in Federal District, Brazil.....	259
<b>APÊNDICE B – PUBLICAÇÃO EM PERIÓDICOS.....</b>		<b>260</b>
B.1.	ATMOSPHERIC ENVIRONMENT.....	261
B.1.1.	Spatial distribution of vehicle emission inventories in the Federal District, Brazil.....	261
B.2.	REVISTA BRASILEIRA DE GEOGRAFIA MÉDICA (HYGEIA).....	262
B.2.1.	Avaliação espacial entre poluição do ar e saúde em áreas com limitação de dados .....	262
B.3.	JOURNAL HEALTH.....	263
B.3.1.	Analyzing spatial patterns of cardiorespiratory diseases in the Federal District, Brazil..	263
B.4.	JOURNAL OF THE AIR & WASTE MANAGEMENT ASSOCIATION .....	264
B.4.1.	A spatial multicriteria model for determining air pollution at sample locations .....	264
B.5.	JOURNAL ENVIRONMENT INTERNATIONAL .....	266
B.5.1.	A novel land use approach for assessment of human health: the relationship between urban structure types and cardiorespiratory disease risk .....	266
<b>APÊNDICE C – REPRESENTAÇÃO ESPACIAL DAS VARIÁVEIS UTILIZADAS NESTA PESQUISA .....</b>		<b>267</b>

C.1. INTERNAÇÕES HOSPITALARES.....	268
C.2. ENDEREÇAMENTO .....	269
C.3. MALHA VIÁRIA .....	270
C.4. VEÍCULOS .....	271
C.5. POPULAÇÃO.....	272
C.6. RENDA .....	272
C.7. INSTITUIÇÕES DE ENSINO .....	273
C.8. HIDRÔMETROS .....	274
C.9. QUEIMADAS.....	274
C.10. USO DO SOLO.....	275
C.11. RODOVIÁRIAS E TERMINAIS DE ÔNIBUS .....	276
C.12. AEROPORTO.....	276
C.13. ALTIMETRIA .....	277
C.14. UMIDADE .....	277
C.15. TEMPERATURA .....	278
C.16. IMAGEM AÉREA.....	278
C.17. TIPOS DE ESTRUTURAS URBANAS.....	279
<b>APÊNDICE D –RESULTADO DA ESPACIALIZAÇÃO DOS DADOS PARA A ANÁLISE DE</b>	
<b>ÁREAS PRIORITÁRIAS PARA MENSURAÇÃO DA EXPOSIÇÃO HUMANA À POLUIÇÃO</b>	
<b>ATMOSFÉRICA .....</b>	<b>280</b>
D.1. CRITÉRIO EXPOSIÇÃO HUMANA .....	281
D.1.1. Presença humana .....	281
D.1.2. Tipos de estruturas das edificações .....	285
D.1.3. Efeitos no ser humano .....	285
D.2. CRITÉRIO FONTES DE POLUIÇÃO.....	287
D.2.1. Fixas .....	287
D.2.2. Móveis.....	290
D.3. CRITÉRIO CARACTERÍSTICA DO AMBIENTE.....	291
<b>APÊNDICE E – SCRIPTS UTILIZADOS .....</b>	<b>293</b>
E.1. MODELO QUANTILE REGRESSION (UMA VARIÁVEL PREDITORA).....	294
E.2. MODELO QUANTILE REGRESSION (MAIS DE UMA VARIÁVEL PREDITORA).....	300
<b>APÊNDICE F – EXEMPLOS DOS TIPOS DE ESTRUTURAS URBANAS (IMAGEM DE</b>	
<b>SATÉLITE E DETALHE DO LOCAL).....</b>	<b>305</b>

## Introdução

---

As cidades são regiões que concentram fontes significativas de poluição, nas quais causam impactos aos ecossistemas naturais e até mesmo ao próprio ambiente urbano. Os automóveis, as indústrias, as usinas exemplificam essas fontes, que, sobretudo, são motivadas pelo consumo humano. Foi a partir de meados do século XX que essa relação de causa e efeito entre as atividades humanas e o meio ambiente começou a ser um tema frequente nas discussões científicas e governamentais (FENGER, 2009; VESILIND; MORGAN, 2011).

Dentre os tipos de fontes, as relacionadas com a poluição atmosférica têm se destacado em meio às discussões (TURNER, 1970; BRINGFELT et al., 1974; NIEUWSTADT, 1980). O destaque do tema aumentou em decorrência dos estudos que identificaram impactos significativos causados pela poluição do ar aos sistemas ambientais (SRIVASTAVA; KUMAR, 2012; PENG et al., 2012), aos sistemas econômicos (VLACHOKOSTAS et al., 2010; POZZER et al., 2012), e principalmente, à saúde humana (DOCKERY et al., 1993; SOLOMON et al., 2011; TOURI et al., 2013; SLEZAKOVA et al., 2013; BIND et al., 2015; POWER et al., 2015).

Quanto à saúde humana, o tópico se sobressai devido ao elevado risco de ocorrência de efeitos adversos à saúde quando as pessoas estão em contato com o ar poluído (THEPANONDH; TORUKSA, 2011). Nesse caso, a ocorrência de doenças no ser humano é considerada uma *proxy* indicadora da qualidade do ar. As doenças do sistema cardiovascular (RUNDELL, 2012; VALDÉS et al., 2012; LIN, H. et al., 2013) e do sistema respiratório (TRASANDE; THURSTON, 2005; ARBEX et al., 2012) predominam como uma das principais *proxy*.

A questão da saúde humana é ainda mais enfatizada por saber que um terço da população mundial vive em ambientes insalubres em razão da concentração elevada de poluentes atmosféricos (CHRISTOPHERSON, 2012). A Organização Mundial de Saúde (OMS) mostrou que no ano de 2010 a poluição do ar foi a causa de 223 mil mortes por câncer de pulmão em todo o planeta (OMS, 2013). Ainda no ano de 2010, mas sem considerar as causas específicas por câncer de pulmão, aproximadamente três milhões de pessoas em todo o planeta morreram devido à poluição atmosférica (LIM et al., 2012). Dois anos depois, 2012, o número total de pessoas que morreram por causa da poluição do ar aumentou para sete milhões (WHO, 2014a). Considerando especificamente o material particulado de até 2,5 µm (um tipo de poluente



atmosférico), Lozano et al. (2012) estimam que esse poluente é responsável por dois milhões de mortes prematuras por ano, classificado como a 13ª principal causa de mortalidade em todo o planeta.

Ainda quanto aos efeitos da poluição do ar à saúde humana, Fajersztajn et al. (2013) mostraram que 8% das mortes por câncer de pulmão em todo o mundo são atribuídas à exposição por um único tipo de poluente, o material particulado. Christopherson (2012) apresenta que aproximadamente 2% das mortes anuais nos Estados Unidos (EUA), Canadá, Europa, México, China e Índia são decorrentes da poluição atmosférica. Solomon et al. (2011) relatam que a redução de  $10 \mu\text{g}/\text{m}^3$  do material particulado com até  $2,5 \mu\text{m}$  aumentaria em 1,5 a expectativa de vida das pessoas. Cita-se ainda o estudo de Silva et al. (2012), no qual foi identificado que se o metrô de São Paulo parasse um ano, as mortes causadas por problemas respiratórios e circulatórios cresceriam 14% no período. Esse crescimento do número de mortes estaria ligado ao aumento de 75% da concentração de poluentes na cidade de São Paulo, decorrente do maior número de veículos nas ruas. Além disso, Silva et al. (2012) estimam que o metrô de São Paulo parado durante um ano geraria um custo para o governo estadual de 18 bilhões de dólares.

Diante do cenário apresentado, Phalen (2012a) mostra que a mensuração da exposição humana às fontes de poluição do ar é uma ferramenta de apoio para a criação de políticas públicas em saúde e meio ambiente que visam o controle e gestão das fontes de poluição atmosférica. Como principal benefício desse controle e gestão, cita-se a melhoria da qualidade de vida da população.

Atualmente, os principais métodos de mensuração da exposição humana são as estações de monitoramento, os equipamentos portáteis - conhecidos como *personal exposure*, o biomonitoramento, o sensoriamento remoto - satélites, e os modelos com variáveis relacionadas ao uso e ocupação do solo - conhecidos como *land use models* (SOLOMON et al., 2011; PHALEN, 2012b).

Dentre os métodos de mensuração, o desafio consiste, sobretudo, no equilíbrio entre a finalidade da mensuração e o custo econômico envolvido. Por exemplo, as estações de monitoramento possuem custo elevado de implantação e operação, e possibilitam somente a mensuração da exposição de um grupo populacional. Já os equipamentos portáteis possuem um custo reduzido, possibilitam a mensuração da exposição do indivíduo, mas necessitam das estações de monitoramento para calibração (ADEME, 2002; KANAROGLOU et al., 2005; MOODLEY et al., 2011; ZHENG et al., 2011).

Diante desse desafio operacional e econômico, muitos centros urbanos ainda carecem de um sistema para mensuração da exposição humana à poluição atmosférica. Observando somente o uso do método das estações de monitoramento, os países desenvolvidos estão à frente dos países em desenvolvimento. Por exemplo, há aproximadamente um total de 4.100 estações de monitoramento do material particulado de até 2,5  $\mu\text{m}$  considerando os países desenvolvidos da Europa e da América do Norte. Por outro lado, os países em desenvolvimento de todos os continentes totalizam aproximadamente 101 estações de monitoramento do material particulado de até 2,5  $\mu\text{m}$  (FRIEDL et al., 2010). Outro exemplo mostra que no Brasil há um total de 252 estações de monitoramento (considerando todos os poluentes), enquanto que nos EUA há aproximadamente 5.000, e no Japão e Alemanha 1.800 (EEA, 2012; UBA, 2013; ALVES et al., 2014).

Avaliando especificamente a situação brasileira, Alves et al. (2014) mostram que do total de 5.570 municípios brasileiros, apenas 1,7% possuem monitoramento da qualidade do ar. São Paulo, o estado mais rico, possui a maior rede, composta por 83 estações. Além de São Paulo, somente mais oito estados brasileiros possuem rede de monitoramento: Espírito Santo, Minas Gerais, Paraná, Rio de Janeiro, Bahia, Rio Grande do Sul, Sergipe e Distrito Federal (DF).

Dessa forma, os métodos que possuem um custo inferior, como o sensoriamento remoto e os modelos relacionados ao uso e ocupação do solo, têm sido utilizados com mais frequência. Além de suprir a necessidades de áreas urbanas que não possuem um sistema de monitoramento da exposição humana, esses métodos podem contribuir paralelamente com as áreas urbanas que já são monitoradas (DONKELAAR, VAN et al., 2010; KLOOG et al., 2012; MUKERJEE et al., 2012; WANG et al., 2013). Essa contribuição paralela já está sendo utilizada como apoio nas tomadas de decisões feitas pelas agências ambientais de referência internacional, como a agência americana EPA – *Environmental Protection Agency* (EPA, 2013a) e a europeia EEA – *European Environment Agency* (EEA, 2012).

Porém, os métodos de avaliação da exposição humana mais baratos ainda estão em processo inicial de pesquisa, gerando assim uma necessidade de aperfeiçoamento (HU, 2009; PADRÓ-MARTÍNEZ et al., 2012). As primeiras pesquisas com esses métodos surgiram somente a partir do século XXI. Por exemplo, especificamente quanto aos modelos de uso e ocupação do solo, ainda pouco se sabe sobre a relação entre o uso do solo, as fontes de poluição do ar e a saúde humana. Além disso, ainda pouco se conhece sobre os fatores que influenciam a variabilidade espacial da exposição e sobre o processo de integração dos dados de saúde na modelagem.

Portanto, a presente pesquisa testou a hipótese de que a exposição da população do DF às fontes de emissões de poluentes do ar pode ser estimada por meio da classificação e mensuração do uso e ocupação do solo.

A justificativa de escolha do DF como área de estudo se baseia em cinco pontos: 1) situação atual da medição da exposição humana; 2) uso e ocupação do solo urbano – expansão urbana; 3) crescimento demográfico; 4) crescimento das fontes veiculares de poluição; e, 5) elevado número de ocorrência de doenças cardiorrespiratórias.

A mensuração da exposição humana no DF é feita somente por estações de monitoramento, que ainda estão no processo inicial de consolidação, o que a torna precária e de pouca representatividade. O DF tem sete estações que monitoram principalmente as partículas totais em suspensão – menor que 100  $\mu\text{m}$  (IBRAM, 2013), um poluente que deixou de ser considerado como relevante pelas agências ambientais de referência internacional, como a EPA (EPA, 2013a). Além disso, as estações são mal distribuídas espacialmente, pois grandes centros de atividades no DF ainda não são monitorados.

Quanto ao uso e ocupação do solo, o DF apresentou um crescimento da área urbana em torno de 30% nos últimos 15 anos. Essa expansão urbana esteve atrelada a um crescimento demográfico de 2,82% ao ano (SEDUMA, 2009). Atualmente, o DF possui uma população de aproximadamente 2,8 milhões de pessoas. Considerando os municípios mais populosos do Brasil, o DF está na quarta posição. São Paulo, Rio de Janeiro e Salvador ocupam as três primeiras posições, respectivamente (IBGE, 2013).

Em relação à frota veicular, o DF tem aproximadamente 1,6 milhões de veículos, uma taxa anual de crescimento de 4,5%. A relação é de praticamente 0,6 veículos por habitante. Entre os estados brasileiros, o DF está na quinta posição quanto o maior número de veículos por pessoa. Santa Catarina, Paraná, São Paulo e Rio Grande do Sul ocupam as quatro primeiras posições, respectivamente (DENATRAN, 2015).

E por fim, assumindo que as doenças do sistema cardiorrespiratório são *proxies* indicadoras da qualidade do ar (conforme já mencionado anteriormente), no DF 27% dos pacientes são internados devido às doenças cardiorrespiratórias. Um total de 400 mil pessoas foram internadas por doenças cardiorrespiratórias nos últimos cinco anos e 15 mil vieram a óbito. Considerando as internações por doenças cardiorrespiratórias dos últimos cinco anos, o DF possui uma relação (total de casos / população) de 0,15; enquanto que o estado de São Paulo possui uma relação de 0,14. Quanto aos números de óbitos, ambos os estados possuem uma

relação de 0,01 (DATASUS, 2015). Destaca-se que um grande número de estudos já mostraram que no estado de São Paulo, sobretudo na região metropolitana, há associações significativas entre poluição do ar e o aumento de doenças cardiorrespiratórias (CONCEIÇÃO et al., 2002; RIBEIRO; CARDOSO, 2003; PAULA SANTOS et al., 2005; TOLEDO; NARDOCCI, 2011; MOURA et al., 2012).

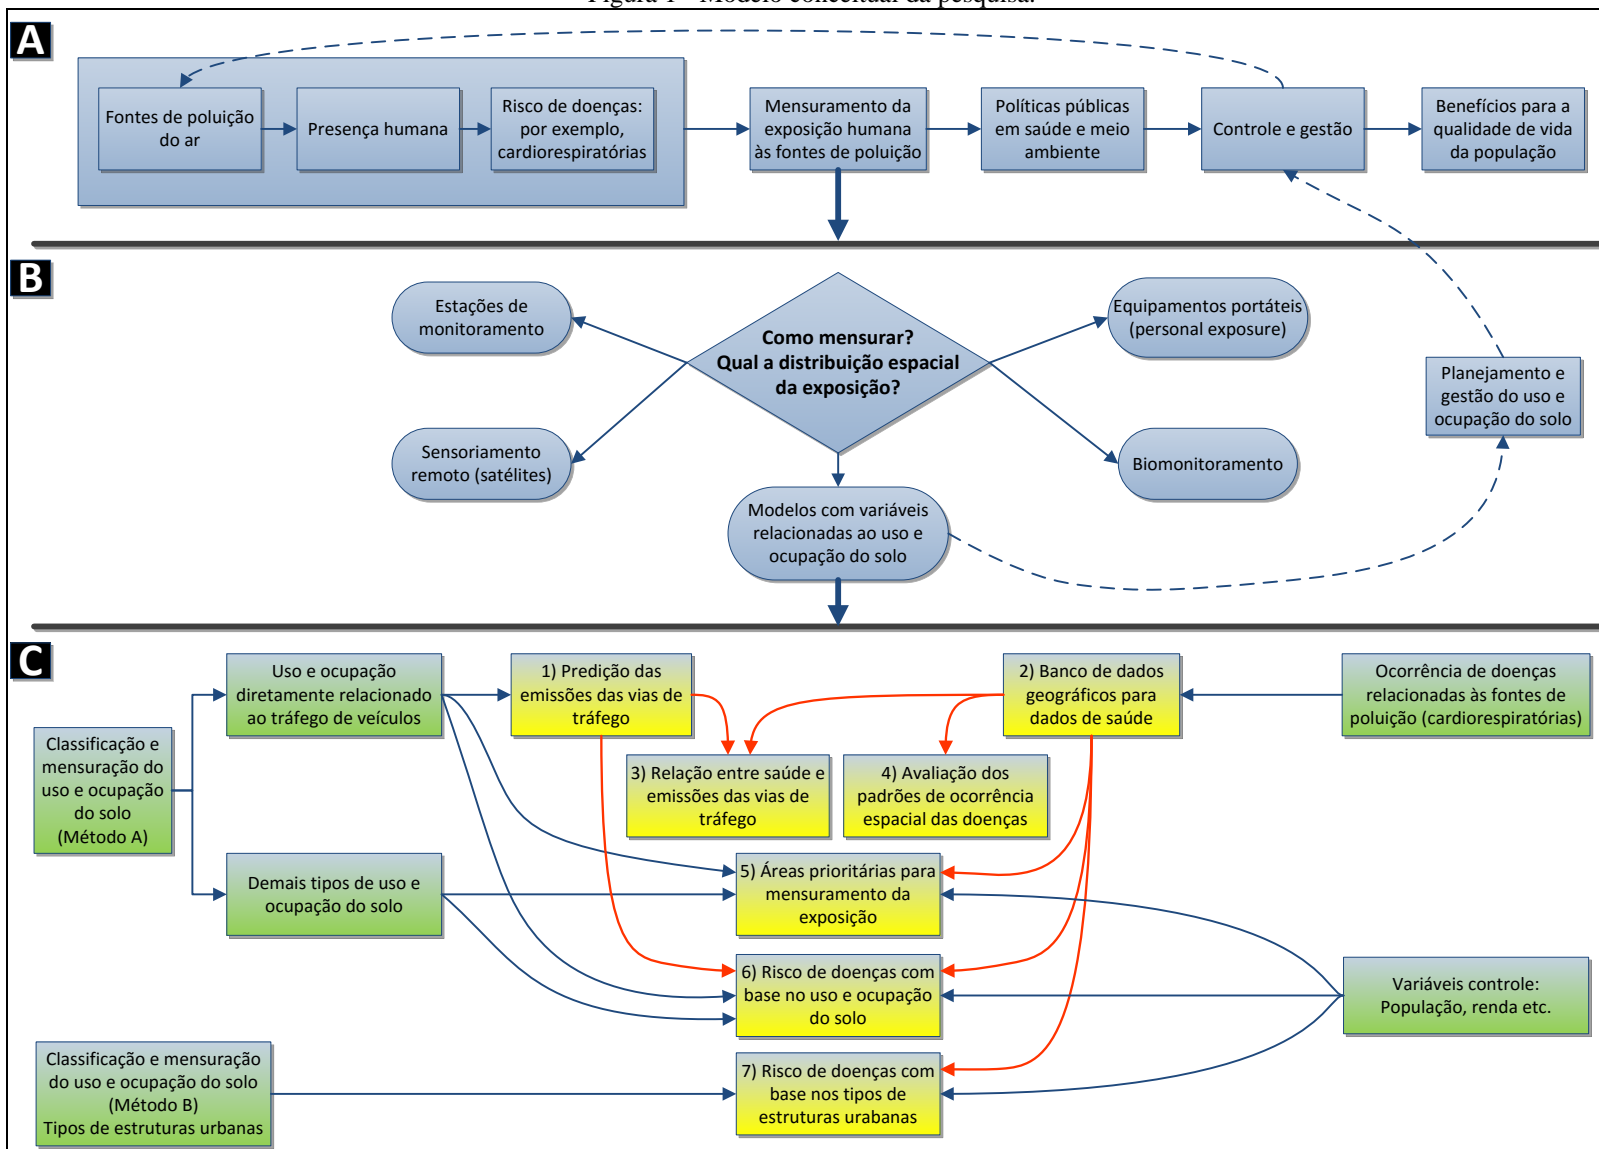
Portanto, diante dos desafios na região do DF e da necessidade de aperfeiçoamento dos métodos em uso do solo para mensuração da exposição humana, a presente pesquisa teve o objetivo geral de avaliar a exposição espacial da população do DF às fontes de poluição do ar por meio de modelos que consideram a classificação e mensuração do uso e ocupação do solo como variável preditora.

Esta pesquisa teve sete objetivos específicos: 1) estimar as emissões das vias de tráfego; 2) construir um banco de dados geográficos para os dados de saúde; 3) avaliar a relação entre saúde e emissões decorrentes das vias de tráfego; 4) avaliar os padrões de distribuição espacial da ocorrência de doenças cardiorrespiratórias; 5) identificar as áreas prioritárias para mensuração da exposição humana às fontes de poluição atmosférica; 6) estimar o risco da ocorrência de doenças cardiorrespiratórias com base no uso e ocupação do solo; e 7) avaliar a relação entre os tipos de estruturas urbanas e o risco de doenças cardiorrespiratórias.

A Figura 1 apresenta o modelo conceitual da pesquisa e os respectivos objetivos específicos traçados. Os dados primários e secundários para a entrada de cada objetivo específico serão detalhados entre os capítulos 2 e 8. No entanto, para um prévio entendimento dos dados de entrada apresentados na Figura 1, destaca-se que o uso e ocupação do solo foi considerado por duas abordagens (método A e método B).

O método “A” considerou o uso e ocupação do solo diretamente relacionado ao tráfego de veículos (localização das vias, emissões de poluentes decorrentes de cada via, localização das rodoviárias etc.) e os demais tipos de uso e ocupação (áreas residenciais, comerciais, industriais etc.). Já o método “B” considerou a classificação e mensuração do uso e ocupação do solo com base nos conceitos de tipos de estruturas urbanas (esse método será detalhado no Capítulo 8). Por fim, destaca-se que a ocorrência de doenças cardiorrespiratórias foi considerada como *proxy* indicadora da qualidade do ar (a base dessa consideração será detalhada no Capítulo 1, apesar de que esta Introdução já apresentou algumas referências) e que os modelos foram controlados com co-variáveis do tipo renda, população etc. (as definições de co-variáveis serão apresentadas no Capítulo 1).

Figura 1 - Modelo conceitual da pesquisa.



Fonte: Produção do próprio autor.

Nota: ideia conceitual (A e B); fluxo geral do objetivo da tese (C); objetivos específicos da tese (retângulo amarelo); dados primários de entrada (retângulo verde); dados secundários de entrada (seta vermelha).

O trabalho está estruturado da seguinte forma. O Capítulo 1 apresenta o estado da arte que a pesquisa foi baseada, especificamente, nos conceitos de poluição atmosférica, saúde ambiental e modelagem. O Capítulo 2 apresenta a descrição detalhada da área de estudo - DF, das variáveis utilizadas na pesquisa e das ferramentas operacionais (programas computacionais). E os Capítulos 3 a 8 apresentam o desenvolvimento e resultados de cada um dos objetivos específicos.

Até o fechamento desta tese, os resultados apresentados nos Capítulos 3 a 8 foram publicados, estão em fase de publicação ou estão em fase de finalização para submissão. Três trabalhos foram apresentados em eventos (resultados dos Capítulos 5 e 6), quatro artigos foram publicados em revistas (resultados dos Capítulos 3, 5, 6 e 8), um artigo está em avaliação pelos revisores (resultados do Capítulo 4) e um artigo está em fase de finalização para submissão (resultados do Capítulo 7). O Apêndice A apresenta os trabalhos apresentados em eventos. O Apêndice B apresenta as publicações já realizadas e o comprovante de submissão do artigo que ainda está em avaliação.

# Capítulo 1 - Revisão da literatura

---

## 1.1 POLUIÇÃO ATMOSFÉRICA

A poluição atmosférica é definida como elementos ou substâncias presentes no ar que possuem concentrações acima dos limites de segurança (PHALEN, 2012b). O Conselho Nacional do Meio Ambiente (Conama) considera como limites de segurança a quantidade de poluente que não torna o ar impróprio, nocivo ou ofensivo a seres vivos e a materiais (CONAMA, 1990).

Atualmente, em centros urbanos como São Paulo, Brasília, Santiago, Chicago, Pequim, Londres, Lisboa, a concentração de alguns poluentes atmosféricos estão acima dos limites (RIBEIRO; CARDOSO, 2003; METCALFE; DERWENT, 2005; SOKHI, 2011; ALMEIDA-SILVA et al., 2011; RÉQUIA JÚNIOR; ABREU, 2011; SANTANA et al., 2012; GALLARDO et al., 2012; WANG, QINGSONG et al., 2012). Esse cenário atual de ambientes urbanos poluídos é decorrente de um processo histórico insustentável de urbanização, industrialização e desenvolvimento dos meios de transporte (SOKHI, 2011; GU et al., 2012; PHALEN, 2012b).

Black (2010) mostra que no período do Império Romano já havia problemas relacionados à concentração excessiva de poluentes atmosféricos. O fluxo intenso de cavalos circulando pela cidade ocasionava a suspensão de partículas fina do solo. Com isso, tiveram que ser criadas medidas de restrição do uso de cavalos como meio de transporte em certos horários no centro de Roma. Na época as cidades já eram organizadas de forma que o maior fluxo dos meios de transporte localizava-se no centro.

No século XX, alguns fatos ligados à poluição atmosférica marcaram o processo do desenvolvimento industrial. A elevada concentração de poluentes atmosféricos associada às condições meteorológicas, incluindo nevoeiro intenso e inversões de baixa altitude (inversão térmica), impactou a população local de algumas cidades. Podem-se citar os episódios ocorridos no Vale do Rio Meuse, na Bélgica, em 1930; o episódio da Pensilvânia, em 1948; o episódio de Londres, em 1952 (METCALFE; DERWENT, 2005; SOKHI, 2011; PHALEN, 2012b). Destaca-se que o fenômeno da inversão térmica não é impactante. O problema consiste na presença excessiva de poluentes do ar que ficaram abaixo do nevoeiro, nos quais estão impossibilitados de circular (SPEDDING, 2002; LENZI; FAVERO, 2011).

A presença dos poluentes na atmosfera que marcou períodos históricos e ainda continua sendo um desafio em centros urbanos como Brasília é decorrente de um complexo sistema de interações descrito pelas ciências atmosféricas (BRAGA et al., 2005; DOMÉNECH, 2008; LENZI; FAVERO, 2011; MAHOWALD, 2011; DERISIO, 2012; KOOP, 2013).

Assunção (2004) e Sokhi (2011) mostram que a ciência atmosférica define a poluição do ar a partir da classificação do tipo de poluente (item 1.1.1) e das fontes de poluição (item 1.1.2). O monitoramento da qualidade do ar (item 1.1.3) é o mecanismo utilizado para conhecer o tipo e a quantidade de poluente disperso em uma determinada área. Um dos principais objetivos do estudo da poluição atmosférica é poder ter orientações para controlar os efeitos causados pelo ar poluído - item 1.1.4.

### 1.1.1 TIPOS DE POLUENTES

#### 1.1.1.1 Particulados

Os particulados, como o próprio nome diz, são partículas dispersas na atmosfera que apresentam dimensões que variam de 0,0001  $\mu\text{m}$  a 500  $\mu\text{m}$ . Os nevoeiros, a fumaça, as poeiras, as bactérias, os polens são os principais exemplos de particulados. Essas partículas se apresentam na atmosfera sobre a forma de 3 tipos de dispersão: solução verdadeira, dispersão coloidal e dispersão heterogênea. No entanto, caso a fase dispersante seja uma fase gasosa, passa-se a ser classificado como aerossóis (LENZI; FAVERO, 2011; MAHOWALD, 2011; ANDREAE, 2013; PARK et al., 2013).

Para efeito de estudos científicos, os materiais particulados são classificados em: Partículas Totais em Suspensão (PTS), aqueles com até 100  $\mu\text{m}$ ; Materiais Particulados com até 10  $\mu\text{m}$  ( $\text{MP}_{10}$ ), também conhecidos como inaláveis; e os Materiais Particulados com até 2,5  $\mu\text{m}$  ( $\text{MP}_{2,5}$ ), no qual tem o maior potencial de impacto aos seres humanos (ENVIRONMENTAL PROTECTION AGENCY, 2004). Além dessas classificações, estudos recentes já estão sendo realizados com observação às partículas chamadas de ultrafinas, aquelas menores que 1  $\mu\text{m}$  (KWASNY et al., 2010; SABALIAUSKAS et al., 2012; MANIGRASSO; AVINO, 2012; ZHANG et al., 2013; QUIROS et al., 2013).

O diâmetro do material particulado é a sua propriedade mais importante. Por exemplo, é pelo tamanho das partículas que se pode estimar o impacto desse poluente, além do tempo de permanência na atmosfera. Uma partícula que tem a metade do tamanho de outra cai quatro



vezes mais lenta. As menores partículas ficam presentes no ar por mais tempo, pois se assentam tão lentamente que pode-se dizer que estão presentes no ar quase que indefinidamente (BAIRD; CANN, 2011).

A composição química do material particulado é outra propriedade de relevante interesse nos estudos em qualidade do ar. Um dos principais objetivos dos estudos da composição química dos particulados é a estimativa das principais fontes de emissões em uma determinada área. Por exemplo, pesquisas mostram que o zinco (Zn), chumbo (Pb), cobre (Cu) são elementos traços que indicam as fontes veiculares; potássio (K) são indicadores da queima de madeira; arsênio (As) e selênio (Se) são indicadores da combustão do carvão (LADEN et al., 2000; KHILLARE; SARKAR, 2012; VARGAS et al., 2012)

O comportamento, as fontes, os efeitos dos tipos de materiais particulados tem sido investigado por uma diversidade de pesquisadores de vários países, como no Brasil (IGNOTTI et al., 2010), na China (CHOI; KIM, 2012), na Itália (MASIOL et al., 2012), no Canadá (ANASTASOPOULOS et al., 2012), na Colômbia (VARGAS et al., 2012), na Coreia do Sul (PARK et al., 2012), nos Estados Unidos (CHINA; JAMES, 2012), na Índia (DESHMUKH et al., 2012).

Dentre as pesquisas relacionadas às partículas atmosféricas, destaca-se o grande número das que tiveram o objetivo de estudar o processo de dispersão do poluente. Estudos têm mostrado que o vento é um fator ambiental importante para a dispersão dos particulados (STEINKE, 2012; CHINA; JAMES, 2012; RODRIGUEZ et al., 2013). Por exemplo, na Holanda, Hendriks et al. (2013) identificaram que 2/3 da concentração de  $MP_{10}$  é de origem de outros países. As condições climatológicas, sobretudo o vento, é um dos fatores principais para gerar a dispersão desse poluente entre os países vizinhos do território holandês. Outro exemplo é a dispersão da poeira do continente africano que chega atingir a costa leste dos Estados Unidos (CHRISTOPHERSON, 2012).

Além dos ventos, a concentração de partículas atmosféricas também sofre alterações conforme as estações do ano (DESHMUKH et al., 2012; KIMBROUGH et al., 2012). No hemisfério Norte, o verão é o momento em que há os maiores picos de concentração de particulados (WILSON et al., 2004; RUNDELL, 2012). O estudo de Bahadori et al. (2000) mostrou que em quatro cidades dos Estados Unidos, Philadelphia, Washington, Nashville e Boston, os picos de  $MP_{10}$  e  $MP_{2,5}$  aconteceram na estação do verão. Já as menores concentrações ocorreram no inverno. No hemisfério Sul as maiores concentrações dos poluentes são normalmente no período de inverno, pois muitas das vezes o inverno está associado com o período de baixa

umidade. Dessa forma, as concentrações de poluentes são maiores devido ao fenômeno da inversão térmica (VESILIND; MORGAN, 2011). A Companhia de Tecnologia e Saneamento Ambiental (Cetesb) do estado de São Paulo mostra que no inverno a concentração de poluente aumenta em até 80% em algumas áreas (CETESB, 2013).

A influência dos fatores naturais não é exclusiva ao comportamento dos particulados (YU et al., 2013). Os tipos de poluentes atmosféricos classificados como gases também sofrem influência das variáveis climatológicas (FIORE et al., 2012). Assim, de modo sistêmico, a poluição atmosférica pode ser vista pela interação entre as fontes de poluição, os componentes climatológicos, as características do relevo, os ciclos biogeoquímicos (CHRISTOFOLETTI, 1999; MONTEIRO; MENDONÇA, 2011; CHRISTOPHERSON, 2012).

#### **1.1.1.2 Gases**

Os poluentes caracterizados como gases são aqueles que possuem uma força de repulsão entre os elementos químicos que o constituem. As pontes de hidrogênio e a maior ou menor polarizabilidade entre os elementos definem a presença dessa força. A força de repulsão é uma resultante do estado cinético e do tipo de ligação entre as unidades que compõem o elemento em análise (LENZI; FAVERO, 2011).

Partindo-se do pressuposto da concentração na atmosfera e do impacto causado, os gases mais comuns que têm sido considerados nos estudos sobre poluição atmosférica são o monóxido de carbono (CO); o dióxido de carbono (CO<sub>2</sub>); os óxidos de enxofre (SO<sub>x</sub>), sobretudo o dióxido de enxofre (SO<sub>2</sub>); os óxidos de nitrogênio (NO<sub>x</sub>), sobretudo o dióxido de nitrogênio (NO<sub>2</sub>); e o ozônio (O<sub>3</sub>). Esses são os gases mais pesquisados nos estudos de caráter científico (WALLACE et al., 2009, 2012; LISKA; BEIJO, 2012; PONGRATZ; CALDEIRA, 2012; LUVSAN et al., 2012).

Destaca-se que nem todo gás presente na atmosfera é considerado um poluente. Por exemplo, para manutenção da vida no Planeta Terra a atmosfera constitui-se de 78% de nitrogênio (N<sub>2</sub>), no qual não é impactante ao meio ambiente (SPEDDING, 2002; GOMES, 2010). O CO<sub>2</sub> é um outro exemplo, pois não é considerado diretamente um poluente para os seres vivos. Os efeitos do CO<sub>2</sub> aos seres vivos são indiretos (GASPARRINI; GUO; HASHIZUME; KINNEY; et al., 2015; GASPARRINI; GUO; HASHIZUME; LAVIGNE; et al., 2015; NORDIO et al., 2015).

Os fatores determinantes para um gás ser caracterizado como um poluente atmosférico é a sua composição química, a sua concentração e a sua localização nas camadas atmosféricas. Assim, concentrações elevadas de  $\text{NO}_2$  ( $\text{NO} + \text{O}_2 \rightarrow \text{NO}_2$ ) caracterizam-se como um poluente. Já o  $\text{O}_3$  é considerado poluente quando está presente na troposfera (até 10 km de altura). O gás  $\text{O}_3$  presente na estratosfera (11 – 50 km) é considerado essencial para a proteção da radiação ultravioleta (BAIRD; CANN, 2011; LENZI; FAVERO, 2011).

As reações químicas dos gases presentes no ar são consideradas um importante aspecto nas ciências atmosféricas. As reações podem ser do tipo termal ou fotoquímica (METCALFE; DERWENT, 2005). Essas reações compõem a dinâmica dos ciclos biogeoquímicos de alguns gases em análise. Por exemplo, o CO e o  $\text{CO}_2$  estão relacionados ao ciclo do carbono, o  $\text{SO}_x$  ao ciclo do enxofre, o  $\text{NO}_x$  ao ciclo do nitrogênio (DOMÉNECH, 2008; LENZI; FAVERO, 2011; DERISIO, 2012; AUSTIN, A. T. et al., 2013). Destaca-se, também, a influência que o sistema atmosférico sofre pelos sistemas da litosfera, hidrosfera e biosfera. Cita-se a contribuição à atmosfera pelos vulcões ( $\text{SO}_x$ ) - (PRESS et al., 2006), pelas bactérias que degradam a matéria orgânica no solo ( $\text{NO}_x$ ) - (TASDEMIR et al., 2012), pelos oceanos e fotossíntese ( $\text{CO}_2$ ) - (MAHOWALD, 2011; HÖNISCH et al., 2012). A observação também pode ser realizada no outro sentido, ou seja, a influência causada pelo sistema atmosférico. Um exemplo são as chuvas ácidas, que transferem toda a carga poluente da atmosfera ( $\text{SO}_2$  e  $\text{NO}_x$ ) para os recursos hídricos, para o solo e para os seres vivos (DOMÉNECH, 2008; GRIGAL, 2012; WU et al., 2012; REIS et al., 2012; HŮNOVÁ et al., 2013).

Metcalf e Derwent (2005) citam os casos de alguns lagos na América do Norte e na Europa que apresentam pH baixos devido à influência do sistema atmosférico - decorrência do fenômeno conhecido como deposição ácida, chuva ácida. Nesse sentido, toda a biota aquática foi influenciada pelo fenômeno, gerando, por exemplo, a mortandade dos peixes. Liu et al. (2013) mostram outro exemplo estudado na China no qual foi identificada a elevada alteração dos ecossistemas chineses devido a crescente deposição do nitrogênio (N). Liu et al. (2013) identificaram que no período entre os anos de 1980 e 2000 a média anual da carga de deposição do N na China aumentou aproximadamente 8 kg por hectare.

As reações químicas dentro de cada ciclo podem produzir os poluentes conhecidos como secundários. Entende-se como poluente secundário aquele que é formado a partir de um primário após uma reação química. Já o poluente primário é oriundo diretamente de uma fonte de emissão. O  $\text{O}_3$  é um exemplo de poluente secundário, pois pode ser formado a partir do  $\text{NO}_2$ , após a reação fotoquímica com o oxigênio molecular ( $\text{O}_2$ ) e o oxigênio atômico (O). Outro

exemplo é o aerossol de sulfato ( $\text{SO}_4^{2-}$ ), que se forma quando o  $\text{SO}_2$  reage com o oxigênio na presença de água. Vale destacar que os particulados também podem ser classificados como secundários, após os processos de remoção e formação de particulados na atmosfera (ASSUNÇÃO, 2004; CHRISTOPHERSON, 2012; ANDREAE, 2013; BECHLE et al., 2013).

Além dos particulados, os gases também são vulneráveis às influências climatológicas. Baldauf et al. (2013) mostram, por exemplo, que em Las Vegas nos EUA os picos de concentração de  $\text{NO}_2$  ocorreram quando a velocidade do vento se apresentava baixa. Os autores viram também que a poluição atmosférica atingiu as maiores distâncias da fonte de emissão conforme o aumento da velocidade do vento. Nesse sentido, pode-se afirmar que quanto maior a velocidade do vento, maior a distribuição espacial da poluição. E que quanto menor a velocidade do vento, maior a concentração do gás perto da fonte de emissão (TANG et al., 2001; WALLACE et al., 2009; RODRIGUEZ et al., 2013).

Outro exemplo é em relação ao  $\text{O}_3$ , no qual as concentrações na atmosfera são extremamente sensíveis às condições climatológicas, sobre tudo a temperatura (MA et al., 2012). Um estudo realizado no leste da Ásia com dados referentes ao período de 1985 a 2006 observou que a concentração de  $\text{O}_3$  pode sofrer uma variação de até 30% devido à mudança de temperatura da região (JEONG; PARK, 2013).

Há alguns outros gases presentes em menor proporção na atmosfera, mas que são considerados poluentes. Assunção (2004) cita os amoníacos ( $\text{NH}_3$ ), os Hidrocarbonetos Aromáticos Policíclicos (HAP), os compostos orgânicos voláteis (COV) - tendo como exemplo o metano ( $\text{CH}_4$ ), os cloretos de hidrogênio ( $\text{HCl}$ ), os sulfetos de hidrogênio ( $\text{H}_2\text{S}$ ). Em algumas regiões esses gases também apresentam um impacto negativo significativo, como em Nova York (JUNG et al., 2011), no Reino Unido (TANG et al., 2001), em Sydney (HENSHER; STOPHER, 2004).

### 1.1.2 FONTES DE POLUIÇÃO

No contexto global, mais de 70% dos poluentes presentes na atmosfera são de origem antrópica (HARISH, 2012). No entanto, em alguns lugares, como áreas próximas de vulcões, a emissão natural de poluentes do ar é considerada a mais expressiva (PRESS et al., 2006). Dessa maneira, as fontes de poluição atmosférica podem ser divididas em naturais e antrópicas. Outra forma de classificar as fontes de emissão de gases e partículas é com base na mobilidade da fonte, ou seja, fixas e móveis, além da classificação com referência ao ambiente de poluição, *outdoor* e *indoor* (SOKHI, 2011).

### 1.1.2.1 Fontes naturais

Os vulcões, os solos, os desertos, as queimadas, a vegetação, os oceanos são exemplos das principais fontes naturais de poluição atmosférica (AGUIAR et al., 2005). A presença significativa dessas fontes associadas a certas condições de característica do ambiente, como clima e relevo, já são suficientes para gerarem um impacto negativo decorrente da poluição do ar, independente das fontes antrópicas (MOTTA; CORRÊA, 1998).

Quanto aos vulcões, destaca-se a capacidade de dispersão que os poluentes lançados possuem, principalmente quando o vulcão entra em atividade de erupção. Pode-se citar o vulcão *Eyjafjallajokull* na Islândia, no qual entrou em erupção em 2010 e atingiu cerca de 40 países da Europa. Os principais poluentes lançados foram os NO<sub>x</sub>, SO<sub>x</sub>, particulados e aerossóis (COLETTE et al., 2011; MATTHIAS et al., 2012; PETÄJÄ et al., 2012). Outro destaque também é em relação à quantidade de poluente lançado na atmosfera pelas erupções vulcânicas. Por exemplo, em 1991, o Monte Pinatubo nas Filipinas emitiu em torno de 20 milhões de toneladas de SO<sub>2</sub> e particulados (CHRISTOPHERSON, 2012).

Os solos, sobretudo os expostos, e os desertos são caracterizados como áreas fontes de particulados (ALMEIDA-SILVA et al., 2011; SAYEGH, 2012; CHOI; KIM, 2012). Como no caso dos vulcões, a dispersão desses particulados também podem atingir longas distancias da fonte de emissão. O deserto do Saara é um exemplo. As areias do deserto chegam a atravessar o Oceano Atlântico até a floresta Amazônica. Sobre a floresta, as areias têm um potencial de interferência na ocorrência de chuvas na região, o que mostra mais um indício da relação sistêmica entre poluição do ar, sistemas biogeoquímicos e sistemas climáticos (ACADEMIC ONEFILE, 2013).

Outro exemplo da ação dos solos e desertos como fonte de particulados é citado por China e James (2012), no qual os autores identificaram que em Las Vegas nos EUA 45% de todo o material particulado transportado pelo vento é oriundo das superfícies naturais, os desertos e os solos expostos. Os demais 55% são oriundos das atividades antrópicas.

Vale destacar especificamente em relação aos solos, que também são fontes de emissão de alguns gases, porém em menor proporção. A emissão desses gases é em decorrência dos processos biogeoquímicos que ocorrem no solo. São emitidos óxidos nitrosos (N<sub>2</sub>O) pelo processo de desnitrificação, amônia (NH<sub>3</sub>) pelos processos aeróbicos, gases redutores como o CH<sub>4</sub> e o sulfeto de hidrogênio (H<sub>2</sub>S) pelo processo de fermentação anaeróbica em zonas úmidas (WANG, D. G. et al., 2008; DRIVAS et al., 2011; GRIGAL, 2012; GERON; HAYS, 2013).

Quanto às queimadas, vale destacar que podem ocorrer por causas naturais ou por ação humana. Nesse sentido, para considerá-la como fonte natural de emissão de poluentes atmosféricos, as razões de ocorrência não podem ser antrópicas (FREITAS; LONGO, 2005). A principal variável para tornar um ambiente propício para a geração de queimadas naturais é a estação da seca, tendo como exemplo algumas regiões da Austrália (REISEN et al., 2013), dos EUA (CHRISTOPHERSON, 2012; GERON; HAYS, 2013), da África (WILLIAMS et al., 2012) e do Brasil, principalmente a Amazônia e o Cerrado (FREITAS; LONGO, 2005; IGNOTTI et al., 2010; INPE, 2013). Em ambas as regiões já foram registradas as correlações positivas entre os picos de queimadas anuais e as maiores concentrações de gases e partículas atmosféricas. Os principais poluentes emitidos pelas queimadas são o CO, CO<sub>2</sub>, NO<sub>x</sub> e particulados (CHRISTOPHERSON, 2012). Vale destacar que a quantidade e a característica do poluente que será emitido é dependente do tipo de matéria que é queimada (PARK et al., 2013).

E em relação à vegetação e aos oceanos, são dois componentes que estão ligados diretamente aos ciclos biogeoquímicos. Representam, sobretudo, a biosfera e a hidrosfera, respectivamente (CHRISTOPHERSON, 2012). Diante disso, o principal poluente emitido pelas plantas são os polens e os hidrocarbonetos (SAYEGH, 2012). Já os oceanos, têm como produtos decorrentes das reações físico-químicas o CO, CO<sub>2</sub>, CH<sub>4</sub>, NO<sub>x</sub>, além da emissão de particulados (HÖNISCH et al., 2012).

### **1.1.2.2 Fontes antrópicas**

Além das fontes naturais, a outra classificação que é considerada a mais expressiva no contexto mundial e especificamente na maioria dos centros urbanos, são as fontes de origem antrópica. Na Holanda, por exemplo, 70-80% do MP<sub>10</sub> e 80-95% do MP<sub>2.5</sub> são de origem antrópica, no qual os setores de agricultura e de transporte são considerados os maiores contribuidores (HENDRIKS et al., 2013).

As fontes de poluição atmosférica decorrentes das atividades humanas podem ser oriundas dos meios de transportes, das indústrias, de algumas usinas de geração de energia, e de outras atividades tais como, construção civil, aterros sanitários, usinas de tratamento de esgoto etc. (SOKHI, 2011). Há também as fontes mais pontuais, aquelas que não possuem a característica de se dispersar espacialmente por uma cidade, tais como o tabagismo e os aparelhos de ar condicionado (CRISTALE et al., 2012; CHOWDHURY et al., 2013).


#### 1.1.2.2.1 Meios de transporte

A nível mundial, os meios de transportes são responsáveis pela emissão de 30% de NO<sub>x</sub> e 14% de CO<sub>2</sub> de todo o planeta Terra (VASCONCELLOS, 2006). No Brasil, em torno de 40% do CO<sub>2</sub> são oriundos dos meios de transporte (MCT, 2013). Em Pequim, os sistemas de transporte emitem cerca de 35% das concentrações de NO<sub>x</sub>. Já em Tóquio, 71% de NO<sub>x</sub> foram decorrentes dos meios de transporte (SOKHI, 2011). Nos EUA, os veículos automotores emitem 55% da concentração de NO<sub>x</sub>, 78% de CO, 47% dos COV, 85% de SO<sub>x</sub>, 58% de MP (CHRISTOPHERSON, 2012; PHALEN, 2012b). Diante desse contexto, os principais poluentes emitidos pelos meios de transporte são NO<sub>x</sub>, CO<sub>2</sub>, MP, hidrocarbonetos, CO, SO<sub>x</sub>, COV e O<sub>3</sub> (VASCONCELLOS, 2006).

O elevado número de veículos automotores terrestres são as principais causas do cenário que aponta a participação significativa dos meios de transportes nos inventários de emissão. Vale destacar que nos EUA 35,1% do NO<sub>x</sub> são oriundos dos automóveis, motocicletas, ônibus e caminhões (HANSON; GIULIANO, 2004). Nesse sentido, o desenvolvimento econômico de um país passa ser um indicador de poluição atmosférica. Percebe-se que os países mais desenvolvidos possuem uma maior taxa de motorização, o que pode acarretar uma maior emissão de gases e partículas decorrentes dos meios de transportes (HANSON; GIULIANO, 2004; VASCONCELLOS, 2006; FAN et al., 2012).

No Brasil, o desenvolvimento econômico nos últimos anos tem sido um estimulador para o aumento do número de veículos automotores terrestres (MOTTA et al., 20AD; VASCONCELLOS, 2006). De acordo com o Ministério do Meio Ambiente (MMA), no período de 1980 até 2008 o número de veículos no território brasileiro teve um aumento maior que 200%. Dentre os veículos automotores terrestres como, caminhões, ônibus, motocicletas, os automóveis se destacam quantitativamente por representarem 59%, tendo como referência o ano de 2009 (Figura 2).

Figura 2 - Evolução do número de veículos no Brasil.



Fonte: MMA (2011).

Os automóveis são considerados uma categoria de transporte de passageiro individual, conhecidos também como veículos leves. Diferente dos ônibus que são meios coletivos para o transporte de passageiros e classificados como veículos pesados. As motocicletas são consideradas veículos individuais leves para transporte de passageiro. E os caminhões são classificados como veículos pesados para o transporte de carga. Cada tipo desses veículos se diferencia em relação à emissão de poluentes atmosféricos (CABRAL et al., 2001).

Sobre o ponto de vista do combustível utilizado, os veículos pesados têm um potencial maior de poluição. A queima do diesel, que é o combustível utilizado em boa parte dos veículos pesados, é mais impactante ao meio ambiente que a queima do álcool e da gasolina (HABERMANN; GOUVEIA, 2012). Destaca-se que o setor de transporte no Brasil corresponde a 48% do consumo de demanda total de petróleo. Desses, 47% é óleo diesel, e 30% a gasolina automotiva. Entre o total de óleo diesel consumido, 8% correspondem ao biodiesel (REIS et al., 2005; VASCONCELLOS, 2006).

Branco e Walsh (2005) afirmam que geralmente as maiores concentrações de MP se encontram nas regiões com alto número de veículos a diesel. O MMA (2011) mostra que a taxa média de emissão de CO<sub>2</sub> (kg/l) de um veículo movido a gasolina é de 2,40; de um veículo movido a diesel é 2,69; movido a metanol é 1,08 e movido a etanol é 1,50. Vale ressaltar que a idade do veículo, a tecnologia do motor, composição do combustível, regulagem e manutenção do veículo influenciam nessas taxas de emissão (BLACK, 2010).



No entanto, sobre a ótica da capacidade do transporte e da frota de veículos, o tráfego de veículos leves individuais é o responsável pela maior parte das emissões oriundas dos meios de transporte (HENSHER; BUTTON, 2000; KIM; KWAN, 2003). Na área metropolitana do Rio de Janeiro, por exemplo, os ônibus emitem 4.040 t de CO<sub>2</sub> por dia, gerando uma taxa de 0,34 kg para cada passageiro. Já os automóveis dessa mesma área emitem 7.947 t de CO<sub>2</sub> por dia, e cada passageiro contribui com 2,58 kg de CO<sub>2</sub>, ou seja, 8 vezes maior que a emissão relativa de um passageiro de ônibus (VASCONCELLOS, 2006). Quanto ao número de passageiros transportados, Vasconcellos (2006) cita que um ônibus comum movido a óleo diesel com 45 assentos e com 2 passageiros está emitindo em média menos CO e hidrocarbonetos por pessoa que um automóvel levando 1,5 passageiro. Outra observação citada ainda por Vasconcellos (2006) é que um ônibus comum movido a óleo diesel, com 45 assentos e com 4 passageiros, está usando em média menos energia por pessoa que um automóvel levando 1,5 passageiro.

As maiores concentrações de poluentes atmosféricos decorrentes dos veículos terrestres leves e pesados estão presentes nos ambientes urbanos. A densidade do tráfego, os tipos de veículos, o poder aquisitivo e o estilo de vida da população são fatores que determinam a qualidade do ar nas cidades (CERVERO; KOCKELMAN, 1997; LIMTANAKOOL et al., 2004; KAM et al., 2012; CABALLERO et al., 2012; WALLACE et al., 2012).

Nesse sentido, medidas governamentais e algumas mudanças de comportamento da população podem colaborar com a melhoria da qualidade do ar em uma cidade. Em alguns casos, essas medidas são restritivas ao uso do transporte particular. Vasconcellos (2006) e o Ministério das Cidades (2006) citam: a) a restrição à circulação em determinadas regiões ou em determinados horários; b) o rodízio de veículos; c) o pedágio urbano; d) a intervenção sobre as interações de transporte e uso do solo; e) a promoção do transporte coletivo; f) a promoção dos modos alternativos de transporte; g) a promoção da carona solidária.

Essas medidas são conhecidas como políticas para o transporte sustentável. Black (2010) e Duarte et al. (2013) definem o transporte sustentável como a taxa de uso dos recursos renováveis que não excede a taxa de renovação, e também, como a taxa de emissão dos poluentes que não excede a capacidade de assimilação. Assim, alguns indicadores são adotados para avaliação da sustentabilidade do transporte em uma cidade, tais como o nível de motorização, uso do transporte público, a facilidade e os pontos negativos da rede de transporte público, a acessibilidade a longa distância, a poluição atmosférica e o ruído, as tendências históricas de acidentes e a relação entre taxas e infraestrutura (CABRAL et al., 2001; HENSHER; STOPHER, 2004; VASCONCELLOS, 2006).

Outras variáveis importantes ligadas ao transporte e que influenciam significativamente na qualidade do ar em um ambiente urbano é a arquitetura da cidade. Por exemplo, a concentração dos poluentes pode ser intensificada em túneis urbanos (ALMEIDA-SILVA et al., 2011) e em avenidas que possuem elevada concentração de prédios altos (HEIDEN et al., 2012; BALDAUF et al., 2013).

Além dos modais de veículos automotores terrestres, já foi identificado também a influência na qualidade do ar de outros modais de transporte, como o transporte aquaviário (OLIVIÉ et al., 2012; ŽIBERT; PRAŽNIKAR, 2012; ZHAO et al., 2013), o aéreo (BARRETT et al., 2010; HSU et al., 2012; LOBO et al., 2012; TOURI et al., 2013) e o ferroviário (ANTT, 2010).

Um estudo realizado no Porto de Xangai identificou que os navios atracados no porto podem ter uma participação de até 64% na emissão de  $PM_{2,5}$  na região portuária (ZHAO et al., 2013). Quanto ao transporte aéreo, Hsu et al. (2012) identificaram correlações positivas entre o tráfego de aviões e a concentração de partículas ultrafinas em um aeroporto nos EUA. E em relação ao transporte ferroviário, o inventário realizado pela Agência Nacional de Transportes Terrestres (ANTT) mostra que no ano de 2009 as ferrovias brasileiras foram responsáveis pela emissão de 1.288 t de  $MP_{10}$ , 50.803 t de  $NO_x$ , 37.807 t de CO (ANTT, 2010). Vale ressaltar que quanto ao impacto das ferrovias, deve-se levar em consideração a tecnologia empregada nos trens. No caso do Brasil, esses dados foram obtidos levando-se em consideração que os trens são movidos a diesel.

#### 1.1.2.2.2 Indústrias e outras fontes

A intensidade e o tipo de poluente lançado na atmosfera decorrente das atividades industriais dependem do tipo específico da indústria, como indústria têxtil, química, de papel, de combustível, de mineração, de bebidas, farmacêutica. Nesse contexto, os grandes parques industriais são considerados os lugares mais críticos como fonte lançadora de gases e partículas (SÁNCHEZ, 2008; GEELEN et al., 2013; GUTTIKUNDA; CALORI, 2013). Um estudo realizado para a região de Rayong, Tailândia (THEPANONDH; TORUKSA, 2011), identificou, por exemplo, que há uma relação da concentração elevada de  $NO_2$  nas regiões com tráfego intenso de veículos, sobretudo no setor industrial da cidade.

No Brasil, o estado de São Paulo se destaca por concentrar a maior parte das indústrias do país. Na região, 13,7% das emissões de  $CO_2$  foram oriundas das indústrias do estado (CETESB, 2011). A cidade de Cubatão - SP ficou conhecida na história por ter apresentado altas

concentrações de poluentes durante a década de 80. O fato nessa cidade ocorreu devido a junção das emissões industriais com as condições de relevo local que impedia a dispersão dos poluentes. Foi necessária a implantação urgente de medidas de controle nas indústrias para minimizar as concentrações de poluentes (LISKA; BEIJO, 2012; TAYRA et al., 2012).

Alguns outros países também são conhecidos pela alta concentração de indústrias. Nos EUA, por exemplo, 45% do COV e 42% do MP presente na atmosfera tem como fonte as indústrias (CHRISTOPHERSON, 2012). Na Índia as indústrias são responsáveis pela emissão de 14% de PM<sub>2.5</sub>, 23% de SO<sub>2</sub>, 11% de NO<sub>x</sub> e 15% de CO (GUTTIKUNDA; CALORI, 2013). E em Portugal, 7,9% dos MP são decorrentes das atividades industriais (MCOTA, 2003).

Além das indústrias, o setor de geração de energia também se apresenta como relevante nos inventários de poluição. Nesse caso, a quantidade de poluentes lançados na atmosfera é dependente das fontes geradoras de energia. Por exemplo, uma termoeletrica a óleo combustível pode emitir 40 mil toneladas anuais de SO<sub>2</sub>, 30 mil de NO<sub>x</sub> e 5.400 de MP para cada tonelada de óleo combustível utilizado na geração de energia. Por outro lado, as fontes de energia hidráulica, eólica e solar emitem anualmente valores insignificantes, nos quais variam em torno de 10; 8; 0,36 gramas de NO<sub>x</sub>, respectivamente (GÓRALCYK, 2003).

Como um exemplo brasileiro, Nakagawa et al. (2013) mostraram que a taxa de emissão de MP na termoeletrica de Piratininga do estado de São Paulo é de 6,92 gramas por segundo de operação. Já em Pequim e em Tóquio, Sokhi (2011) cita que o setor de geração de energia é responsável pela emissão de 49% de toda concentração de SO<sub>2</sub>. Portanto, vale destacar que em alguns inventários são consideradas como uma só categoria as emissões do setor industrial e do setor de geração de energia. É o caso do inventário da região da costa Leste Chinesa, no qual teve como resultado que 69% do COV e 89% do NO<sub>x</sub> são provenientes do setor industrial mais o setor de geração de energia (HUANG et al., 2011).

Em complemento à lista das fontes antrópicas de poluição atmosférica, citam-se as que apresentam em menor porcentagem nos inventários, mas que são consideradas em alguns estudos. Essas fontes são: as atividades de construção civil (JUNG et al., 2011), os aterros sanitários (SILVA, T. N. et al., 2013; GUTTIKUNDA; CALORI, 2013), os incineradores (ASHWORTH et al., 2013), as estações de tratamento de esgoto (CETESB, 2011; MARTELLINI et al., 2012).

### 1.1.2.3 Fontes fixas e móveis

A capacidade de mobilidade é o fator que diferencia as fontes móveis das fixas. Destaca-se que as fontes classificadas como naturais ou antrópicas também podem ter uma subclassificação como fixas ou móveis. Por exemplo, os vulcões que são fontes naturais, têm a subclassificação como uma fonte fixa. As indústrias são consideradas fontes antrópicas e fontes fixas. Os veículos automotores são fontes antrópicas e móveis (PHALEN, 2012b).

No entanto, dependendo do ponto de referência, um conjunto de fontes móveis pode ser considerado como fonte fixa. Cita-se o caso de uma rodoviária, na qual é classificada como uma fonte fixa de poluição, independente dos ônibus que circulam diariamente serem classificados individualmente como fontes móveis. O fato é que a rodoviária que é fixa concentra um número significativo de veículos automotores. Esse raciocínio pode ser estendido para os portos e aeroportos (PHALEN, 2012b).

Nesse sentido, Phalen (2012) mostra que nos EUA 85% do SO<sub>2</sub> vem das fontes fixas. Em São Paulo, as fontes móveis emitem 96% do NO<sub>x</sub> (BRANCO; WALSH, 2005). Já em Santiago, Metcalfe e Derwent (2005) apresentam que 6 toneladas por ano de SO<sub>x</sub> são lançadas na atmosfera pelas fontes fixas, enquanto que as fontes móveis lançam 3,1 toneladas no mesmo período. Porém, quanto ao CO, as fontes móveis contribuem mais, do total de 191,6 toneladas por ano, 175,6 são decorrentes das emissões móveis.

### 1.1.2.4 Fontes conforme o ambiente – outdoor e indoor

Até a década de 90 poucos estudos de poluição atmosférica levavam em consideração os ambientes internos. A maior preocupação era em relação aos ambientes externos. No entanto, a partir dos anos 2000, as pesquisas passaram a considerar os ambientes internos como um lugar significativo para ter concentrações elevadas de poluentes. Entendem-se como os ambientes externos de poluição atmosférica - *outdoor*, todos aqueles que estão ao ar livre. Por outro lado, o interior das edificações, como casas, apartamentos, escritórios, estabelecimentos comerciais, são considerados como ambientes internos - *indoor* (SOKHI, 2011).

A motivação dos estudos para a diferenciação desses dois tipos de ambientes foi baseada no tempo de permanência das pessoas em lugares rotineiros, como, residências, trabalho, centros educacionais, entre outros. Os pesquisadores começaram observar que a maioria das pessoas passa mais que 80% das horas diárias nos ambientes internos, tornando-se assim susceptíveis

aos efeitos danosos da concentração *indoor* de gases e partículas (TRONCOSO; CIFUENTES, 2012; BUONANNO, G. et al., 2013). A Organização Mundial de Saúde (OMS) destaca que a poluição *indoor* está em oitavo lugar como um dos fatores para o surgimento de doenças cardiovasculares (OMS, 2010).

Phalen (2012) cita certos poluentes comuns de serem encontrados em ambientes fechados, tais como: aerossol biológico, que possuem como fonte os animais de estimação; COV, que possuem como fonte os produtos como sprays, solventes, além das pinturas; particulados, que possuem como fonte as plantas e o cigarro; gases, que possuem como fonte as descargas elétricas, os fogões a gás e o cigarro; e os microrganismos, que possuem como fonte os sistemas de ar-condicionado e os animais de estimação. Chowdhury et al. (2013) e Sarkhosh et al. (2012) destacam que a poluição externa também pode influenciar na concentração de poluentes nos ambientes internos. A intensidade dessa influência é dependente de características como o tempo que a janela fica aberta, o tipo do sistema de circulação do ar do edifício, o sistema de vedação da estrutura (LIN, L.-Y. et al., 2013; LEE et al., 2014).

Devido às fontes de poluição *indoor* e à influência *outdoor*, os ambientes internos podem apresentar concentrações de poluentes próximas dos ambientes externos. Um estudo realizado em 4 regiões urbanizadas da Coreia - Seoul, Daegu, Asan e Suncheon mostrou que enquanto dentro das residências tinha uma média de 21,2 ppb de NO<sub>2</sub>, fora das residências a média foi de 23,7 ppb (LEE, K. et al., 2013). Em uma área urbana da cidade de Cassino, na Itália, Buonanno et al. (2013) estudaram a exposição individual de crianças. Os autores identificaram que as residências das crianças contribuíam com uma dose diária de 25%, relacionado à deposição do MP no trato respiratório.

Além das regiões urbanizadas, as residências das áreas rurais também se destacam por apresentarem concentrações elevadas de poluentes atmosféricos em ambiente *indoor*. Nessas áreas, os fogões são considerados a principal fonte, pois ainda é comum encontrar fogões que utilizam lenha ou óleo querosene (MONDAL et al., 2011; VESILIND; MORGAN, 2011; SINGHE; JAMAL, 2012a). Na Índia, aproximadamente 85% da energia utilizada para cozinhar é da queima de biomassa, como madeira, resíduos de agricultura (CHENG et al., 2013).

### 1.1.3 MONITORAMENTO DA POLUIÇÃO DO AR

A acurácia e a precisão dos estudos de poluição do ar dependem da qualidade do monitoramento. É na etapa de monitoramento que parte dos dados serão coletados para alimentar os modelos que objetivam representar a dinâmica da poluição atmosférica (CONGALTON; GREEN, 1999; WALLACE et al., 2009; JOLY; PEUCH, 2012). A implantação de uma infraestrutura para a coleta desses dados é justificada pelo fato de ser uma ferramenta de auxílio para as políticas de saúde pública, fornecimento de dados para ativar ações de emergências, acompanhamento de tendências, controle do processo poluidor, controle dos padrões de emissão, fornecimento de dados para o cálculo dos fatores de emissão e para o entendimento da exposição ao ar poluído. Essas justificativas levam a um objetivo principal, contribuir com as ações de promoção para o bem estar da população (AGUIAR et al., 2005).

#### 1.1.3.1 Tipos de monitoramento

As opções para o tipo de monitoramento, assim como o tipo de equipamento para coleta dos dados, podem ser classificados em quatro categorias: passivos ou ativos (YANNOPOULOS, 2011; BHANGAR et al., 2013), fixos ou móveis (KOUSOULIDOU et al., 2013), automático (KUMAR et al., 2011; FERNANDO et al., 2012), biomonitoramento (SAYEGH, 2012; BUSTAMANTE et al., 2013) e monitoramento por satélite (KLOOG et al., 2012).

O monitoramento passivo é aquele em que ocorre pelo processo de difusão molecular, no qual o poluente atmosférico passa por uma camada estática ou por alguma membrana. O equipamento de amostragem, os amostradores, é caracterizado pela existência de uma superfície absorvente em que fica exposta ao ar por um certo período de tempo (hora, dia, mês). Após a exposição em campo, os amostradores são levados ao laboratório para determinação da concentração dos poluentes absorvidos. O método passivo é comum para determinação das concentrações de NO<sub>2</sub>, SO<sub>2</sub>, NH<sub>3</sub> e O<sub>3</sub> (ROADMAN et al., 2003; BHANGAR et al., 2013). Por outro lado, o monitoramento ativo é aquele característico pela presença de um equipamento responsável pelo bombeamento do ar. O equipamento não fica somente exposto ao ar, como no monitoramento passivo. O ar bombeado pode ser coletado pelos processos de adsorção, filtração, difusão, reação ou por uma combinação desses processos. Os equipamentos de monitoramento ativo são comuns para as determinações das concentrações dos MP, SO<sub>2</sub>, NO<sub>2</sub> (MOODLEY et al., 2011).

Destaca-se que tanto os amostradores passivos, quanto os ativos, já foram utilizados para os estudos que buscaram avaliar a contribuição das fontes de poluição (MOODLEY et al., 2011; BHANGAR et al., 2013), os efeitos da poluição atmosférica (LEE et al., 2004; SOLOMON et al., 2011; CABALLERO et al., 2012), além das relações espaciais e temporais das variáveis em questão (GARCIA et al., 2010; DERAISME et al., 2011; RIVERA et al., 2012; PIRJOLA et al., 2012).

Em relação ao monitoramento fixo ou móvel, a diferença está na facilidade de mobilidade do equipamento. Alguns equipamentos necessitam de uma infraestrutura instalada no local para a realização do monitoramento, energia elétrica, grade de proteção etc. Nesses casos, o monitoramento é considerado fixo, pois seria inviável mover frequentemente os equipamentos juntamente com a infraestrutura. Já os equipamentos móveis, são passíveis de mobilidade nas áreas de estudo, o que contribui para as pesquisas que objetivam avaliar a relação espacial ou exposição individual (AGUIAR et al., 2005; WALLACE et al., 2009; FULLER et al., 2012).

Os equipamentos móveis podem ser de grande ou de pequeno porte. Os de grande porte são conhecidos por estarem integrado a um conjunto de equipamentos, em um contêiner, por exemplo, e que podem ser transportados por um veículo automotor. Nesse caso, o contêiner é caracterizado como uma estação de monitoramento móvel (WALLACE et al., 2009). E quanto aos equipamentos de pequeno porte, podem-se citar os conhecidos como portáteis (KANG; KIM, 2012; KOUSOULIDOU et al., 2013). A característica dos equipamentos portáteis é que pode ser transportado por pessoas, o que abre a possibilidade de avaliar a exposição pessoal ao ar poluído (LEE et al., 2006; MENG et al., 2012). Destaca-se que alguns equipamentos passivos também possuem a característica de serem portáteis (CABALLERO et al., 2012; BHANGAR et al., 2013).

O desenvolvimento da tecnologia está possibilitando o surgimento de equipamentos que determinam a concentração dos poluentes atmosféricos de maneira automática. Com isso, a operação manual e de laboratório fica cada vez mais reduzida, pois alguns equipamentos já possuem a função de calcular a concentração dos poluentes e enviar os dados via internet. Já é comum encontrar essa função automática nos equipamentos móveis, sobretudo, os portáteis. Também, algumas estações fixas também podem ser compostas por equipamentos automáticos (METCALFE; DERWENT, 2005).

Conforme Kang e Kim (2012) os equipamentos automáticos podem fornecer medidas com resolução temporal relativamente alta, dia, hora, e até minutos. São utilizados princípios eletro-óptico para determinação da concentração do poluente. Esses princípios eletro-óptico podem

ser exemplificados como: como fluorescência, quimiluminescência, absorção de infravermelho, cromatografia gasosa.

O biomonitoramento é uma técnica que utiliza organismos vivos, os bioindicadores, para avaliar a qualidade ambiental do ar, da água, do solo (PANT; TRIPATHI, 2012; KÄFFER et al., 2012). Quanto à qualidade do ar, já foi testado com frequência e viu-se que é indicado o uso de plantas, líquens, fungos como bioindicadores da poluição atmosférica (PAOLI et al., 2012; SANTOS et al., 2012; ACHOTEGUI-CASTELLS et al., 2013; KHAVANIN et al., 2013).

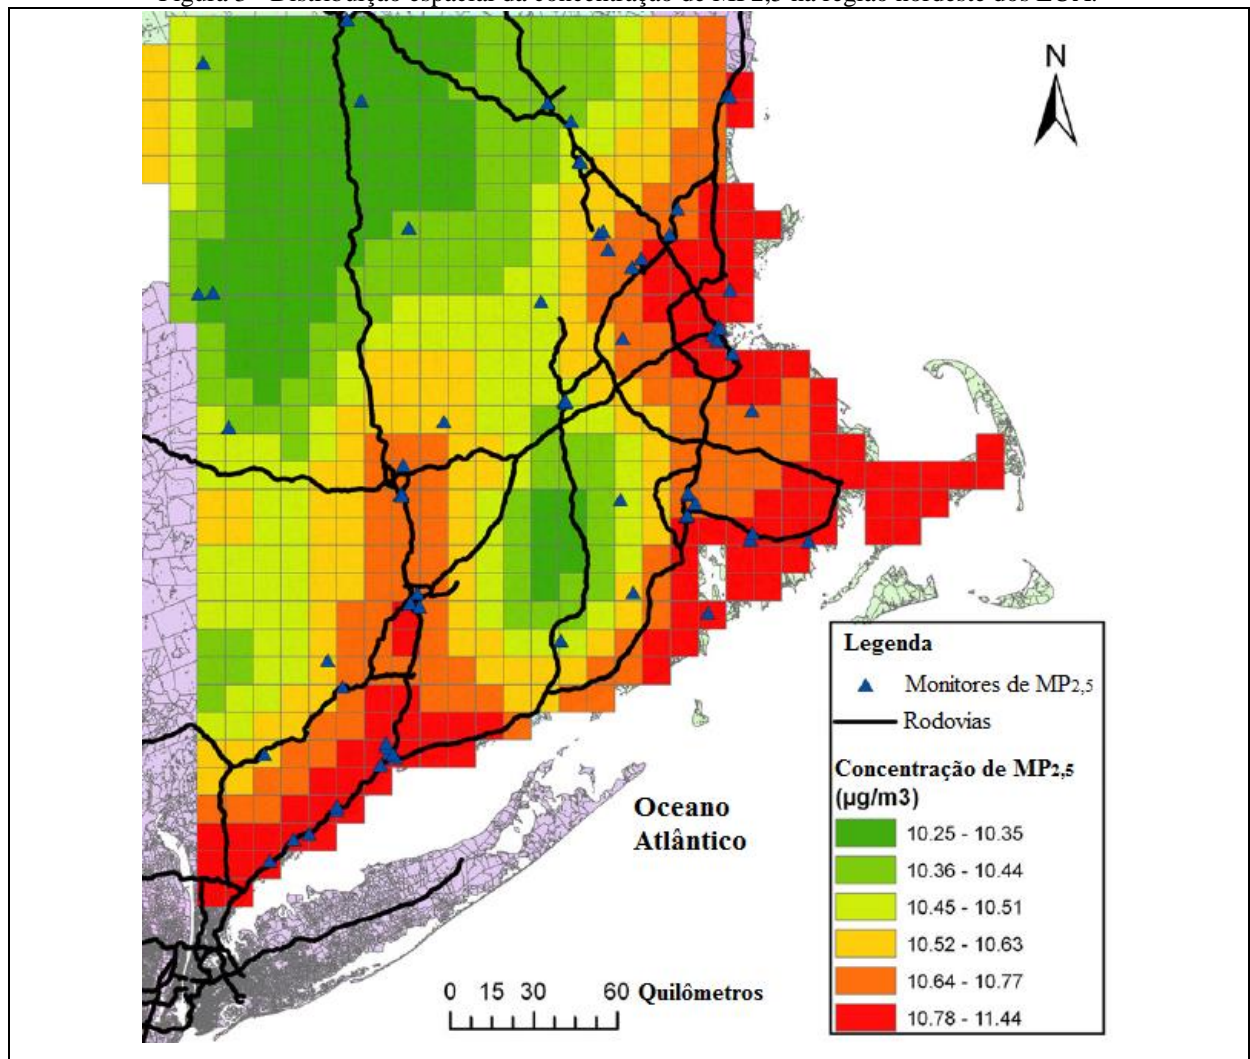
O entendimento do monitoramento da qualidade do ar por satélite se baseia no conceito de sensoriamento remoto. Menezes et al. (2012) definem sensoriamento remoto como a ciência que avalia as interações da radiação eletromagnética com os materiais terrestres. Dentre esses materiais, citam-se os poluentes atmosféricos. Nesse sentido, a radiação eletromagnética emitida pelas partículas atmosféricas podem informar algumas características sobre o material, como por exemplo, o tipo e a concentração de material particulado de uma determinada área (CONGALTON; GREEN, 1999; HEIDEN et al., 2012).

Devido à limitação da resolução espacial dos primeiros satélites, a avaliação da poluição atmosférica por meio dos sensores presentes nos satélites era limitada somente às áreas grandes. No entanto, a partir da década de 90, com o desenvolvimento tecnológico mais intenso dos sensores e melhoria das características das plataformas (satélites), tornou-se possível a observação de pequenas áreas. Atualmente, já se têm satélites com resolução menor que 1 metro (BANZHAF; HÖFER, 2008; MENEZES et al., 2012; MOZUMDER et al., 2012).

Uma das vantagens do monitoramento por satélite é que pode suprir a cobertura das estações fixas a um custo mais baixo (BECHLE et al., 2013). Pesquisas têm utilizado com frequência os dados de ambos os tipos de monitoramento, estações fixas e satélites, para obter um melhor entendimento do comportamento espacial dos poluentes atmosféricos. Como exemplo, a Figura 3 apresenta o resultado de um estudo feito na região Nordeste dos EUA (*New England*), no qual mostrou que é possível avaliar a concentração do  $MP_{2,5}$  por meio de satélites. Um modelo misto de regressão (*mixed effects models*) gerou como resultado um coeficiente de determinação ( $r^2$ ) igual a 0,83. Esse coeficiente é referente à análise do valor predito pelos satélites e do valor monitorado em campo pelas estações fixas na região de *New England* dos EUA (LEE et al., 2012).



Figura 3 - Distribuição espacial da concentração de MP<sub>2,5</sub> na região nordeste dos EUA.



Fonte: Lee H. J. et al. (2012), com edição.

Outras pesquisas também destacaram a viabilidade do uso dos dados de satélites para os estudos de outros poluentes, como NO<sub>2</sub> (BECHLE et al., 2013), aerossol (HU, 2009; MISHRA et al., 2012), SO<sub>2</sub> (MOZUMDER et al., 2012), CO<sub>2</sub> (BAPTISTA, 2004).

Portanto, ressalta-se que os diversos métodos de monitoramento podem ser utilizados simultaneamente, ou isoladamente, conforme os objetivos e as limitações de cada estudo. As redes atuais de monitoramento dos grandes centros urbanos não necessariamente trabalham com um método. A rede da região metropolitana de São Paulo, por exemplo, é composta por equipamentos automáticos, equipamentos manuais, estações fixas e estações móveis, conforme dados da Companhia Ambiental do Estado de São Paulo (CETESB, 2013).

### 1.1.3.2 Redes de monitoramento

As redes de monitoramento são conhecidas como um conjunto de equipamentos de mensuração da poluição atmosférica instalados em um determinado lugar, que geram, processam e disponibilizam informações de forma contínua. Quanto à escala espacial de uma rede, pode ser desde a cobertura de um bairro, uma cidade, um estado, como de um país. Destaca-se, que as informações divulgadas pela rede são importantes para auxiliar na formulação de políticas públicas, como por exemplo, uma ferramenta de apoio para a regulação da qualidade do ar (ADEME, 2002; GOMES, 2010).

Devido ao elevado custo de implantação de uma rede, geralmente a operação fica sobre responsabilidade dos órgãos ambientais (ADEME, 2002). No Brasil, por exemplo, a CETESB, órgão do estado de São Paulo, opera a maior rede do país, composta por 83 estações fixas e móveis, além de equipamentos passivos, ativos, manuais e automáticos (CETESB, 2013). Em Brasília, a rede que ainda está no processo inicial de consolidação, o que a torna precária e de pouca representatividade para a região, é configurada com 7 estações fixas que possuem equipamentos ativos manuais (IBRAM, 2013).

Além de São Paulo e Brasília, poucos outros estados possuem uma rede de monitoramento. Cita-se o estado do Rio de Janeiro, rede operada pelo Instituto Estadual do Ambiente - INEA (INEA, 2013); o estado do Paraná, rede operada pelo Instituto Ambiental do Paraná - IAP (IAP, 2013); o estado do Rio Grande do Sul, rede operada pela Fundação Estadual de Proteção Ambiental - FEPAM (FEPAM, 2013); o estado de Minas Gerais, rede operada pela Fundação Estadual do Meio Ambiente - FEAM (FEAM, 2013). Esse cenário brasileiro resulta no desconhecimento das relações entre as fontes de emissão e qualidade do ar em uma escala nacional. Sobre uma análise geral do país, o Brasil ainda carece de uma rede consolidada, representativa e moderna (AGUIAR et al., 2005).

Contudo, há países em que a rede de monitoramento sobre a ótica nacional é bem estabelecida espacialmente, possui tecnologia avançada, além de ser representativa, como nos EUA (EPA, 2013b), Inglaterra (DEFRA, 2013) e China (AQICN, 2013).

A rede dos EUA é operada pelo órgão ambiental americano - *United States Environmental Protection Agency* - EPA. O sistema de monitoramento é dividido em 9 regiões e atende as 300 maiores cidades dos EUA. A rede é composta por mais ou menos 5 mil estações que possuem equipamentos manuais e automáticos que monitoram os poluentes mais relevantes, como MP, SO<sub>x</sub>, NO<sub>x</sub> e O<sub>3</sub>. É divulgado para o público uma plataforma na internet na qual é possível ter

informações diárias, e até mesmo horárias, sobre as condições da qualidade do ar em toda a região monitorada (EPA, 2013b).

A região da Inglaterra é composta com mais de 300 estações de monitoramento configuradas com estações automáticas e estações manuais. Dessas, em torno de 200 estações são automáticas. O governo inglês iniciou o processo de implantação da rede em 1961, quase uma década após o evento histórico de inversão térmica ocorrido em Londres. O órgão ambiental inglês que opera a rede (Defra - *Department for Environment Food and Rural Affairs*) classifica as estações conforme a sua localização, ou seja, estações urbanas, suburbanas, rurais, tráfego de veículos e industriais (DEFRA, 2013). Especificamente em Londres, há um sistema tecnológico implantado na rede no qual permite que o cidadão londrino acesse pelo celular informações diárias sobre a qualidade do ar em cada região da cidade (LONDON KING'S COLLEGE, 2013).

Na China há uma rede de monitoramento composta com mais de 200 estações. As estações estão concentradas nas cidades que apresentam o nível de poluição atmosférica mais críticos, como Pequim, Shanghai, Hong Kong. Diferente da Inglaterra, na China a política de monitoramento de poluição do ar foi intensificada já a partir do século XXI. O sistema de monitoramento também oferece uma consulta online ao vivo referente a qualidade do ar (AQICN, 2013).

Por fim, destaca-se que o processo de consulta online das redes de monitoramento dos EUA, Inglaterra e China, por exemplo, é denominado como uma etapa dos sistemas atuais que operam com informações espaciais, conhecido como WebGis. O WebGis pode ser caracterizado como a ferramenta computacional que auxilia o processo de operação, processamento e divulgação das informações de uma rede de dados espaciais.

#### 1.1.4 EFEITOS DA POLUIÇÃO ATMOSFÉRICA

A concentração elevada de gases e partículas em dispersão no ar pode gerar efeitos negativos aos componentes dos sistemas ambientais (GRIGAL, 2012), às estruturas urbanas (FUENTE et al., 2012), aos seres humanos (SOLOMON et al., 2011) e até mesmo à economia (YANNOPOULOS, 2011). Os efeitos podem ser diferenciados, sobretudo em relação à intensidade, quando se leva em consideração as fontes de emissão, os tipos de poluentes, as condições meteorológicas e as características do relevo (KOO et al., 2012).

#### 1.1.4.1 Efeitos nos sistemas ambientais e nas estruturas urbanas

Os recursos hídricos, o solo, a vegetação são exemplos de componentes ambientais vulneráveis aos efeitos da poluição atmosférica (SOKHI, 2011). Quanto aos recursos hídricos, os poluentes atmosféricos podem ser responsáveis pela variação do pH, da condutividade elétrica e de alguns íons, como: cloreto ( $\text{Cl}^-$ ), fluoreto ( $\text{F}^-$ ), nitrato ( $\text{NO}_3^-$ ), sulfato ( $\text{SO}_4^{2-}$ ), fosfato ( $\text{PO}_4^{3-}$ ). As alterações desses componentes químicos são decorrentes da dinâmica entre as chuvas e os poluentes do ar, por exemplo. No momento das chuvas, parte da carga poluente presente na atmosfera é transferida para os recursos hídricos, influenciando assim na qualidade do corpo hídrico (KOLENDOWICZ et al., 2011; WU, Q. et al., 2012; REIS et al., 2012). Um estudo espaço temporal realizado por DIAS et al. (2012) na cidade de Cuiabá exemplifica a relação da concentração de poluentes atmosféricos e qualidade da água. O resultado apresentado por esse estudo mostra que as áreas urbanas e os períodos de chuva foram os que apresentaram os maiores valores de correlação entre a concentração de gases e partículas na atmosfera e a concentração de íons na água.

A transferência dos poluentes do ar pela água da chuva também pode ser direcionada ao solo, o que gera um comprometimento a sua característica (SRIVASTAVA; KUMAR, 2012; WANG, QIONG et al., 2012; TASDEMIR et al., 2012). Como exemplo, Tasdemir et al., (2012) mostraram que na Turquia a concentração dos compostos policlorados no solo e no ar tiveram correlações negativa e significativas. A diminuição da concentração no ar gerava um aumento de concentração no solo, mostrando que os compostos estavam saindo do sistema atmosférico pelo processo de deposição no solo. Ressalta-se que os compostos policlorados compõem o grupo das substâncias orgânicas semi voláteis, na qual apresentam características tóxicas e de bioacumulação (WANG, D. G. et al., 2008).

O solo contaminado pode influenciar negativamente no desenvolvimento da vegetação. Esse processo de contaminação pode ocorrer pelas raízes e pelos estômatos, estrutura foliar controladora das trocas gasosas. Por exemplo, a deposição de particulados na superfície das folhas gera a redução da penetração da luz solar, que é necessária para o processo de fotossíntese. Em geral, as plantas podem sofrer alterações na coloração, alterações no crescimento e o colapso no tecido foliar (METCALFE; DERWENT, 2005; BAIRD; CANN, 2011; PANT; TRIPATHI, 2012; SRIVASTAVA; KUMAR, 2012; THAMBAVANI; PRATHIPA, 2012; SAYEGH, 2012).

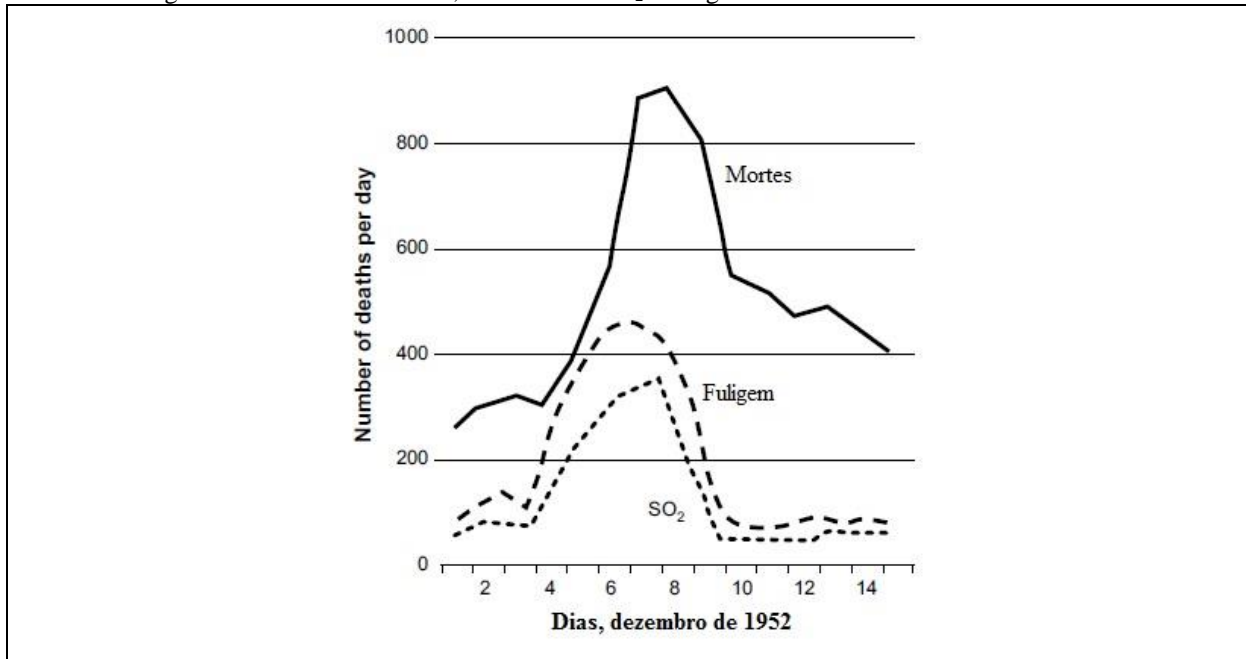
Assim, as chuvas e os ventos são as principais variáveis responsáveis pelo transporte dos poluentes presentes no ar para os outros componentes ambientais, os recursos hídricos, os solos e as plantas (GRIGAL, 2012; RODRIGUEZ et al., 2013). Vale destacar também que além dos impactos nesses componentes, as estruturas urbanas - prédios, monumentos culturais, são influenciados pela poluição atmosférica. Isso ocorre principalmente por reações químicas, a corrosão, por exemplo, nas superfícies de determinadas estruturas de uma cidade (FUENTE et al., 2012).

#### **1.1.4.2 Efeitos na saúde humana**

Os acidentes ocorridos no século XX foram os primeiros indícios de que concentrações elevadas de gases e partículas na atmosfera causam efeitos danosos à saúde humana (SOLOMON et al., 2011). Por exemplo, Derisio (2012) mostra que no acidente do Vale do Rio Meuse em 1930 morreram 63 pessoas, no episódio de inversão térmica na Pensilvânia em 1948 provocou a morte de 20 pessoas e mais 7.000 manifestaram problemas de saúde, e no episódio de Londres em 1952 gerou a morte de 2.000 pessoas.

Todos esses acontecimentos que marcaram o século XX são caracterizados como atípicos, ou seja, no qual a concentração de poluentes na atmosfera teve um aumento brusco em um período de tempo curto devido a fatores antrópicos e/ou naturais. O episódio de Londres em 1952, por exemplo, foi devido a uma frente fria que chegou à capital inglesa durante os dias 5 e 9 de dezembro de 1952 e fez com que a população queimasse mais carvão que o usual. Os efeitos das emissões lançadas pela queima de carvão foram intensificados com o fenômeno de inversão térmica que ocorreu justamente nesse período (DERISIO, 2012). A Figura 4 apresenta o número de mortes no episódio de Londres, 1952, juntamente com a variação da presença de SO<sub>2</sub> e fuligem na atmosfera.


Figura 4 - Número de mortes, emissões de SO<sub>2</sub> e fuligem em Londres - dezembro de 1952.



Fonte: Fenger (2009), com edição.

Nota: número de mortes por dia (number of deaths per day).

Dockery et al. (1993) foram os primeiros a investigar a associação entre poluição do ar e mortalidade tendo como referência as concentrações de poluentes usuais em uma cidade, e não considerando como um evento atípico. O estudo de Dockery et al. (1993) é conhecido como *Harvard six cities*. Esse nome se refere à Universidade de Harvard (instituição onde o estudo foi desenvolvido) e a seis cidades americanas nas quais foram avaliadas (Portage, Topeka, Watertown, St. Louis, Harriman, Steubenville). No estudo de *Harvard six cities* foram avaliadas 8.111 pessoas nas seis cidades durante 16 anos (início em 1974). Os autores encontraram que o aumento de 10 µg/m<sup>3</sup> de MP<sub>2,5</sub> foi associado com 14% no aumento do risco de morte (todas as causas), 26% no aumento do risco de mortes por causa do sistema circulatório e 37% no aumento do risco de morte por câncer de pulmão. A conclusão final dos autores foi que a concentração de MP<sub>2,5</sub> na atmosfera é diretamente associada com a expectativa de vida da população. Steubenville foi a cidade que apresentou a maior concentração de MP<sub>2,5</sub> e a menor taxa de expectativa de vida (Figura 5).

Figura 5 - Harvard six cities, expectativa de vida e concentração de  $PM_{2.5}$ .

Fonte: Dockery et al. (1993), com edição.  
Nota: expectativa de vida (life expectancy).

O *Harvard six cities* estudo teve duas extensões (LADEN et al., 2006; LEPEULE et al., 2012), nas quais as mesmas cidades foram reavaliadas com uma extensão na análise temporal do conjunto dos dados. Um dos objetivos dessas extensões foi analisar os efeitos das políticas de controle da qualidade do ar implantadas pelo órgão ambiental americano (*Environmental Protection Agency* – EPA) desde a publicação do primeiro estudo em 1993. Vale ressaltar que foi o primeiro estudo de *Harvard six cities* que alertou à EPA sobre os reais efeitos da poluição atmosférica sobre a saúde humana. Os autores das extensões do *Harvard six cities* encontraram resultados mostrando os benefícios das políticas de controle da qualidade do ar sobre a população.

Após o primeiro estudo de *Harvard six cities* começou a ser difundido na comunidade científica o maior interesse para os estudos entre poluição do ar e saúde humana em outras regiões, tais como no Brasil (CONCEIÇÃO et al., 2002; TOLEDO; NARDOCCI, 2011; RÉQUIA JÚNIOR; ABREU, 2011; ARBEX et al., 2012), no Chile (VALDÉS et al., 2012; TRONCOSO; CIFUENTES, 2012), na Espanha (RIVERA et al., 2012; GONZALEZ-BARCALA et al., 2013), na Inglaterra (POWELL et al., 2011; MÖLTER et al., 2012; YIM et al., 2013), na Itália (ROSENLUND; PICCIOTTO; et al., 2008; BORGINI et al., 2011; KOUSOULIDOU et al., 2013), na Índia (BARRETT et al., 2010; MONDAL et al., 2011; KHILLARE; SARKAR,

2012), na China (CHAN; YAO, 2008; CHEN et al., 2012; CHOWDHURY et al., 2013), na Austrália (XU et al., 2013). Os efeitos da poluição do ar sobre a saúde humana identificados por esses estudos podem ser detalhados principalmente como:

a) efeitos no sistema respiratório, o que propicia o aumento dos casos de pessoas com câncer, asma, alergias, doenças no pulmão (TRASANDE; THURSTON, 2005; ARBEX et al., 2012). Conforme a Figura 6, os poluentes atmosféricos presentes no sistema respiratório passam por diferentes tipos de deposição, o que gera patologias distintas em cada compartimento do trato respiratório. Especificamente para o material particulado, Gomes (2010) detalha que as menores partículas são as que chegam ao compartimento do pulmão. Nesse sentido, partículas maiores que 7  $\mu\text{m}$  afetam a cavidade oral e nasal, as com 4,7 a 7  $\mu\text{m}$  afetam a laringe, as com 3,3 a 4,7  $\mu\text{m}$  afetam a traquéia e os brônquios primários, as com 2,1 a 3,3  $\mu\text{m}$  afetam os brônquios secundários, as com 1,1 a 2,1  $\mu\text{m}$  afetam os brônquios terminais e as menores que 0,65  $\mu\text{m}$  afetam os alvéolos pulmonares;

Figura 6 - Patologias do sistema respiratório decorrentes da poluição do ar.

Compartimento do trato respiratório		Mecanismo de deposição	Patologia
Superior	Nariz	- impactação - difusão - interceptação - eletrostático	- inflamação - infecção - ulceração - câncer
	Boca		
	Laringe		
Traqueobronquial	Traquéia	- impactação - sedimentação - difusão - interceptação	- inflamação - broncoespasmo - infecção - obstrução - câncer
	Brônquio		
	Bronquio		
Pulmonar	Terminal bronquíolos	- sedimentação - difusão - interceptação	- inflamação - infecção - edema - enfisema - fibrose - câncer
	Bronquiolo respiratório		
	Duto alveolar		
	Alvéolos saco		

Fonte: Phalen (2012), com edição.



b) efeitos no sistema circulatório, propiciando o aumento dos casos de câncer, de doenças cardiovasculares e até influenciando no desempenho para o condicionamento físico de pessoas que praticam esporte (ZANOBETTI; SCHWARTZ, 2009; RUNDELL, 2012; VALDÉS et al., 2012; LIN, H. et al., 2013);

c) aumento dos casos de pessoas com diabetes. Estima-se que a poluição do ar causa uma resistência à insulina, que é um precursor da diabete (SOLOMON et al., 2011; TSAI et al., 2012; NICOLE, 2015);

d) efeitos na saúde perinatal, podendo influenciar no nascimento prematuro, com baixo peso, com deformidades físicas e a maior probabilidade da criança desenvolver doenças do sistema respiratório (AGUILERA et al., 2009; ARBEX et al., 2012; OLIVEIRA, DE et al., 2012; HOFFMAN et al., 2012);

e) e os efeitos nos olhos (TORRICELLI et al., 2014), no sistema nervoso (GENC et al., 2012; DAVIS et al., 2013) e na reprodução humana (SLAMA et al., 2008; LEGRO et al., 2010; VERAS et al., 2010).

Por fim, destaca-se que as pesquisas que buscam avaliar os efeitos da poluição do ar sobre a população humana são consideradas estudos em saúde ambiental, especificamente, estudos em epidemiologia ambiental. O item 1.2 desta tese apresenta os principais conceitos e associação com poluição do ar relacionada a essa área do saber.

#### **1.1.4.3 Efeitos na economia**

A literatura tem demonstrado os efeitos econômicos da poluição atmosférica sobre dois pontos: o custo da poluição e o benefício da despoluição. O primeiro se relaciona ao custo associado principalmente aos efeitos à saúde humana, ou seja, os recursos de saúde gastos para tratar as pessoas que adquiriram doenças por respirar um ar poluído. Já o segundo ponto se refere aos benefícios econômicos decorrentes da implantação de alguma medida para prevenir ou regular a poluição atmosférica (SILVA; LIMA, 2006; BRAJER et al., 2012; POZZER et al., 2012; XIA et al., 2014).

Nesse sentido, Christopherson (2012) mostra que o evento histórico ocorrido em Londres no ano de 1952 causou um prejuízo em torno de 250 milhões de libras esterlinas. O mesmo autor destaca que em 1913 nos EUA o custo anual da poluição do ar foi estimado em 20 dólares por

habitante. Em São Paulo, Branco e Walsh (2005) divulga que os custos ambientais e sociais ligados à frota de veículos a diesel podem chegar a ser 800 milhões de reais por ano. E no Brasil, conforme a Tabela 1, o custo chega a passar de R\$19.000,00 por cada tonelada de emissão de MP.

Tabela 1 - Custo da poluição no Brasil por tonelada e poluente lançado.

Poluente	R\$ / tonelada de emissão
CO	727
HC	3.221
NOx	3.728
MP	19.062
SOx	14.185
CO2	116

Fonte: Vasconcellos (2006).

Além do custo relacionado à saúde humana, alguns estudos investigaram os efeitos econômicos da poluição do ar em outras variáveis, por exemplo, na agricultura. Devido o impacto no metabolismo vegetal, a concentração elevada de O<sub>3</sub> tem inviabilizado a produção de algumas safras na Grécia (VLACHOKOSTAS et al., 2010).

Em relação aos benefícios econômicos decorrentes da implantação de políticas ambientais, Christopherson (2012) destaca a criação do Decreto do Ar Limpo - DAL pelo governo americano. Foi gasto em torno de 523 bilhões de dólares para implantar todos os regulamentos do DAL durante o período de 1970 a 1990. No entanto, estima-se que os benefícios dessa implantação foram de 21,7 trilhões de dólares. Vale destacar que todo o regulamento do DAL foi revisto após o primeiro estudo de *Harvard six cities*.

## 1.2 SAÚDE AMBIENTAL

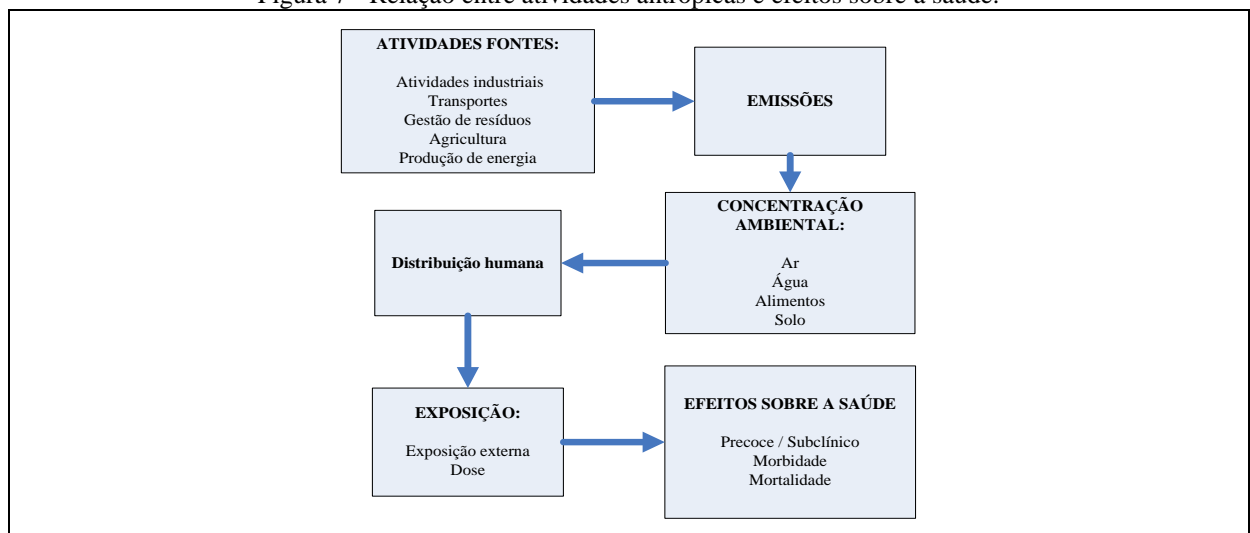
Segundo a Organização Mundial da Saúde (OMS), saúde ambiental é definida como as consequências na saúde humana em decorrência da interação humana com o meio ambiente. Entende-se aqui como meio ambiente o preservado (meio ambiente natural), o transformado pelo homem (por exemplo, uma cidade) e as interações sociais. A OMS ainda define que a saúde ambiental é uma área que se refere às abordagens teóricas e práticas para valorar, corrigir e controlar os fatores ambientais com potencial para prejudicar a saúde de gerações atuais e futuras (OMS, 2013).

A ocorrência de doenças nas pessoas é um dos exemplos das consequências da interação humana com o meio ambiente. Dessa forma, as pesquisas com objetivo de avaliar a ocorrência de uma doença sobre uma determinada população são consideradas como estudos epidemiológicos, ou especificamente, estudos na área de epidemiologia ambiental (WANG, 2002; NATAL, 2004).

### 1.2.1 EPIDEMIOLOGIA AMBIENTAL

Dentre os estudos em epidemiologia ambiental, citam-se os que consideram as ações antrópicas no meio ambiente como objeto de estudo. As atividades humanas podem gerar, por exemplo, poluição nos recursos hídricos, geração de resíduos sólidos, proliferação de vetores, geração de ruídos e poluição atmosférica (SMITH; KRIEBEL, 2010). A Figura 7 apresenta um fluxo de causa e efeito mostrando as relações entre atividades antrópicas e efeitos sobre a saúde.

Figura 7 - Relação entre atividades antrópicas e efeitos sobre a saúde.



Fonte: Ministério da Saúde (2011), com edição.

Conforme a Figura 7, vê-se que as emissões oriundas das atividades antrópicas e concentradas nos diferentes componentes ambientais podem impactar a saúde humana. Esse impacto é apontado principalmente pela morbidade e mortalidade das pessoas. Manigrasso e Avino (2012) e Lipfert e Murray (2012) mostram que os efeitos sobre a saúde humana podem ser indicados pelo número de internações hospitalares, o número de atendimentos hospitalares e o número de óbitos. Destaca-se que o tópico relacionado especificamente à exposição humana (apresentado na Figura 7) será tratado no item 1.2.1.2 desta tese.

Diante desse contexto, as pesquisas epidemiológicas podem ser classificadas em cinco categorias, que são:

- a) estudo *cross-seccional*: são estudos descritivos. Grupos são estudados em um período de tempo para descobrir a relação entre exposição e a doença mensurada. A exposição e a condição de saúde são determinadas simultaneamente (TANG et al., 2001; MOODLEY et al., 2011; NANDASENA et al., 2012; BHANGAR et al., 2013; GONZALEZ-BARCALA et al., 2013);
- b) estudo ecológico: são descritivos e analíticos. Cada unidade de análise são grupos de pessoas comparadas com a exposição do próprio indivíduo. Portanto, vale destacar que a unidade de análise é a população e não o indivíduo (ENVIRONMENTAL PROTECTION AGENCY, 2004; LIN, H. et al., 2013);
- c) estudo de cortes: um grupo de indivíduos é classificado a partir das características pessoais, como sexo, idade, peso, etc. (SOLOMON et al., 2011);
- d) estudo *time series*: um grupo é avaliado em momentos temporais específicos (BAKONYI et al., 2004; ZANOBETTI; SCHWARTZ, 2009; CHIEN; BANGDIWALA, 2012; VALDÉS et al., 2012);
- e) estudo de caso-controle: é um estudo analítico no qual dois grupos são divididos. Aqueles que possuem doenças específicas e aqueles que não têm a doença - o controle (ENVIRONMENTAL PROTECTION AGENCY, 2004; SOLOMON et al., 2011).

O estudo clássico em epidemiologia ambiental foi desenvolvido por John Snow em 1855 (SNOW, 1936) – considerado o pai da epidemiologia moderna. John Snow verificou por meio de um estudo ecológico a relação entre água poluída e ocorrência de cólera na cidade de Londres. Os resultados mostraram que a qualidade da água consumida pela população da capital inglesa estava diretamente associada à ocorrência de cólera. Nesse caso, a qualidade da água

era determinada por três companhias de saneamento, nas quais forneciam água para a população na época. John Snow identificou que duas dessas companhias forneciam água extremamente poluída. Portanto, o grupo populacional que consumia água dessas duas companhias, apresentava maior risco de ter cólera.

A condução das análises feita por John Snow considerando as três companhias de saneamento é conceituada como análise com (co-variáveis), o que é considerado de grande importância nos estudos epidemiológicos.

### **1.2.1.1 Co-variáveis em epidemiologia (variáveis controle)**

Co-variável em epidemiologia é definida como a influência de um terceiro fator na relação entre exposição e ocorrência da doença. As co-variáveis devem ter três características em um estudo: deve ser associada com a doença, deve ser associada com a exposição considerando a população estudada como o todo, e deve representar a relação casual entre exposição e doença (SMITH; KRIEBEL, 2010).

As co-variáveis tem a função de controlar o estudo, evitando-se assim qualquer viés relacionado à análise. Há quatro formas de controlar o estudo utilizando as co-variáveis: por meio do processo de randomização; restringindo o estudo em subgrupos; estratificando os dados; e, o mais comum nos estudos epidemiológicos, introduzindo a co-variável como uma variável preditora nos modelos (SZKLO; NIETO, 2000).

As pesquisas em epidemiologia ambiental têm utilizado frequentemente co-variáveis relacionadas à faixa etária, ao gênero, à renda, à densidade demográfica, à predisposição genética como forma de controlar o estudo (PHALEN, 2012b; WAI et al., 2013). A seguir serão detalhados alguns resultados já divulgados pela literatura, nos quais os estudos foram controlados com base nessas co-variáveis. Os resultados apresentados a seguir serão específicos à poluição atmosférica, pois é o objeto de análise da presente tese.

#### **1.2.1.1.1 Faixa etária**

As crianças e os idosos são o grupo etário que mais sofre com os efeitos de respirar um ar poluído (RIBEIRO; CARDOSO, 2003; ARBEX et al., 2012; GRIGG, 2012; MORTIMER et al., 2012; LEIVA et al., 2013). Por exemplo, Mortimer et al. (2012) estimam que 500 mil crianças no mundo de até 5 anos morrem anualmente em decorrência da poluição atmosférica.

Outro exemplo é apresentado por Vasconcellos (2006), no qual foi identificado que na região metropolitana de São Paulo o acréscimo de  $100 \mu\text{g}/\text{m}^3$  de  $\text{MP}_{10}$  gera um aumento de 13% do risco de pessoas acima de 65 anos morrerem. Wai et al. (2013) mostram ainda que há um risco relativo de 1,22% do aumento do número de internações de crianças e idosos para cada acréscimo de  $10 \mu\text{g}/\text{m}^3$  do  $\text{MP}_{2,5}$ .

#### 1.2.1.1.2 Gênero

Algumas pesquisas identificaram que as mulheres se encontram mais vulneráveis à poluição do ar devido às condições de exposição que elas se encontram. É o caso dos ambientes internos - *indoor* de poluição, sobretudo, as cozinhas residenciais. As mulheres estão mais presentes nesses ambientes que os homens (MAKRI; STILIANAKIS, 2008; SINGHE; JAMAL, 2012b; MIRAGLIA et al., 2013; GONZALEZ-BARCALA et al., 2013).

#### 1.2.1.1.3 Renda

A renda tem sido considerada como uma importante co-variável nos estudos epidemiológicos (SZKLO; NIETO, 2000). Resultados mostram que as pessoas que moram em casas com infraestrutura precária estão mais expostas aos efeitos da poluição atmosférica, pois a infraestrutura precária possibilita uma maior interação entre os ambientes de poluição *indoor* e *outdoor* (LEE et al., 2004).

Outro exemplo quanto à renda é apresentado por Mondal et al. (2011). Os autores mostram que as comunidades carentes ainda utilizam para cozinhar os alimentos as fontes com um maior potencial poluidor, como a lenha ou querosene.

Outra observação é que os bairros de baixa renda geralmente estão localizados em regiões próximas às fontes de emissão (SINGHE; JAMAL, 2012b; BRANIS; LINHARTOVA, 2012).

#### 1.2.1.1.4 Densidade demográfica

A densidade demográfica é considerada como uma importante co-variável nas avaliações entre poluição do ar e saúde humana (VALDÉS et al., 2012). A principal ideia é que à maior densidade de pessoas demanda um maior fluxo de interações entre atividades humana e meio ambiente, o que conseqüentemente está associado com a questão da saúde humana (LAMSAL et al., 2013).

#### 1.2.1.1.5 Predisposição genética

A principal hipótese da predisposição genética é que as pessoas que passam a vida respirando um ar poluído podem gerar heranças de DNA modificados aos filhos (SOLOMON et al., 2011; ARBEX et al., 2012).

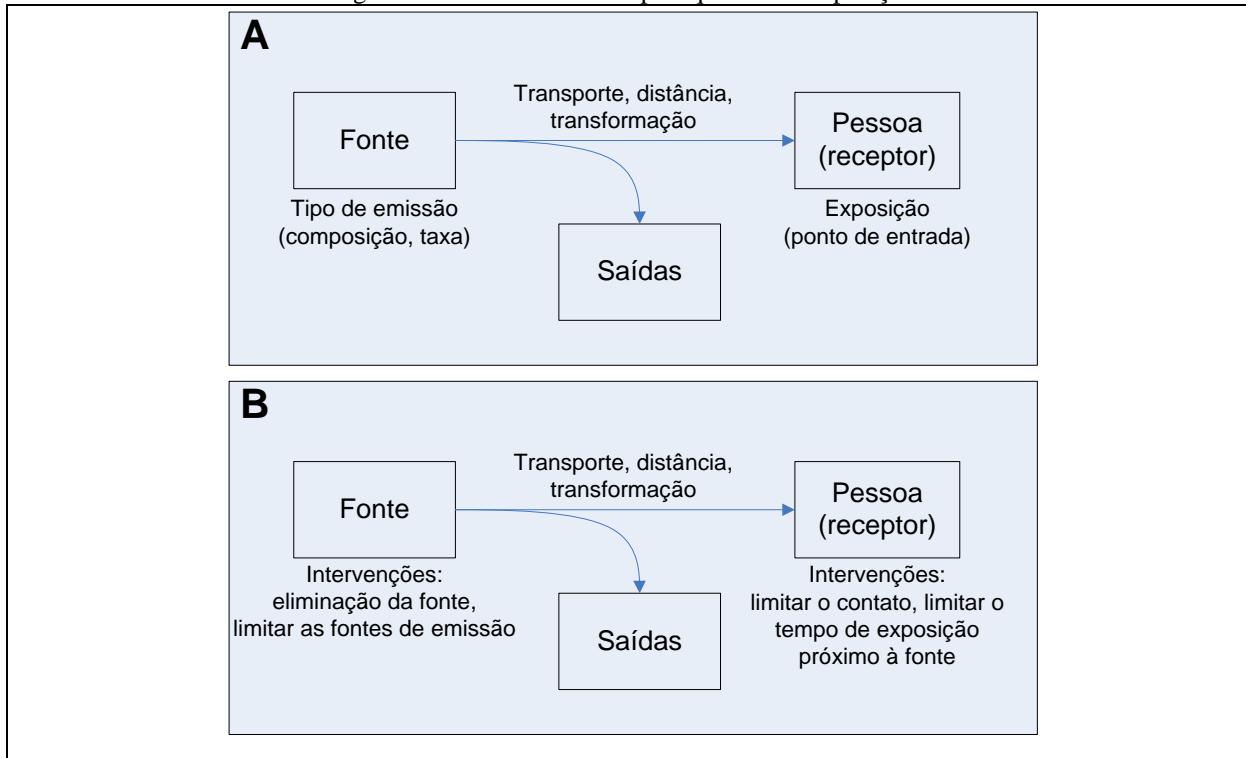
#### 1.2.1.2 Avaliação da exposição humana em epidemiologia

Exposição é definido em quatro dimensões: composição, forma física (sólido, gás, líquido, particulado etc.), concentração ambiental (intensidade) e duração. Essas dimensões estão relacionadas a um agente definido em um ponto de entrada no corpo humano. Considera-se como agente definido as bactérias, a radiação, o ruído, a poluição do ar etc. Nas avaliações da exposição humana em epidemiologia ambiental os agentes tem um mensuramento quantitativo que define a intensidade e duração que se relacionam com o risco de agravo à saúde humana (SZKLO; NIETO, 2000).

Especificamente quanto à poluição do ar como um agente, as estações de monitoramento é o método utilizado para o mensuramento da exposição. Nesse caso, as estações mensuram à exposição local (uma área fixa), o que determina a exposição da população. Por outro lado, os equipamentos portáteis de monitoramento determinam a exposição pessoal (SMITH; KRIEBEL, 2010).

Wang (2002) mostra que a exposição pode ser exemplificada pelo modelo de fonte-receptor. Os agentes são considerados como as fontes, por exemplo a poluição do ar, e as pessoas que estão respirando o ar poluído são os receptores. A Figura 8 apresenta a representação do modelo fonte-receptor em duas situações hipotéticas. A primeira sobre modelo fonte-receptor do processo que define exposição; e a segunda sobre as intervenções para eliminar a fonte ou reduzir a exposição do receptor.

Figura 8 - Modelo fonte-receptor que define exposição.



Fonte: Wang (2002), com edição.

Nota: modelo fonte-receptor do processo que define exposição (A); intervenções para eliminar fonte ou reduzir a exposição do receptor (B).

Wang (2002) ainda mostra que o receptor (a pessoa) pode receber o poluente lançado pela fonte por meio de três tipos de exposição: exposição por inalação (por exemplo a poluição do ar), exposição por ingestão (por exemplo um alimento) e exposição por pele (por exemplo a radiação solar).


### 1.2.1.3 Epidemiologia espacial

Natal (2004) e o Ministério da Saúde (2011) mostram que a análise espacial nas pesquisas em epidemiologia ambiental fornece uma maior precisão e acurácia na estimação dos riscos associados à saúde humana. A variação do risco está fortemente ligada às mudanças espaciais.

O estudo de John Snow em 1855 (SNOW, 1936) teve indiretamente uma observação espacial. John Snow observou que a ocorrência de cólera em Londres tinha uma distribuição espacial do tipo *cluster*, o que indica a presença de um fator comum na região identificada como *cluster*. A Figura 9 apresenta o mapa produzido por John Snow mostrando o agrupamento espacial dos casos de cólera em Londres.



Figura 9 - Agrupamento espacial da ocorrência de cólera em Londres, 1855.

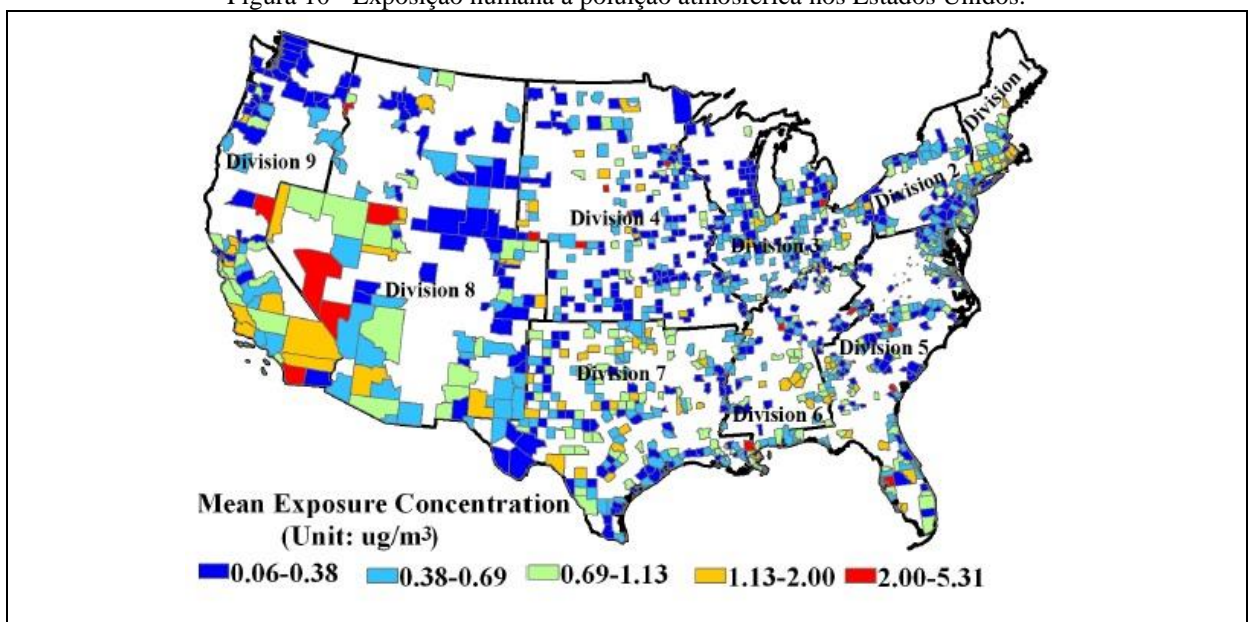


Fonte: Snow (1936), com edição.

Nota: círculo vermelho mostra o *cluster* da ocorrência de cólera.

Atualmente, com o desenvolvimento das geotecnologias veio o aperfeiçoamento das análises espaciais, sobretudo em relação à capacidade de processamento de um conjunto maior de informações geográficas, até como a produção de mapas mais elaborados que o produzido por John Snow. Por exemplo, Zou et al. (2014) apresentaram uma análise da exposição humana à poluição atmosférica nos Estados Unidos (Figura 10).

Figura 10 - Exposição humana à poluição atmosférica nos Estados Unidos.



Fonte: Zou et al. (2014).

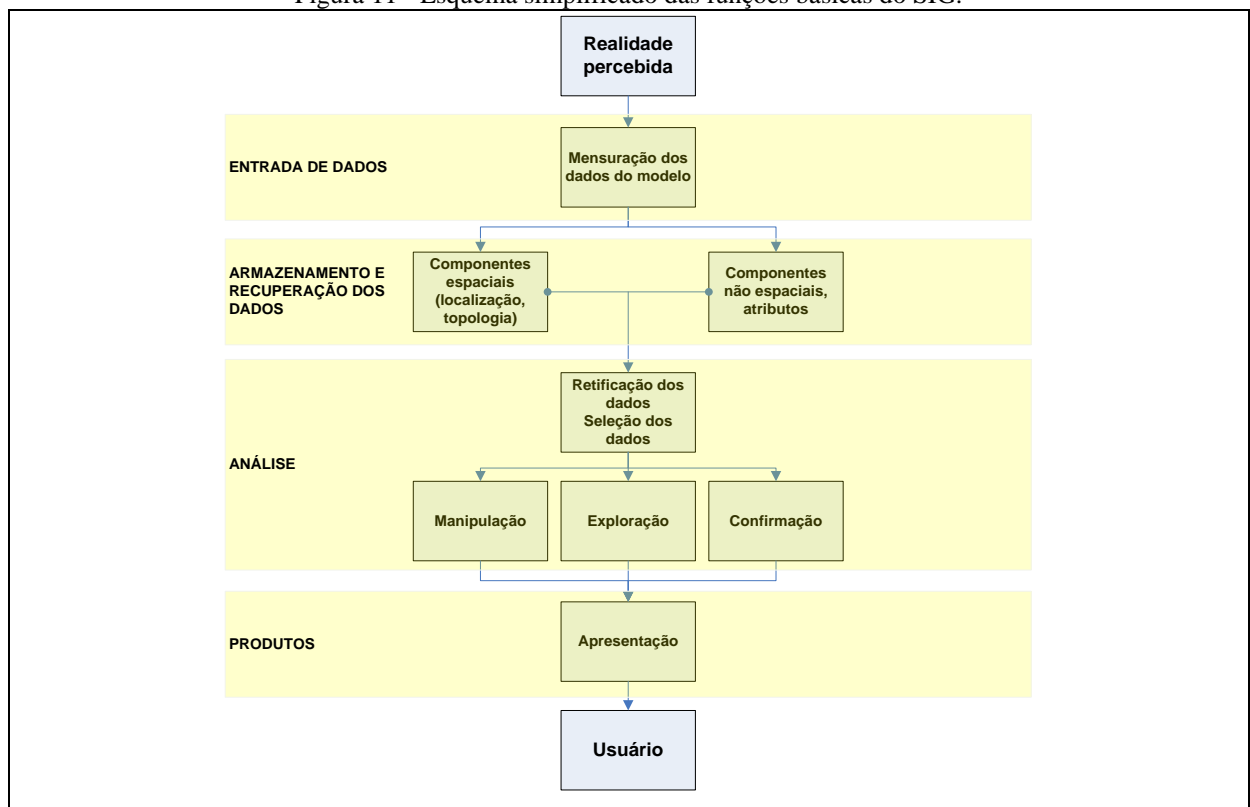
Nota: média da concentração da exposição (mean exposure concentration): unidade (unit); divisão (division).

Com o desenvolvimento das análises espaciais, não só em epidemiologia, mas em todas as disciplinas acadêmicas, foi consolidada a área científica em Sistemas de Informações Geográficas (SIG). Os conhecimentos já agregados a essa área do saber são os que possibilitam uma análise espacial de maior robustez, conforme apresentado pelo mapa na Figura 10.

#### 1.2.1.3.1 SIG nas análises em epidemiologia espacial

O uso do SIG teve início na década de 1960. Desde então, a técnica veio sendo aperfeiçoada por meio dos constantes estudos (CHRISTOFOLETTI, 1999; CÂMARA et al., 2001; LONGLEY et al., 2013). Conforme a Figura 11, a entrada de dados, o armazenamento e a recuperação dos dados, a análise e os produtos configuram um esquema simplificado das funções básicas do SIG (CHRISTOFOLETTI, 1999; SILVA; ZAIDAN, 2011).

Figura 11 - Esquema simplificado das funções básicas do SIG.



Fonte: Christofolletti (1999), com edição.


O conjunto das funções básicas que configuram o SIG (Figura 11) gera um produto – o resultado do modelo, no qual o usuário pode se orientar nas tomadas de decisões. Esse produto é dependente da maneira pela qual a realidade foi percebida pelo modelador, ou seja, a qualidade

dos dados de entrada do modelo influenciará no resultado final da modelagem. Portanto, vale destacar que todo o processo da entrada dos dados até a geração dos produtos pode ser operado atualmente com o auxílio de softwares para SIG (CÂMARA et al., 2001).

A popularização dos softwares para SIG facilitou o uso de algumas técnicas para a modelagem espacial das informações geográficas. Essas técnicas podem ser exemplificadas pela interpolação espacial, pelos modelos de densidade, pelas análises de proximidade e pela álgebra de mapas. Além disso, os softwares em SIG possibilitaram o desenvolvimento e aplicação das análises em geoestatística. A operação matemática dessas técnicas e análises sem um auxílio computacional dos softwares inviabilizaria os estudos com grandes quantidades de dados (SINGH; KUMAR, 2012).

Como exemplo, cita-se o estudo de Moral et al. (2012), nos qual os autores apresentam um variograma experimental referente à exposição ao O<sub>3</sub> em uma região na Espanha (Figura 12). As funções variogramas são conhecidas por medirem a variância entre pontos separados por uma distância  $h$ . Com isso, em teoria, os pontos próximos apresentam uma menor variância que os pontos mais distantes. A tendência em muitos casos é que a variância venha a se estabilizar em torno da variância máxima a partir de certa distância (YAMAMOTO; LANDIM, 2013).

Figura 12 - Variograma experimental para a exposição ao O<sub>3</sub>.



Fonte: Moral et al. (2012).

Por fim, destaca-se que todo o processo de estudo da exposição espacial do ser humano à alguma influência antrópica ou natural é visto como modelos ambientais (GERHARZ et al., 2013; BEEVERS et al., 2013; LAMSAL et al., 2013). Especificamente no caso tratado por esta tese, são modelos espaciais da exposição humana às fontes de poluição do ar. O item 1.3 descreve os principais conceitos do processo de modelagem ambiental.

### 1.3 MODELAGEM AMBIENTAL

A modelagem é uma técnica utilizada para representar fenômenos que ocorrem no mundo real. Essa realidade é representada com base na observação humana, e não exatamente como o fenômeno ocorre. Em um contexto geral para os estudos ambientais, os modelos podem ser classificados em matemáticos, modelos de sistemas, modelos preditivos e modelos gráficos (CHRISTOFOLETTI, 1999).

Os modelos matemáticos são aqueles apresentados em forma de equação. Um exemplo comum são os modelos de regressão. Já os modelos de sistemas procuram representar de maneira lógica o funcionamento de um determinado sistema, com os respectivos fluxos de entradas, saídas e retroalimentações. Os modelos preditivos têm o objetivo principal de prever a evolução do sistema com base na variação de parâmetros e valores de variáveis. E os modelos gráficos, ou modelos de desenho experimental, representam a estrutura de um determinado espaço geográfico (CHRISTOFOLETTI, 1999; HABERMANN; GOUVEIA, 2012; MOZUMDER et al., 2012). Quanto aos modelos matemáticos, destaca-se que ainda podem ser subdivididos em três classes (CHRISTOFOLETTI, 1999). Seguem:

- a) determinísticos: são baseados em noções clássicas de matemática. As relações entre as variáveis dependentes e independentes são previsíveis. Esses modelos geralmente se baseiam nas pressuposições sobre as leis de fenômenos físicos e químicos;
- b) probabilísticos ou estocásticos: as variáveis e os parâmetros envolvidos nos modelos são imprevisíveis. Destaca-se que esses modelos são as bases para a simulação;
- c) otimização: tem a característica de avaliar a maximização ou a minimização de alguma força ou critério presente no modelo, como por exemplo, o estado de entropia máxima, o estado de eficiência máxima, os custos mínimos.

Christofoletti (1999) mostra também que os modelos podem ser constituídos de algumas características básicas como, seletividade, simplicidade, reaplicabilidade. Além dessas características, os modelos ainda podem atender às funções do tipo psicológica, comunicativa, promissora, de previsibilidade, de simulação, e de condensação temporo-espacial. Quanto a esse último, a relevância se concentra pela abertura de possibilidades para entender o fenômeno avaliado em diferentes escalas temporais e espaciais. Por exemplo, nos modelos de poluição

atmosférica, as condições do espaço e do tempo podem determinar a característica das fontes de emissão, o tempo de permanência dos gases e partículas na atmosfera, e conseqüentemente, a concentração modelada dos poluentes (ZHOU; LEVY, 2007; PIRJOLA et al., 2012; GERHARZ et al., 2013).

Outro ponto importante sobre a modelagem é em relação à aplicação. Os métodos atuais de modelagem evoluíram ao ponto de abrirem possibilidades para serem aplicados em áreas multidisciplinares (MOREIRA; TIRABASSI, 2004). Por exemplo, modelos criados por administradores e economistas podem ser adaptados para uma aplicação específica na área ambiental, cita-se o *Analytic Hierarchy Process - AHP* (ABREU et al., 2000; GARTNER, 2001; FONTANA et al., 2013). Por outro lado, modelos que inicialmente foram criados para a área ambiental, também podem ser aplicados na economia, na gestão pública, na saúde; citam-se os modelos em Sistemas de Informações Geográficas - SIG (VLACHOKOSTAS et al., 2010; SHAH, 2012).

### 1.3.1 MODELAGEM EM POLUIÇÃO DO AR E SAÚDE HUMANA

Inicialmente, destaca-se que os modelos descritos por este item 1.3.1 são considerados estudos em epidemiologia ambiental, e que muitos consideram as análises em SIG. A descrição nesse item é somente como forma de consolidar os conceitos e aplicações do processo de modelagem ambiental.

Jerrett et al. (2005) sugerem cinco categorias que representam a modelagem específica para o tema poluição atmosférica e saúde humana: os modelos de proximidade, os modelos de interpolação estatística ou dispersão, os modelos de inalação humana, os modelos de regressão em uso do solo (*land use regression*) e os modelos híbridos.

#### 1.3.1.1 Modelos de Proximidade

Os modelos de proximidade são conhecidos por mensurar a proximidade da presença humana às fontes de poluição. Um exemplo são os estudos que avaliam a proximidade das áreas residenciais às rodovias, às fábricas etc. Nesse caso, um indicador epidemiológico é a ocorrência de doenças respiratórias (ZOU et al., 2009). Pode-se citar o estudo realizado por Brender et al. (2008), no qual os autores identificaram que as mulheres acima de 35 anos que vivem até uma milha das indústrias do Texas - EUA possuem duas vezes mais chance de sofrer

doenças respiratórias. Como outros exemplos de estudos, destacam-se os desenvolvidos por Thepanondh e Toruksa (2011), Rundell (2012), Buonanno et al. (2012).

Destaca-se que ainda foi pouco explorado nas análises de proximidade o estudo do decaimento da exposição humana em função da distância das fontes de emissão.

### **1.3.1.2 Modelos de interpolação estatística ou dispersão**

Os modelos de interpolação estatística ou dispersão são geralmente integrados aos modelos clássicos de dispersão de poluentes atmosférico, como o gaussiano, o Aermol, o Cmaq, mas que há o acréscimo da variável saúde humana no processo de modelagem. Por consequência, abre-se uma oportunidade para uma análise de alta resolução para os fatores de saúde e poluição atmosférica (ZOU et al., 2009). Pode-se citar como estudos já realizados o que foi desenvolvido por Yim et al. (2013), em que foi avaliado a dispersão dos poluentes atmosféricos decorrentes dos aeroportos da Inglaterra e os respectivos efeitos à saúde humana. Exemplos de outros estudos que utilizaram modelos de dispersão foram desenvolvidos por Fan et al. (2012), Beevers et al. (2013), Verstraeten et al. (2015).

### **1.3.1.3 Modelos de inalação humana**

Esse tipo de modelo trabalha com uma escala individual, ou seja, é levada em consideração a dose que cada pessoa tem por respirar um ar poluído. Nesse sentido, uma variável importante de entrada no modelo é o conhecimento sobre as atividades das pessoas que estão sendo avaliadas (ZOU et al., 2009). Destaca-se que os instrumentos portáteis são os usuais para o levantamento das informações referentes às doses de cada pessoa. Como exemplo de estudos, vale citar o desenvolvido por Buonanno e Giorgio et al. (2013), em que foi avaliada a exposição diária aos gases e partículas de 103 crianças em uma região na Itália. Foi identificado que o período em que as crianças estavam indo para escola a pé foi o de maior exposição à poluição atmosférica. Outro estudo semelhante com avaliação das doses inaladas por crianças foi desenvolvido por Borgini et al. (2011), porém, nesse, os autores avaliaram somente a exposição ao MP<sub>2.5</sub>. Demais estudos que utilizaram os modelos de inalação humana foram desenvolvidos por Hertel et al. (2001), Lee et al. (2004), Fan et al. (2012), Meng et al. (2012), Gerharz et al. (2013), Beevers et al. (2013).

### 1.3.1.4 Modelos land use regression

O modelo *Land Use Regression (LUR)* tem sido um dos mais utilizados nos últimos estudos em epidemiologia ambiental. O modelo considera os conceitos de regressão múltipla para a realização das análises. Variáveis independentes, como, tráfego de veículos, topografia, umidade, temperatura, velocidade do vento, uso do solo e densidade demográfica podem compor o modelo para prever a concentração de um determinado poluente atmosférico. A fórmula matemática generalizada que representa o LUR é apresentada pela Equação 1 (WANG et al., 2013).

$$Y = \alpha + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \beta_3 \cdot X_3 + \dots + \beta_n \cdot X_n$$

Equação 1

Em que, Y é a concentração de um determinado poluente – a variável dependente;  $\alpha$  o coeficiente linear do modelo;  $\beta_1, \beta_2, \beta_3 \dots \beta_n$  são os respectivos coeficientes das variáveis independentes; e  $X_1, X_2, X_3 \dots X_n$  são as variáveis independentes.

Um estudo desenvolvido para a região metropolitana de São Paulo identificou que o LUR foi capaz de explicar mais de 60% da variabilidade espacial da concentração de  $MP_{10}$  (HABERMANN; GOUVEIA, 2012). Outro estudo em 36 países europeus identificou que o modelo LUR explica em média 82% do  $NO_2$  e 78% do  $NO_x$  (BEELEN et al., 2013). Outro resultado encontrado com a aplicação do LUR foi com o estudo de So e Wang (2003), em que os autores avaliaram a concentração do  $O_3$  nas áreas urbanas e rurais de Hong Kong e identificaram que a concentração de  $O_3$  nas áreas rurais estava sendo influenciada pelas áreas urbanas. Outros trabalhos que utilizaram o LUR podem ser encontrados em Kanaroglou et al. (2005), Ryan e Lemasters (2007), Rosenlund e Forastiere et al. (2008), Su, J. G. et al. (2009), Madsen et al. (2011), Rivera et al. (2012), Singh e Kumar (2012), Mukerjee et al. (2012).

Diante do exposto, o LUR é utilizado frequentemente para prever a concentração de algum poluente. Em seguida é avaliada a exposição humana em função da concentração do poluente estimado no modelo. Destaca-se que ainda foi pouco explorado nas análises do LUR o uso de alguma variável relacionada aos efeitos na saúde humana (por exemplo, ocorrência de doença) como resposta direta no modelo.

### **1.3.1.5 Modelos híbridos**

Os modelos híbridos são conhecidos por combinarem os diferentes tipos de processo de modelagem, por exemplo, os modelos de proximidade juntamente com os modelos de inalação (ZOU et al., 2009). Ou exemplo é o estudo de Beevers et al. (2013), no qual os autores avaliaram a dispersão e as proximidades das fontes de emissão que colocam em risco a saúde das pessoas na Inglaterra.

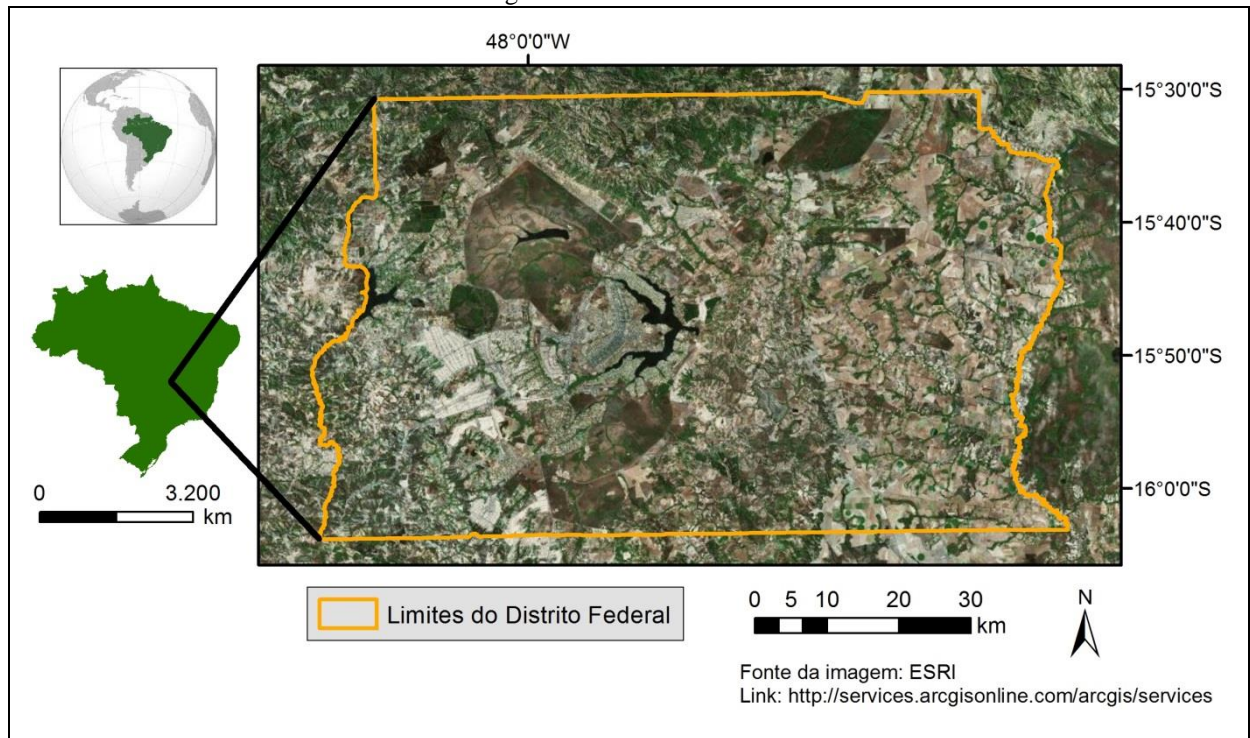


## Capítulo 2 - Área de estudo, variáveis e ferramentas

### 2.1 ÁREA DE ESTUDO

O estudo foi realizado na região do DF, localizada nos paralelos de 15° 30' e 16°03' de latitude Sul e os meridianos de 47° 25' e 48° 12' de longitude Oeste. A área total ocupada pela região é de 5.814 km<sup>2</sup> (IBGE, 2013). A Figura 13 apresenta a localização do DF.

Figura 13 - Área de estudo.



Fonte: Produção do próprio autor.

A Secretaria de Desenvolvimento Urbano e Meio Ambiente do DF (Seduma) mostra que desde o ano de 2000, a área urbana do DF já cresceu em torno de 30%. Esse crescimento é visto principalmente pelo processo de conurbação urbana entre as 31 regiões administrativas que compõem todo o DF. Atualmente, pode-se destacar que os principais vetores de urbanização agregado ao crescimento populacional do DF estão na direção Sul, Oeste e Nordeste (SEDUMA, 2009).

O DF possui uma população estimada em 2,8 milhões de pessoas. Desse contingente populacional, em torno de dois milhões são classificados como população residente da área urbana. O crescimento demográfico do DF é de 2,82 % ao ano. Prevê-se que até o ano de 2030 a população total excederá 3,7 milhões de pessoas. Destaca-se ainda que a densidade demográfica do DF é de 444,66 habitantes / km<sup>2</sup>. O principal desafio do elevado crescimento populacional do DF é com o planejamento urbano, no qual impacta diretamente os sistemas de transporte, a qualidade ambiental, a saúde pública (IBGE, 2013).

O Índice de Desenvolvimento Humano (IDH) do DF está acima do IDH nacional. O IDH do DF é de 0,824 enquanto que o do Brasil é de 0,744. Especificamente quanto à renda da população urbana, o DF tem um valor de rendimento médio mensal per capita igual a 2.097,83 reais (IBGE, 2013).

Todo esse contexto urbano do DF se encontra no bioma Cerrado. O relevo predominante é caracterizado pelas áreas planas e elevadas, colinas arredondadas e chapadas intercaladas por escarpas. A altitude da região tem uma variação entre 600 a 1 350 m.

Quanto ao clima, o Instituto Nacional de Meteorologia (Inmet) apresenta que há predominância na região do clima tropical sazonal, tendo uma estação chuvosa e quente e outra estação fria e seca. A temperatura média anual na região é em torno de 21°C, sendo que o mês de agosto a outubro concentram as maiores temperaturas. As menores temperaturas ocorrem durante o período de maio a julho (Tabela 2).

Tabela 2 - Temperatura no DF no decorrer dos meses (°C).

	Jan.	Fev.	Mar.	Abr.	Mai.	Jun.	Jul.	Ago.	Set.	Out.	Nov.	Dez.	MÉDIA
med.	21,6	21,8	22,0	21,4	20,2	19,1	19,1	21,5	22,5	22,1	21,7	21,5	21,2
max.	26,9	26,7	27,1	26,6	25,7	25,2	25,1	27,3	28,3	27,5	26,6	26,2	26,6
min.	17,4	17,4	17,5	16,8	15,0	13,3	12,9	14,6	16,0	17,4	17,5	17,5	16,2

Fonte: Inmet (2012).

Nota: temperatura média (med.); temperatura máxima (max.); temperatura mínima (min.).

A umidade relativa do ar varia entre 49 a 79% durante o ano. As máximas são atingidas nos meses de novembro a abril. Já os períodos mais secos estão concentrados nos meses de julho a setembro (Tabela 3).

Tabela 3 - Média mensal da umidade relativa do ar no Distrito Federal (%).

Jan.	Fev.	Mar.	Abr.	Mai.	Jun.	Jul.	Ago.	Set.	Out.	Nov.	Dez.
76,0	77,0	76,0	75,0	68,0	61,0	56,0	49,0	53,0	66,0	75,0	79,0

Fonte: Inmet (2012).

A precipitação média anual no DF tem variação entre 1 200 a 1 800 milímetros. Os meses de novembro a fevereiro são destacados por concentrarem os maiores volumes de chuva. Vale ressaltar que no período seco, pode ficar mais de 90 dias sem chuva na região (INMET, 2012). Essas condições associadas às características do bioma Cerrado intensificam o surgimento de queimadas florestais na região, o que se caracteriza como uma fonte importante de poluição atmosférica (apresentado no Capítulo 1). O número de focos de queimadas anuais no DF pode ultrapassar de 500, conforme o Instituto Nacional de Pesquisas Espaciais (INPE, 2013).

Outra significativa fonte de poluição atmosférica, conforme apresentado no Capítulo 1, são os veículos automotores. Em 2014 o DF apresentou um total aproximado de 1,6 milhões de veículos. Desses, 72% são veículos do tipo leve, 11% motocicletas e 17% veículos pesados. A taxa anual de crescimento da frota de veículos no DF é de 4,5% (DENATRAN, 2015).

Quanto às informações de saúde, especificamente para as doenças do sistema cardiorrespiratório (importante indicador de exposição humana à poluição do ar, conforme apresentado no Capítulo 1), em torno de 27% das internações no DF são devido às doenças cardiorrespiratórias. Em relação aos óbitos, 36% são em decorrência de doenças do sistema cardiorrespiratório. Durante o período de 2008 a 2014 no DF, 400 mil pessoas foram internadas e 15 mil morreram por causas de doenças cardiorrespiratórias (DATASUS, 2015).

## 2.2 VARIÁVEIS DA PESQUISA

Um total de 17 variáveis foram utilizadas para a realização desta tese. Dentre essas variáveis, nove passaram por processamentos. Os processamentos são caracterizados em: criação de variáveis com base em dados secundários, ou edição/tratamento de dados não espaciais com objetivo de incluir a informação espacial.

Onze fontes foram acessadas para aquisição dos dados que representam cada variável - Departamento de Informática do Sistema Único de Saúde (DATASUS), Secretaria de Estado de Gestão do Território e Habitação do DF (SEDHAB), Departamento de Trânsito do DF (DETRAN), Departamento de Estradas e Rodagem (DER), Governo do Distrito Federal (GDF),

Instituto Brasileiro de Geografia e Estatística (IBGE), Secretaria de Educação do DF (SEDF), Companhia de Saneamento Ambiental do DF (CAESB), Instituto Nacional de Pesquisas Espaciais (INPE), Secretaria de Transporte Urbano do DF (DFTRANS) e Instituto Brasília Ambiental (IBRAM).

O Quadro 1 apresenta os detalhes de cada variável. Como complemento, a Figura 14 reapresenta os objetivos específicos da tese (separados por Capítulos) e o fluxo dos dados de entrada primários e secundários. Considerou-se nesta tese como dados primários aqueles que foram utilizados diretamente da fonte de consulta (em alguns casos houve necessidade de um processamento). Já os dados secundários foram aqueles decorrentes dos resultados de um prévio objetivo específico desta tese.

O Apêndice C exibe a representação espacial de cada uma das 17 variáveis utilizadas nesta pesquisa. Destaca-se que os mapas apresentados no Apêndice C são referentes ao formato final da variável, ou seja, após o processamento (quando necessário).

Especificamente quanto à representação espacial das variáveis, destaca-se que todas as 17 variáveis foram transportadas para um banco de dados em SIG. Foi adotado para o banco de dados o sistema de projeção em Universal *Transverse Mercator* (UTM), América do Sul, SIRGAS 2000 UTM Zone 23S. Por fim, foi criado um metadados individual para cada uma das 17 variáveis. Os metadados foram criados no formato ISO 19139 *Metadata Implementation Specification GML 3.2*.

Quadro 1 - Variáveis da pesquisa.

(Continua)

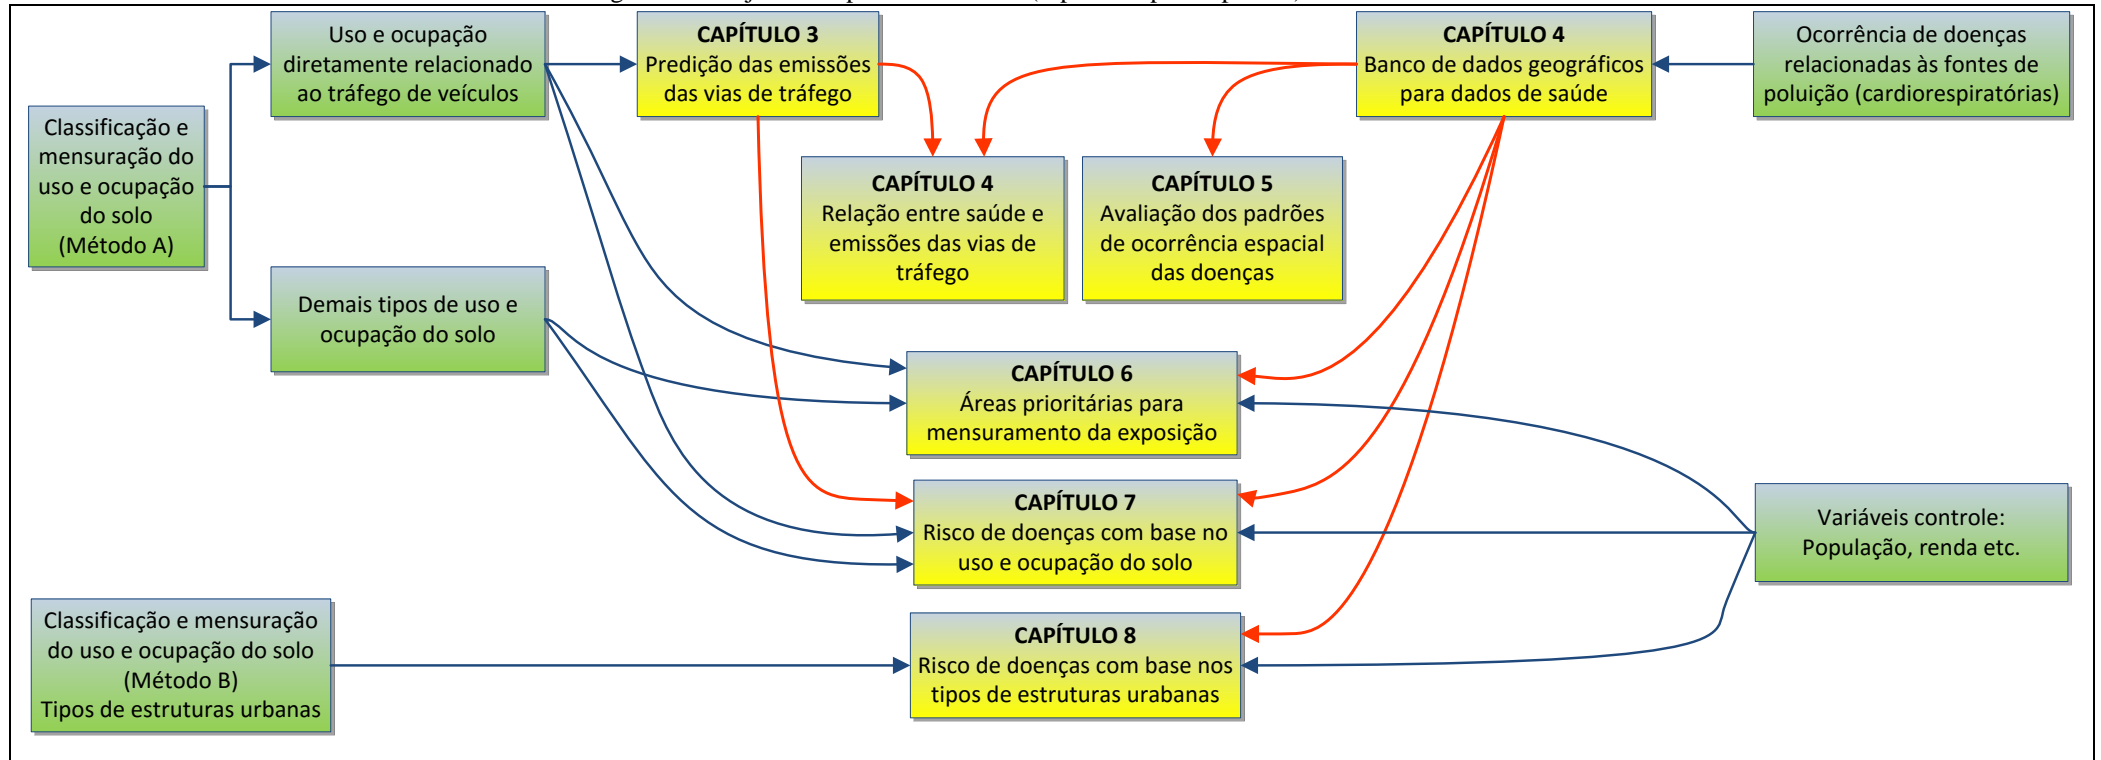
VARIÁVEL	FONTE DOS DADOS	DESCRIÇÃO	ESCALA TEMPORAL	FORMATO ORIGINAL DO DADO	O DADO FOI PROCESSADO? SE SIM, EM QUAL CAPÍTULO SERÁ DETALHADO O PROCESSAMENTO?	FORMATO FINAL DO DADO (FORMATO GEOGRÁFICO)	UNIDADE	O DADO FOI UTILIZADO EM QUAL(S) ANÁLISE(S)? (CAPÍTULOS)
Saúde	(DATASUS, 2013)	Endereço residencial e idade dos pacientes atendidos e internados	Informação mensal de 2008 a 2013	Planilha Excel	Sim. Capítulo 4	Vetor (Polígono)	Número de internações hospitalares	Capítulos: 4, 5, 6, 7 e 8 *
Endereçamento	(SEDHAB, 2012)	Sistema de endereçamento do DF	Ano de 2012	Vetor (Polígono)	O dado não foi processado	Vetor (Polígono)	Classes qualitativas: regiões administrativas, setores, quadras, conjuntos e lotes	Capítulos: 4, 7 e 8
Malha viária	(SEDHAB, 2012)	Malha viária (rodovias, ruas, avenidas etc.)	Ano de 2012	Vetor (Linha)	O dado não foi processado	Vetor (Linha)	Coordenadas geográficas	Capítulos: 3, 4, 6 e 7 **
Veículos	(DETRAN, 2009) (DER, 2010) (GDF, 2008)	1- Detran: média mensal do tráfego de veículos, com classificação do porte; 2- DER: quantidade diária do tráfego de veículos, com classificação do porte; 3- GDF: média horária (6h às 19h) do tráfego de veículos, com classificação do porte.	Detran: Maio de 2009  DER: 2007 a 2010  PDTU: média dos dias 08, 09 e 10 de abril de 2008	1- Detran: Vetor-ponto  2- DER: PDF  3- GDF: PDF	Sim. Capítulo 3	Vetor (Linha)	Número de veículos	Capítulos: 3, 6 e 7 **
População	(IBGE, 2012a)	Habitantes por setor censitário	Ano de 2010	Vetor (Polígono)	O dado não foi processado	Vetor (Polígono)	Número de pessoas	Capítulos: 4, 6, 7 e 8 *****
Renda	(IBGE, 2012a)	Total de rendimento mensal por setor censitário	Ano de 2010	Vetor (Polígono)	O dado não foi processado	Vetor (Polígono)	R\$	Capítulos: 6, 7 e 8 *****
Instituições de ensino	(SEDF, 2012)	Total de alunos por nível escolar nas instituições educacionais	Ano de 2012	Planilha Excel	Sim. Capítulo 6	Vetor (Ponto)	Número de alunos	Capítulo 6 *****
Hidrômetros	(CAESB, 2011)	Média do consumo de água em cada hidrômetro do DF	Ano de 2011	Vetor (Ponto)	O dado não foi processado	Vetor (Ponto)	m <sup>3</sup>	Capítulo 6 *****
Queimadas	(INPE, 2013)	Pontos de focos de queimadas	2010 a 2012 (Diário)	Planilha Excel	Sim. Capítulo 6	Vetor (Ponto)	Coordenadas geográficas	Capítulos: 6 e 7 ***

VARIÁVEL	FONTE DOS DADOS	DESCRIÇÃO	ESCALA TEMPORAL	FORMATO ORIGINAL DO DADO	O DADO FOI PROCESSADO? SE SIM, EM QUAL CAPÍTULO SERÁ DETALHADO O PROCESSAMENTO?	FORMATO FINAL DO DADO (FORMATO GEOGRÁFICO)	UNIDADE	O DADO FOI UTILIZADO EM QUAL(S) ANÁLISE(S)? (CAPÍTULOS)
Uso do solo	(SEDHAB, 2012)	Classificação do uso do solo	Ano de 2012	Vetor (Polígono)	O dado não foi processado	Vetor (Polígono)	Classes qualitativas: urbanização, comércio, corpos d'água, formações florestais, área verde intraurbana, construção civil, solo exposto, indústrias, área urbana, mineração, pastagem, chácaras, parques urbanos e unidades de conservação.	Capítulos: 6, 7 e 8 ***
Rodoviárias e terminais de ônibus urbano	(SEMOB, 2013) (GDF, 2008)	Localização das rodoviárias e terminais de ônibus urbano. Informações sobre a quantidade de linhas de ônibus (diária) circulante em cada rodoviária e terminal	Ano de 2008	PDF	Sim. Capítulo 6	Vetor (Ponto)	Número de linhas circulantes	Capítulos: 6 e 7 **
Aeroporto	Não há fonte. O dado foi gerado nesta pesquisa	Localização do aeroporto	Ano de 2012	-	Sim. Capítulo 6	Vetor (Polígono)	Coordenadas geográficas	Capítulo 6 **
Altimetria	(SEDHAB, 2012)	Curvas altimétricas	Ano de 2012	Vetor (Linha)	O dado não foi processado	Vetor (Linha)	Classes qualitativas: muito baixa, baixa, média, alta e muito alta.	Capítulos: 6 e 7 *****
Umidade	(IBRAM, 2013)	Média da umidade relativa do ar	Julho de 2012 a dezembro de 2013	PDF	Sim. Capítulo 6	Vetor (Ponto)	%	Capítulos: 6 e 7 *****
Temperatura	(IBRAM, 2013)	Média da temperatura	Julho de 2012 a dezembro de 2013	PDF	Sim. Capítulo 6	Vetor (Ponto)	°C	Capítulos: 6 e 7 *****
Imagem aérea	(GDF, 2009)	Mosaico de ortofotos de resolução espacial de 1 m	Ano de 2009	Raster Imagem (.ecw)	O dado não foi processado	Raster Imagem (.ecw)	-	Capítulos: 8
Tipos de estruturas urbanas	Não há fonte. O dado foi gerado nesta pesquisa	Classificação de uso do solo com base nos conceitos de tipos de estruturas urbanas	Ano de 2009	-	Sim. Capítulo 8	Vetor (Polígono)	21 classes qualitativas (descritas no Capítulo 8)	Capítulo 8 ****

(Conclusão)

Nota: com base nas definições apresentadas pela Figura 14, segue - ocorrência de doenças relacionadas às fontes de poluição (\*); Método A, uso e ocupação diretamente relacionado ao tráfego de veículos (\*\*); Método A, demais tipos de uso e ocupação do solo (\*\*\*); Método B, tipos de estruturas urbanas (\*\*\*\*); Variáveis controle (\*\*\*\*\*).

Figura 14 - Objetivos específicos da tese (separados por Capítulos) e dados de entrada.



Fonte: Produção do próprio autor.

Nota: esta Figura é uma edição da Figura 1, na qual foi apresentada na Introdução; objetivos específicos da tese separados por capítulos (retângulo amarelo); dados primários de entrada (retângulo verde); dados secundários de entrada (seta vermelha).

## 2.3 FERRAMENTAS

Dez ferramentas computacionais foram utilizadas nesta tese. Em síntese, o principal objetivo do uso das ferramentas foi para auxiliar no processo de edição, criação, análise, armazenamento e visualização das informações geográficas; e auxílio nas análises estatísticas e modelagem. O Quadro 2 apresenta os detalhes de cada ferramenta utilizada.

Quadro 2 - Ferramentas da pesquisa.

PROGRAMA	VERSÃO	FONTE	PRINCIPAL FUNCIONALIDADE NO PRESENTE TRABALHO	O PROGRAMA FOI UTILIZADO EM QUAL(S) ANÁLISE(S)? (CAPÍTULOS)
ArcGis	10.2	(ESRI, 2013a)	Edição, criação e análise de informações geográficas	Capítulos: 3, 4, 5, 6, 7 e 8
ArcCatalog	10.2	(ESRI, 2013b)	Criação do geodatabase e metadados	*
GeoDA	1.6.7.9	(LUC ANSELIN, 2015)	Análise geoestatística e apresentação de resultados	Capítulos: 3 e 5
Google Earth	7.1.1.188	(GOOGLE, 2013)	Visualização de informações geográficas	Capítulos: 3 e 6
Expert Choice	3.01	(ALIGNER, 2004)	Modelagem multicritérios	Capítulo 6
Grapher	8.7.844	(GOLDEN, 2013)	Geração de gráficos	Capítulos: 3, 7 e 8
Excel	10	(MICROSOFT, 2012)	Tratamento, edição, criação e armazenamento de dados	*
SPSS	20	(IBM, 2013)	Análises estatísticas	Capítulo 4
R	2.10.1	(R CORE TEAM, 2013)	Análises estatísticas	Capítulos: 7 e 8

Nota: utilizado antes de qualquer análise (\*).



## Capítulo 3 - Distribuição espacial do inventário de emissões veiculares

---

### 3.1 APRESENTAÇÃO

Os veículos automotores terrestres, tais como carros, ônibus, caminhões e motos são considerados uma das principais fontes de emissão de poluentes atmosféricos (Capítulo 1). A nível mundial, são responsáveis pela emissão de 30% de NO<sub>x</sub> e 14% de CO<sub>2</sub> de todo o planeta Terra (VASCONCELLOS, 2006). No Brasil, em torno de 40% do CO<sub>2</sub> são oriundos dos veículos automotores terrestres (MCT, 2013).

Vlachokostas et al. (2009) mostram que as informações sobre a carga de poluentes atmosféricos que estão sendo lançados em uma área urbana é uma base para a gestão pública que visa criar medidas a favor da qualidade ambiental, e consequentemente beneficiar à saúde pública. Nesse contexto, as estações de monitoramento de poluição atmosférica são os principais mecanismos para obter informações sobre a concentração de gases e partículas presentes na atmosfera.

No entanto, nem todas as áreas urbanas possuem uma rede de monitoramento eficiente. A implantação e operação de uma rede possui custo elevado e exige mão de obra qualificada, o que passa a ser uma dificuldade para alguns centros urbanos (KANAROGLOU et al., 2005; JOLY; PEUCH, 2012). No Brasil, por exemplo, Alves et al. (2014) mostram que do total de 5.570 municípios, apenas 1,7% possuem monitoramento da qualidade do ar. Há no país um total de 252 estações de monitoramento, porém o problema se agrava pois nem toda estação monitora todos os poluentes exigidos pelo Conama 003 de 1990 (CONAMA, 1990), que são MP<sub>10</sub>, MP<sub>2,5</sub>, O<sub>3</sub>, SO<sub>2</sub>, NO<sub>2</sub>, CO. Quanto ao DF, a rede de monitoramento é composta por sete estações fixas que monitoram PTS, SO<sub>2</sub> e NO<sub>2</sub>. Vale destacar que dentre os materiais particulados, o PTS não é mais considerado como relevante pelos órgãos de referência internacional em padrões de qualidade do ar, EPA - EUA (EPA, 2013a) e OMS (OMS, 2010).

Comparando o número de estações por área territorial, o Brasil tem 0,03 estações por 1.000 km<sup>2</sup>, enquanto que nos EUA são 0,5 estações (ALVES et al., 2014); no Japão 4,9 estações (FUKUSHIMA, 2006); e na Alemanha 5,18 estações (UBA, 2013). Especificamente no DF, são 0,8 estações por 1.000 km<sup>2</sup>. Quanto ao número de habitantes, no Brasil são 1,3 estações por

1 milhão de habitantes (ALVES et al., 2014); enquanto que nos EUA são 16 estações (ALVES et al., 2014); no Japão 15 estações (FUKUSHIMA, 2006) e na Alemanha 23 estações (UBA, 2013). Especificamente no DF, são 1,6 estações por 1 milhão de habitantes.

Diante do exposto, os inventários de poluição passam a ser uma alternativa barata e simples para suprir a necessidade das regiões que não possuem monitoramento da poluição atmosférica, ou que possuem um monitoramento limitado, como no DF (BELLASIO et al., 2007; UEDA; TOMAZ, 2011; HUANG et al., 2011; NAGPURE; GURJAR, 2012).

Portanto, este capítulo apresentará a análise realizada para predição de emissões veiculares, como um método alternativo para áreas não monitoradas ou com limitação no monitoramento. Essa análise é referente ao primeiro objetivo específico desta tese – predição das emissões de tráfego. Destaca-se que os resultados que serão descritos neste capítulo foram publicados no *Journal Atmospheric Environment* (Apêndice B.1).

## **3.2 MÉTODO**

Esta análise foi realizada em três etapas. A primeira consistiu na consolidação do banco de dados espaciais sobre a contagem de veículos das principais vias do DF. A segunda etapa correspondeu ao inventário espacial da emissão de poluentes atmosféricos em cada uma das vias. E a terceira foi realizada a análise do comportamento espacial do inventário. Em todas as etapas foi utilizado o programa ArcGis (ESRI, 2013a) como ferramenta operacional. Especificamente para a análise do comportamento espacial do inventário, em complemento ao programa ArcGis, foi também utilizado o programa GeoDA (LUC ANSELIN, 2015).

### **3.2.1 CONSOLIDAÇÃO DOS VEÍCULOS AUTOMOTORES**

A consolidação dos veículos automotores foi baseada nas informações referentes ao número de veículos que circulam em determinadas vias no DF. Essas informações foram consultadas em três fontes de dados distintas, Detran(2009), DER (2010) e GDF (2008). O acesso a essas três fontes de dados só foi possível mediante a solicitação formal.

Os dados do Detran (2009) e do DER (2010) referem-se à contagem de veículos feita pelos equipamentos de fiscalização eletrônica de velocidade no DF (“os pardais”). Especificamente quanto aos dados do Detran (2009), referem-se ao mês de maio de 2009 e tratam sobre a média de veículos que passaram nas vias em que cada equipamento eletrônico do Detran estava

instalado e em funcionamento no período de referência. Além dessa média para todos os veículos, também foi feita para cada tipo de porte - motocicletas, veículos pequenos, médios e grandes. As informações do Detran (2009) utilizadas no presente trabalho foram decorrentes de 496 equipamentos de fiscalização eletrônica.

Os dados do DER (2010) possuem a mesma metodologia dos dados do Detran (2009) em termos de porte de veículo monitorado. Porém, os dados do DER (2010) são referentes à quantidade diária de veículos durante os anos de 2007 a 2010. Em relação à quantidade de equipamentos do DER (2010) que forneceram dados para a presente pesquisa, houve uma variação em cada ano. Em 2007 foram 79 equipamentos; em 2008, 95 equipamentos; em 2009, 100 equipamentos; e em 2010, 106 equipamentos.

E quanto aos dados do (GDF, 2008), tratam-se do Plano Diretor de Transporte Urbano do Distrito Federal (PDTU). Os dados são referentes à contagem visual de veículos em campo durante o período de 6 horas às 19 horas. A campanha de campo para realização da contagem foi realizada nos dias 08 a 10 de abril (terça a quinta-feira) do ano de 2008, em 34 pontos distintos do DF. Os dados tratados são referentes à média horária dos veículos durante os três dias de contagem em campo. O porte dos veículos considerados pelo PDTU são: automóveis, caminhões, ônibus e motocicletas.

Após o acesso às três fontes (Detran, DER e PDTU), a etapa seguinte consistiu na consolidação dos dados em um único geodatabase. Essa etapa foi subdividida em três: 1) espacialização dos pontos de contagem das três fontes; 2) operações algébricas dos pontos de contagem com base no fluxo das vias; 3) transferência da informação pontual para o segmento de via.

### **3.2.1.1 Espacialização dos pontos de contagem**

Os dados do Detran são os únicos que foram fornecidos já com a informação geográfica (vetor, ponto). Cada ponto representa um equipamento de fiscalização eletrônica (total de 496). Quanto ao DER e PDTU, os dados foram fornecidos no formato de PDF, no qual contém a informação da quantidade de veículos por equipamento eletrônico e a coordenada geográfica de cada equipamento.

Todas as informações dos arquivos PDF foram acessadas de forma manual e individual e transferidas para uma planilha do Excel. Especificamente quanto aos dados do DER, estavam distribuídos em 3.485 arquivos PDF. Os dados do PDTU estavam em um único arquivo PDF.

As informações transferidas para o Excel foram tratadas com objetivo de unificar os dados das três fontes. Lembrando-se que cada fonte possui um padrão diferente referente à delimitação temporal e em relação à classificação dos veículos. Dessa forma, quanto à escala temporal final, foi considerada a média anual da quantidade de veículos circulantes. Para isso, os dados do DER foram agrupados em uma média referente ao período de 2007 a 2010. Os dados do PDTU foram agrupados em uma média de todas as faixas horárias monitoradas. E os dados do Detran foram utilizados do seu formato original. Em relação à classificação final do porte dos veículos, foram padronizadas em três classes, que seguem: motocicletas; veículos leves (automóveis + veículos pequenos + veículos médios); veículos pesados (veículos grandes + caminhões + ônibus). Após o tratamento das informações no Excel, os dados foram especializados, compondo assim um geodatabase preliminar com as três fontes (Detran, DER e PDTU).

### **3.2.1.2 Operações algébricas dos pontos de contagem**

Com objetivo de aumentar a amostra da quantidade de veículos considerando vias não monitoradas, e de sintetizar os pontos referentes às vias de mão dupla, foram realizadas algumas operações algébricas. Os seguintes exemplos hipotéticos detalham essas operações:

a) exemplo hipotético 1 - aumentar a amostra da quantidade de veículos considerando vias não monitoradas: o fluxo de tráfego das vias A e B (monitoradas pelo Detran, DER ou PDTU) alimentam uma via C (não monitorada pelo Detran, DER ou PDTU). Portanto, pode-se estimar a quantidade de veículos na via C pelo somatório dos veículos da via A e B;

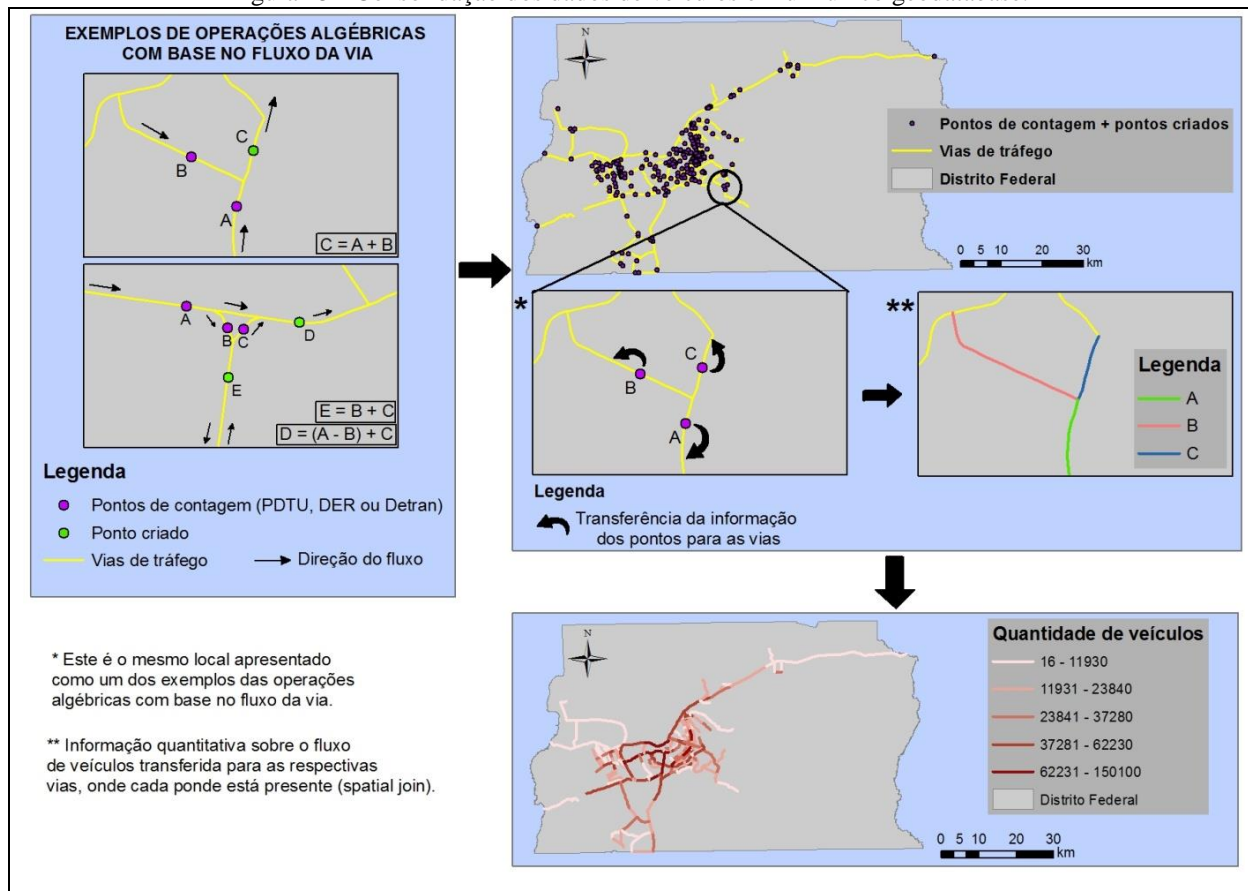
b) exemplo hipotético 2 – sintetizar os pontos referentes às vias de mão dupla: uma via de mão dupla possui 2 equipamentos eletrônicos de fiscalização próximos um do outro. Um equipamento no ponto A e outro equipamento no ponto B. A diferença é que os equipamentos estão monitorando o fluxo de sentidos diferentes. Portanto, foi criado um ponto C (que representa  $A + B$ ) e em seguida os pontos A e B foram removidos do geodatabase.

Esses procedimentos, denominado nesta pesquisa como operações algébricas dos pontos de contagem, foram realizados com análise individual para todo o conjunto de pontos (total de 636) do geodatabase preliminar (descrito no item 3.2.1.1). Por fim, o Street View do Google Earth (GOOGLE, 2013) foi utilizado para auxiliar na identificação do fluxo de cada via.

### 3.2.1.3 Transferência da informação pontual para o segmento de via

Nesta etapa foi realizada a transferência de toda informação pontual (decorrente do item 3.2.1.2) para o segmento de via que representa o local da contagem. Para isso, foi utilizada a base geográfica da malha viária do DF, disponibilizada pela Sedhab (2012). Esse procedimento foi realizado com a ferramenta de relacionamento espacial (*spatial join*) disponibilizada pelo programa ArcGis(ESRI, 2013a). Como resultado, o geodatabase final sobre a quantidade de veículos foi composto por 233 vias de tráfego, as quais apresentam uma extensão total de aproximadamente 615 km. A Figura 15 mostra um exemplo do processo de consolidação dos dados de veículos (operações algébricas e transferência para o segmento de via). Além disso, a Figura 15 apresenta um mapa simbolizando a quantidade de veículos por via (total de 233), no qual exemplifica o resultado final. Por fim, destaca-se que o Apêndice C.4 apresenta os mapas referentes ao resultado final do processo de consolidação, separados por tipo de veículos (motocicletas, veículos leves e veículos pesados).

Figura 15 - Consolidação dos dados de veículos em um único geodatabase.



Fonte: Produção do próprio autor.

### 3.2.2 INVENTÁRIO ESPACIAL

O inventário foi calculado para as 233 vias de tráfego, as quais possuem informações sobre a quantidade de veículos. O método de inventário escolhido foi o *bottom up*. Esse método é utilizado quando é possível ter dados de entrada mais detalhados referente à frota de veículos estudada, como a intensidade de uso, a idade da frota e a quilometragem percorrida. A Equação 2 representa o procedimento de cálculo do método *bottom up* (MMA, 2011; RIGHI et al., 2013).

$$E_{i,y,z} = \frac{(Fr_{i,y} \times Iu_{i,y} \times Fe_{i,z,x})}{10^6}$$

Equação 2

Onde,  $E$  é a taxa de emissão anual em toneladas (t);  $Fr$  é a frota circulante (número de veículos);  $Iu$  a intensidade de uso (média da quilometragem - km/ano);  $Fe$  é o fator de emissão (grama de poluente por quilômetro rodado - g/km);  $i$  é a idade dos veículos;  $y$  é o tipo de veículo;  $z$  é o tipo de poluente; e  $x$  é o tipo de combustível utilizado.

Não foi possível determinar a idade do veículo e o tipo de combustível utilizado na presente análise. Portanto, desconsideraram-se as variáveis  $i$  e  $x$ . Quanto à variável  $y$ , foram representadas por três categorias de veículos: leves, motocicletas e pesados (conforme apresentado no item 3.2.1). E quanto ao tipo de poluente, variável  $z$ , foram considerados os seguintes: CO, NMHC, CH<sub>4</sub>, NO<sub>x</sub>, MP e CO<sub>2</sub>.

A Equação 2 foi utilizada para calcular a taxa de emissão específica para cada dado de frota de veículos observado (uma via específica), com um poluente e um tipo de veículo específico. Com objetivo de quantificar a emissão total de um determinado poluente de cada ponto de frota observada, ou seja, considerando todas categorias de veículos circulantes, foi aplicada a Equação 3.

$$Et_z = E_{\text{veículos leves, } z} + E_{\text{motocicletas, } z} + E_{\text{veículos pesados, } z}$$

Equação 3

Onde,  $Et$  é o valor da emissão total anual em toneladas (t) e  $z$  é o tipo de poluente considerado.

Portanto, os dados usados para a entrada do cálculo de inventário podem ser divididos em frota de veículos, intensidade de uso e fator de emissão. Quanto à frota de veículo, foi considerado o geodatabase da quantidade de veículos por vias (apresentado no item 3.2.1).

Em relação à intensidade de uso, baseou-se nos dados considerados pelo Ministério do Meio Ambiente (MMA, 2011), no qual a intensidade de uso está relacionada à idade do veículo. Como não foi possível obter o dado da idade dos veículos, foi considerado que os veículos da frota circulante têm no máximo até 15 anos de uso. Pois os veículos com até 15 anos de uso representam mais de 90% de toda a frota circulante no DF (DENATRAN, 2015). Portanto, calculou-se uma média da intensidade de uso para os veículos entre 0 a 15 anos, 1995 a 2010. Assim, a intensidade de uso considerada nesta pesquisa para os veículos leves foi de 14.875 km/ano, para as motocicletas 8.625km/ano e para os veículos pesados 70.085 km/ano.

E quanto ao fator de emissão, foram consultados os dados disponibilizados pela Companhia de Tecnologia de Saneamento Ambiental (CETESB, 2012) e MMA (2011), conforme apresentado pelo Quadro 3. Os dados divulgados por essas fontes são as referências para os fatores de emissão dos veículos brasileiros. Destaca-se, que o fator de emissão também é relacionado à idade do veículo. Dessa forma, foi adotado o mesmo procedimento de estimação da idade dos veículos usado para a intensidade de uso.

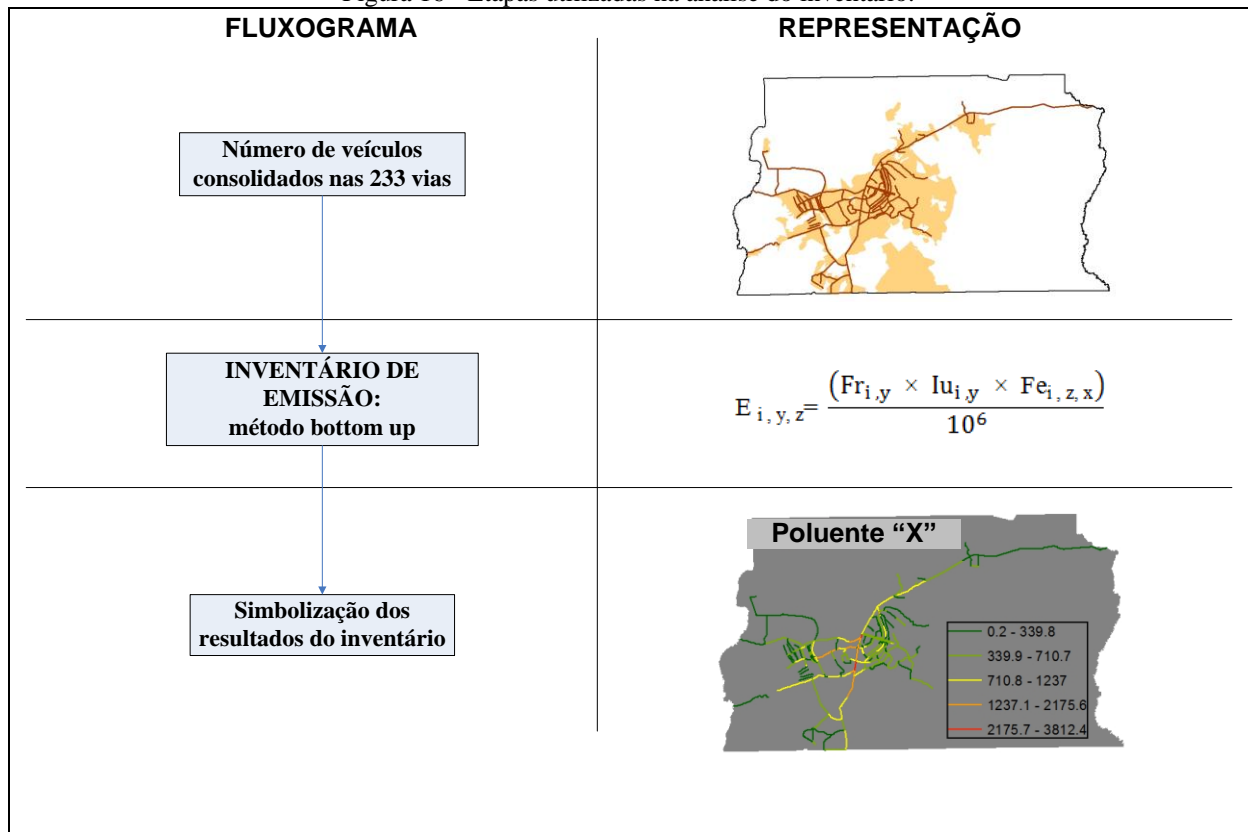
Quadro 3 - Valores de Fator de Emissão (FE) para cada categoria de veículos (g/km).

POLUENTE	LEVES	MOTOS	PESADOS
CO	Fe = 0,88 Fonte: (CETESB, 2012)	Fe = 5,176 Fonte: (MMA, 2011)	Fe = 1,04 Fonte: (CETESB, 2012)
NMHC	Fe = 0,12 Fonte: (CETESB, 2012)	Fe = 0,62 Fonte: (MMA, 2011)	Fe = 6,813 Fonte: (MMA, 2011)
CH <sub>4</sub>	Fe = 0,04 Fonte: (CETESB, 2012)	Fe = 0,111 Fonte: (MMA, 2011)	*
NO <sub>x</sub>	Fe = 0,15 Fonte: (CETESB, 2012)	Fe = 0,142 Fonte: (MMA, 2011)	Fe = 5,78 Fonte: (CETESB, 2012)
MP	Fe = 0,0012 Fonte: (CETESB, 2012)	Fe = 0,009 Fonte: (MMA, 2011)	Fe = 0,2055 Fonte: (CETESB, 2012)
CO <sub>2</sub>	Fe = 188,8333 Fonte: (CETESB, 2012)	Fe = 90 Fonte: (CETESB, 2012)	**Fe = 521 Fonte: (MMA, 2011)

Nota:\* Desprezível, segundo MMA (2011); \*\* Inicialmente, presumiu-se que todos os veículos pesados em Brasília são movidos a diesel. Em seguida, foi realizado o seguinte cálculo. O MMA (2011) define que os veículos movidos a diesel emitem 2.671 kg/l de CO<sub>2</sub>, além de possuir um rendimento de 5,12 km/litro de diesel. Dessa forma, dividindo 2,671 por 5,12 e multiplicando o valor final por 1.000 (conversão de quilograma para grama), encontra-se um valor de fator de emissão de CO<sub>2</sub> para veículos pesados igual a 521 g/km.

A Figura 16 apresenta uma síntese das etapas de trabalho desenvolvidas para o cálculo do inventário espacial da presente análise. Conforme apresentado no item 3.2.1, inicialmente os dados dos veículos automotores foram consolidados em 233 vias do DF. Em seguida foi calculado o inventário com o método *bottom up*. Como resultado final, os poluentes inventariados foram espacializados (Figura 16).

Figura 16 - Etapas utilizadas na análise do inventário.



Fonte: Produção do próprio autor.

### 3.2.3 ANÁLISE DO COMPORTAMENTO ESPACIAL

Foram aplicados dois métodos de geoestatística com objetivo de avaliar o comportamento espacial da emissão de poluentes estimada pelo inventário.

O primeiro teste geoestatístico teve por objetivo verificar o padrão de distribuição, ou seja, procurou-se identificar a presença de autocorrelação espacial das emissões entre as 233 vias inventariadas no estudo. Entre os testes disponíveis, foi escolhido o Global Moran's I. O resultado desse teste visa identificar se a distribuição dos dados é dispersa, randômica ou agrupada (*cluster*). A Equação 4 apresenta a formulação algébrica usada pelo teste (ANSELIN, 1995).

$$I = \frac{n}{S_0} \frac{\sum_{i=1}^n \sum_{j=1}^n W_{ij} Z_i Z_j}{\sum_{i=1}^n Z_i^2}$$

Equação 4



Onde  $I$  é o Moran's index,  $Z_i$  é o desvio da taxa de emissão de cada via;  $W_{i,j}$  é o peso espacial entre as vias  $i$  e  $j$ ;  $n$  é o número total de vias, que neste estudo foi 233; e  $S_o$  é o agregado de todos os pesos espaciais, representado pela Equação 5.

$$S_o = \sum_{i=1}^n \sum_{j=1}^n W_{i,j}$$

Equação 5

Vale destacar que o valor de  $I$  maior que zero indica que os valores da taxa de emissão são agrupados, ou seja, valores similares da taxa de emissão são encontrados entre as vias de tráfegos vizinhas umas das outras. Valor de  $I$  igual a zero indica que a distribuição é randômica. E valores de  $I$  menor que zero indica que a distribuição é dispersa.

O segundo teste geoestatístico teve o objetivo de identificar o grau de agrupamento entre as 233 vias observadas. O teste identifica os agrupamentos com valores altos (*High cluster*) ou baixos (*Low cluster*), ou seja, se há agrupamentos de vias com elevadas taxas de emissões ou agrupamentos de vias com pouca emissão. Para isso, foi utilizado o teste de Getis-Ord General G, representado pela Equação 6 (GETIS; ORD, 1992).

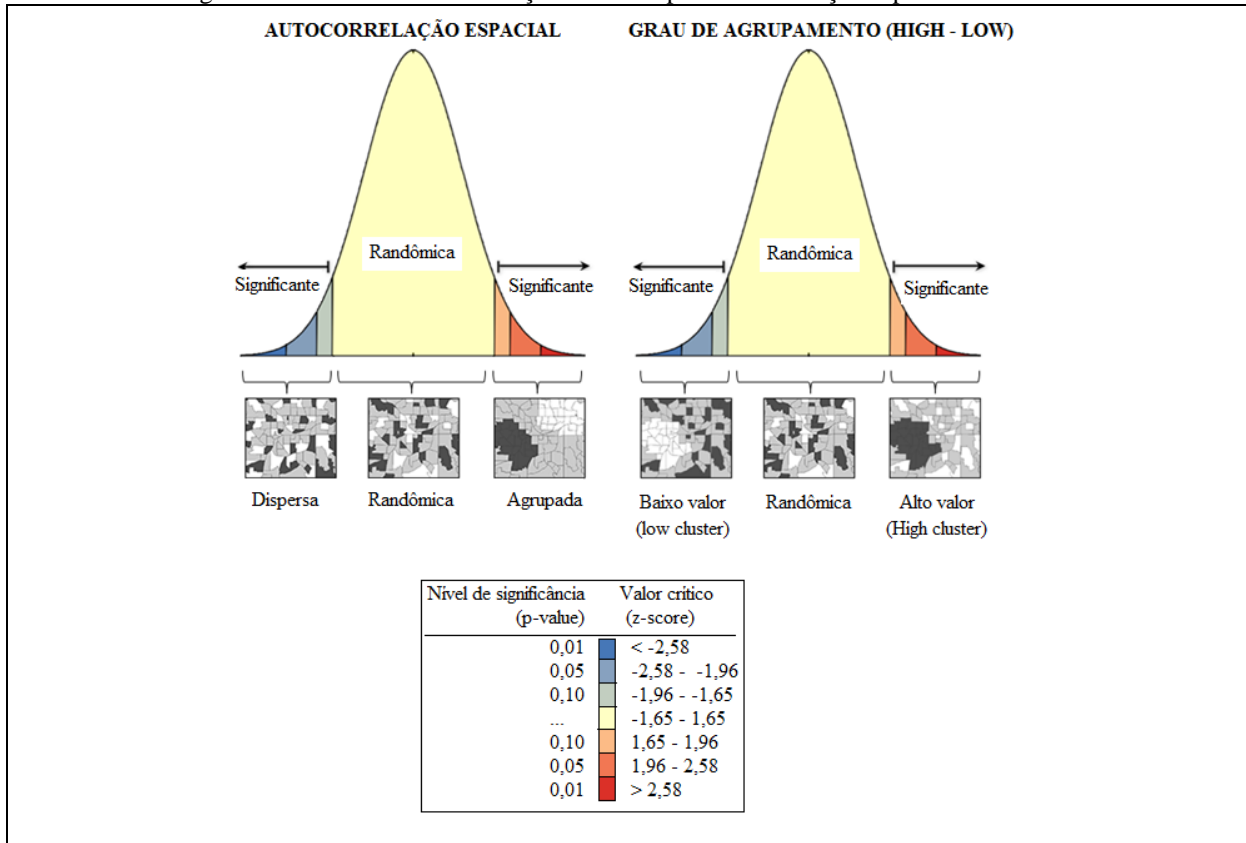
$$G = \frac{\sum_{i=1}^n \sum_{j=1}^n W_{i,j} X_i X_j}{\sum_{i=1}^n \sum_{j=1}^n X_i X_j}, \forall_j \neq i$$

Equação 6

Onde  $G$  é valor de General G,  $X_i$  e  $X_j$  são os valores referentes a taxa de emissão para cada via  $i$  e  $j$ ;  $W_{i,j}$  é o peso espacial entre as vias  $i$  e  $j$ ;  $n$  é o número total de vias, que neste estudo foi 233; e  $\forall_j \neq i$  indica que as vias  $i$  e  $j$  não podem ser a mesma.

Por fim, destaca-se que ambos os testes aplicados pelo presente estudo passaram pelo teste de significância, para então, definir o tipo de distribuição espacial. A Figura 17 ilustra o procedimento que foi realizado.

Figura 17 - Método de classificação utilizado para a distribuição espacial dos dados.



Fonte: ESRI (2013), com edição.

### 3.3 RESULTADOS

Os veículos leves são os que se apresentam em maior número nas 233 vias consideradas, totalizam 6.283.337 veículos, representando 91%. As motos representam 4% e os veículos pesados 5%. A quantidade de veículos entre as vias avaliadas possui um comportamento heterogêneo, conforme o coeficiente de variação encontrado. Em relação aos veículos leves, o coeficiente de variação foi o menor (0,79), quando comparado com os demais veículos. As motos e os veículos pesados tiveram um coeficiente de variação maior que 1 (desvio padrão > média), representando uma elevada variação dos dados (Tabela 4).

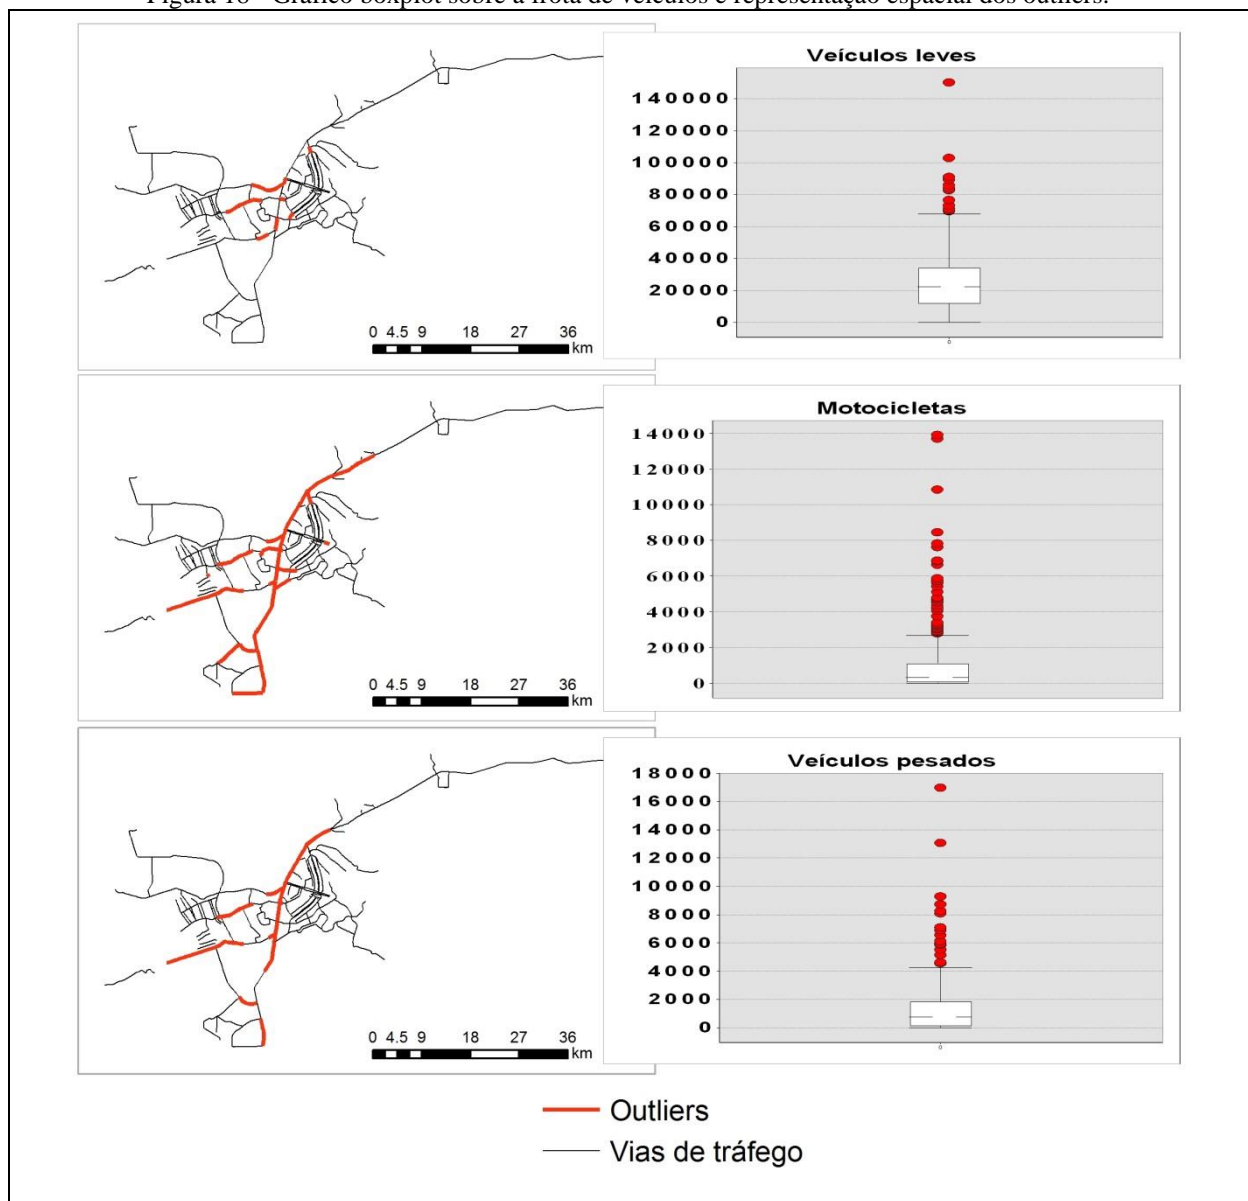
Tabela 4 - Estatística descritiva da frota de veículos automotores presente nas vias de circulação do DF considerada pelo presente estudo.

PARÂMETRO ESTATÍSTICO	Veículos leves	Motos	Veículos pesados
Mínimo	15	0	0
Máximo	150.100	13.900	16.967
Soma	6.283.337	265.785	345.352
Média	26.967	1.140	1.482
DP	21.457	2.097	2.169
CV	0,79	1,83	1,46

Nota: DP = desvio padrão; CV = coeficiente de variação.

A heterogeneidade elevada da quantidade de veículos circulantes entre as 233 vias avaliadas foi um fator significativo para o surgimento dos *outliers*- valores extremos e discrepantes do conjunto de dados. As motos foram a categoria de veículos que apresentaram o maior número de *outliers*. A localização espacial dos *outliers* foi semelhante entre as categorias de veículos, sobretudo, entre as motos e os veículos pesados (Figura 18). Destaca-se, que as vias identificadas como *outliers* são as que apresentam a maior quantidade de veículos dentre o conjunto de dados avaliados.

Figura 18 - Gráfico boxplot sobre a frota de veículos e representação espacial dos outliers.



Fonte: Produção do próprio autor.

Quanto ao comportamento estatístico descritivo da carga de poluentes inventariada (Tabela 5), observa-se que os veículos leves foram os responsáveis pela maior emissão de CO (68,9%), CH<sub>4</sub> (93,6%) e CO<sub>2</sub> (57,9%), enquanto que os veículos pesados emitiram a maior parte de NMHC (92,9%), NO<sub>x</sub> (90,7%) e MP (97,4%). Ainda sobre a Tabela 5, vale ressaltar a respeito da heterogeneidade - relação entre desvio padrão e média da carga de poluentes, principalmente entre as motos e os veículos pesados. Esse comportamento é relacionado a mesma distribuição heterogênea da quantidade de veículos circulantes, conforme apresentado pela Tabela 4.

Tabela 5 - Estatística descritiva da carga de poluentes emitida conforme o tipo de veículo (toneladas/ano).

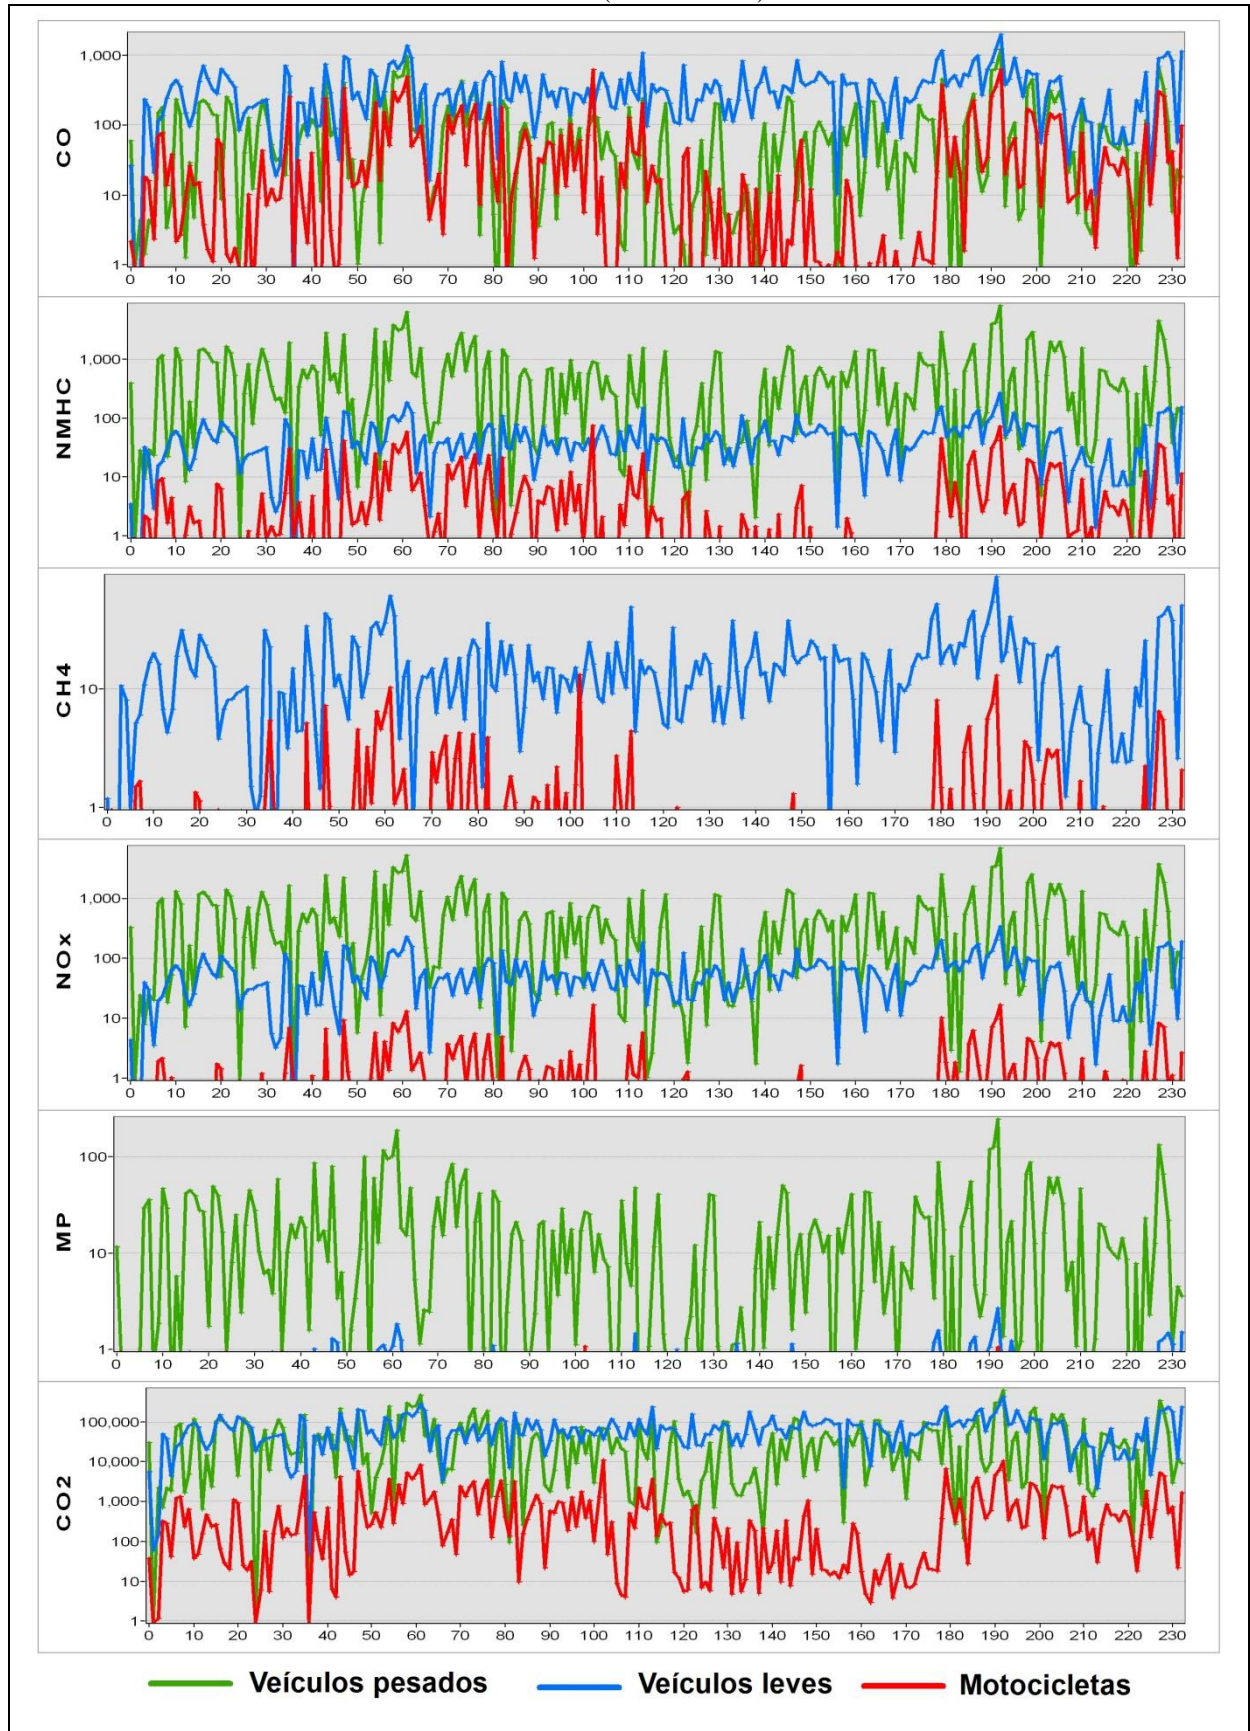
Tipo	Tipo de poluente	Mínimo	Máximo	Soma	Média	Desvio padrão	CV
L	CO	0,21	1.964	82.249	353	281	0,80
	NMHC	0,03	267	11.216	48	38	0,80
	CH <sub>4</sub>	0,01	89	3.739	16	13	0,80
	NO <sub>x</sub>	0,03	335	14.020	60	48	0,80
	MP	0,0003	3	112	0,48	0,38	0,79
	CO <sub>2</sub>	45	421.615	17.649.236	75.748	60.273	0,80
M	CO	0	620	11.865	51	94	1,84
	NMHC	0	74	1.421	6	11	1,84
	CH <sub>4</sub>	0	13	254	1,09	2,01	1,84
	NO <sub>x</sub>	0	17	325	1,39	2,57	1,85
	MP	0	1,08	20	0,09	0,16	1,78
	CO <sub>2</sub>	0	10.790	206.313	885	1.628	1,84
P	CO	0	1.237	25.172	108	158	1,46
	NMHC	0	8.102	164.902	707	1.036	1,46
	CH <sub>4</sub>	-	-	-	-	-	-
	NO <sub>x</sub>	0	6.873	139.899	600	878	1,46
	MP	0	244,37	4.974	21	31	1,46
	CO <sub>2</sub>	0	619.538	12.610.308	54.121	79.232	1,46

Nota: L - veículos leves, M = motocicletas, P = veículos pesados, CV = coeficiente de variação.

A Figura 19 complementa a interpretação da Tabela 5, possibilitando a visualização da alta variação da emissão de poluentes, conforme o tipo de veículo, no decorrer das 233 vias de tráfego estudadas no DF. Vale destacar sobre o comportamento do MP, no qual os veículos pesados foram praticamente unânimes na emissão desse poluente. Ressalta-se que apesar de algumas categorias de veículos serem predominantes no somatório da emissão de um certo tipo de poluente, não significa que essa predominância é unânime em todas as vias (Figura 19).

Com a espacialização dos resultados referentes às taxas de emissões conforme o tipo de veículo (Figura 20), nota-se que os veículos leves e os pesados são os que apresentaram as maiores taxas distribuídas entre as 233 vias estudadas. Ressalta-se ainda, que as vias identificadas pelos *outliers* na Figura 18, são similares às vias identificadas pela Figura 20 como as que possuem as taxas de emissão mais elevadas.

Figura 19 - Gráficos da variação espacial da emissão de poluentes entre as 233 vias estudadas e conforme o tipo de veículo (toneladas/ano).

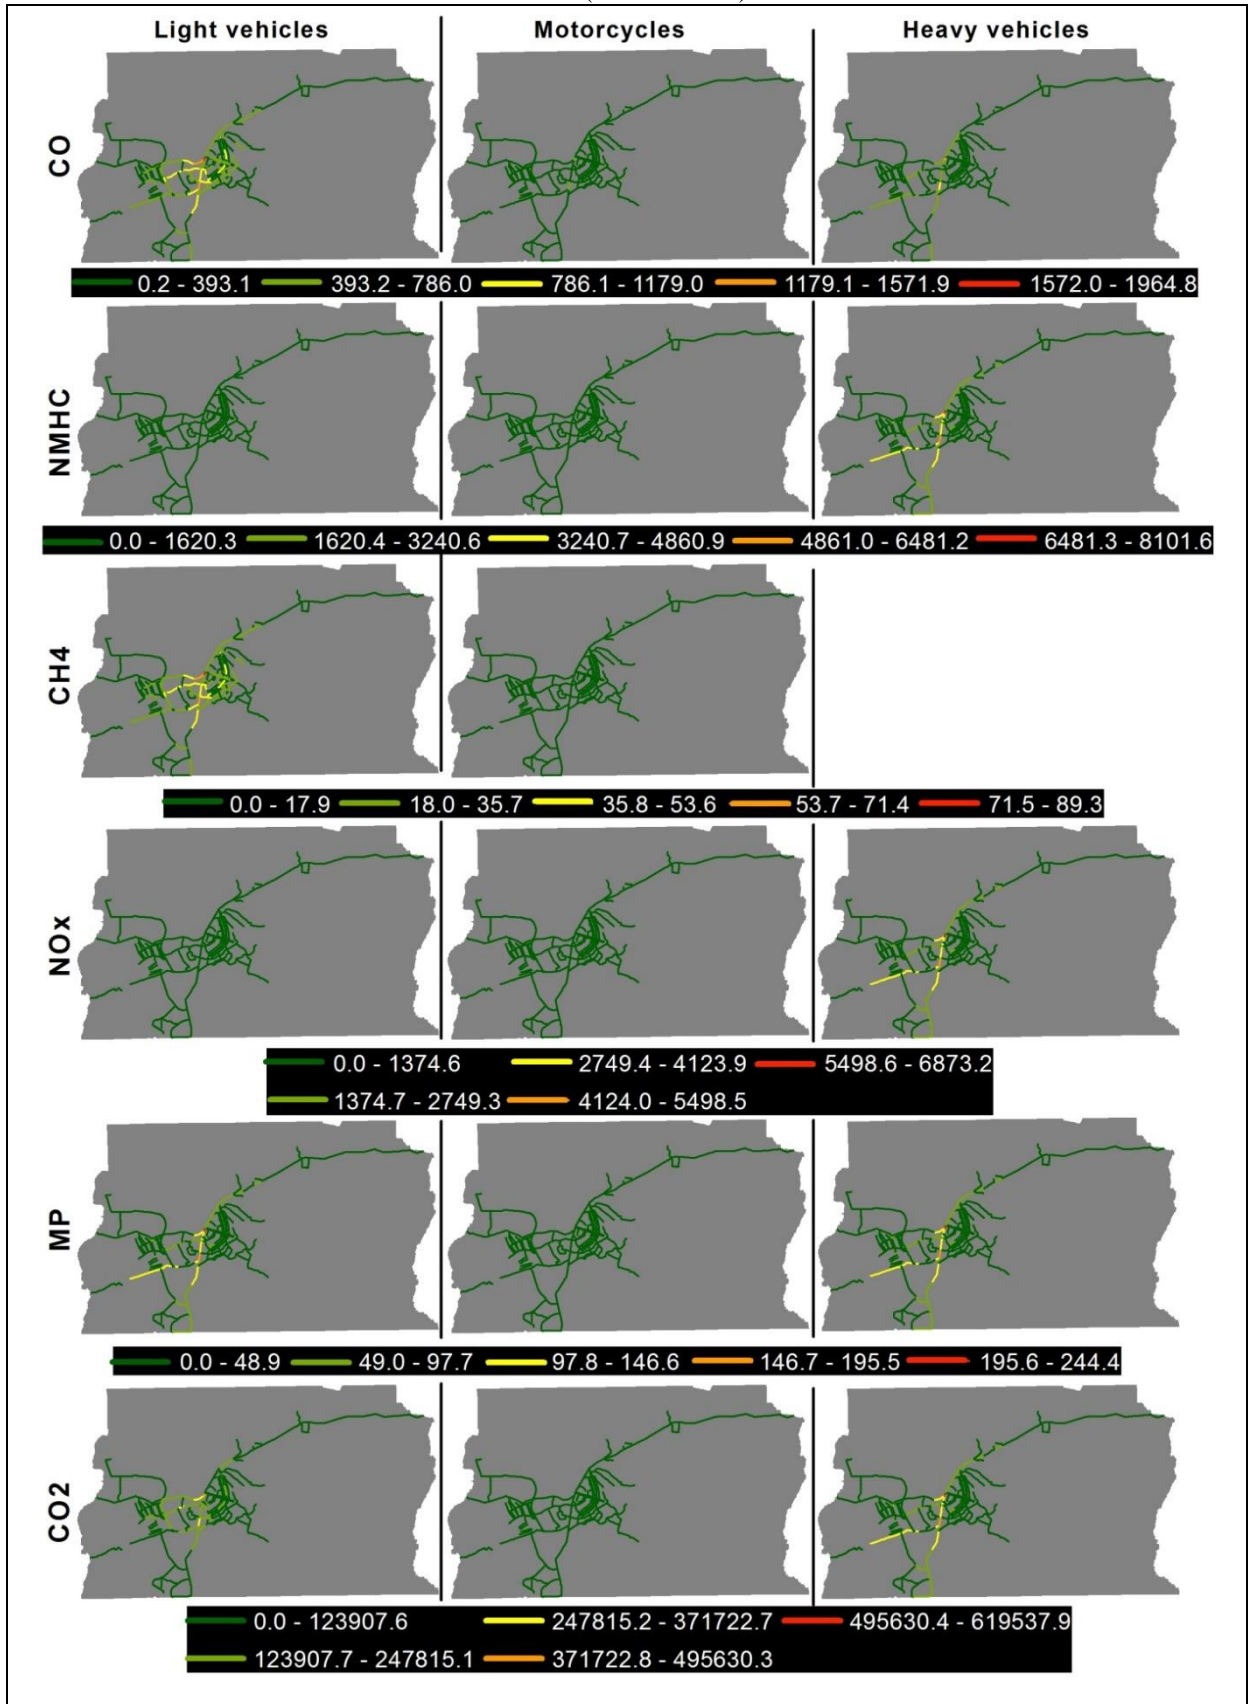


Fonte: Produção do próprio autor.

Nota: Vias (eixo X); Emissão do poluente em escala logarítmica (eixo Y).



Figura 20 - Mapas da variação espacial da emissão de poluentes entre as vias estudadas e conforme o tipo de veículo (toneladas/ano).



Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado - intervalos iguais; Veículos leves (Light vehicles); Motocicletas (Motorcycles); Veículos pesados (Heavy vehicles).

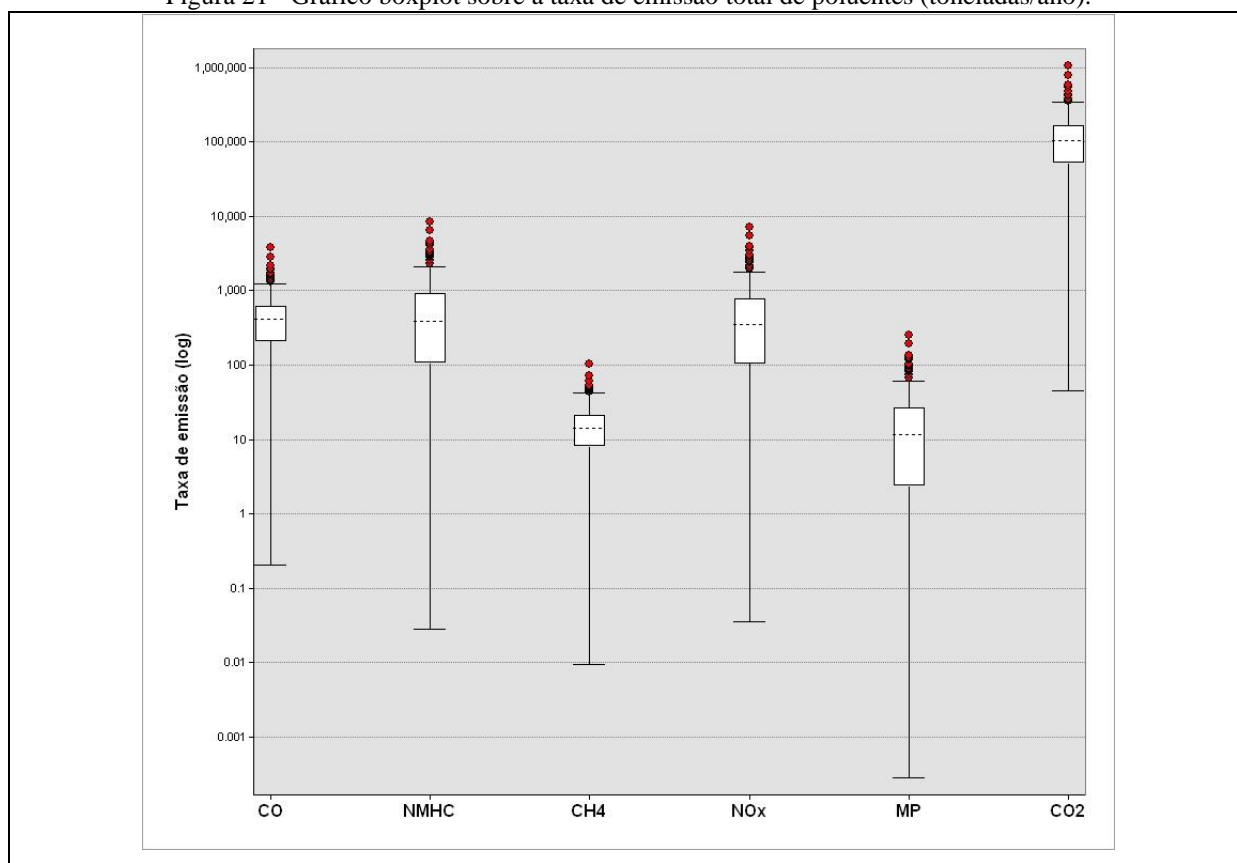
A soma das emissões dos tipos de veículos representou a emissão total do inventário, ou seja, a emissão de todos os veículos circulantes nas vias avaliadas neste estudo. Portanto, considerando a emissão total, o CO<sub>2</sub> foi o poluente que teve a maior carga de lançamento, passou de 30 milhões de toneladas. Em média, são emitidas em torno de 130 mil toneladas anuais de CO<sub>2</sub> entre as 233 vias. Já o CH<sub>4</sub> foi o que teve a menor carga de emissão, em torno de 4 mil toneladas (Tabela 6).

Tabela 6 - Estatística descritiva do total da carga de poluentes lançadas (toneladas/ano).

Tipo de poluente	Mínimo	Máximo	Soma	Média	Desvio padrão
CO	0,21	3.812	119.287	512	473
NMHC	0,03	8.442	177.539	762	1.069
CH <sub>4</sub>	0,01	102	3.993	17	14
NO <sub>x</sub>	0,03	7.224	154.245	662	911
MP	0,0003	248	5.107	22	32
CO <sub>2</sub>	45	1.051.773	30.465.857	130.755	127.056

Ainda sobre a avaliação estatística da carga total de poluentes, destaca-se que o comportamento da distribuição da emissão de poluentes é assimétrico. Além disso, todos os poluentes apresentaram valores atípicos superiores (*outliers*), certamente devido ao comportamento heterogêneo da quantidade de veículos circulantes nas vias (Figura 21).

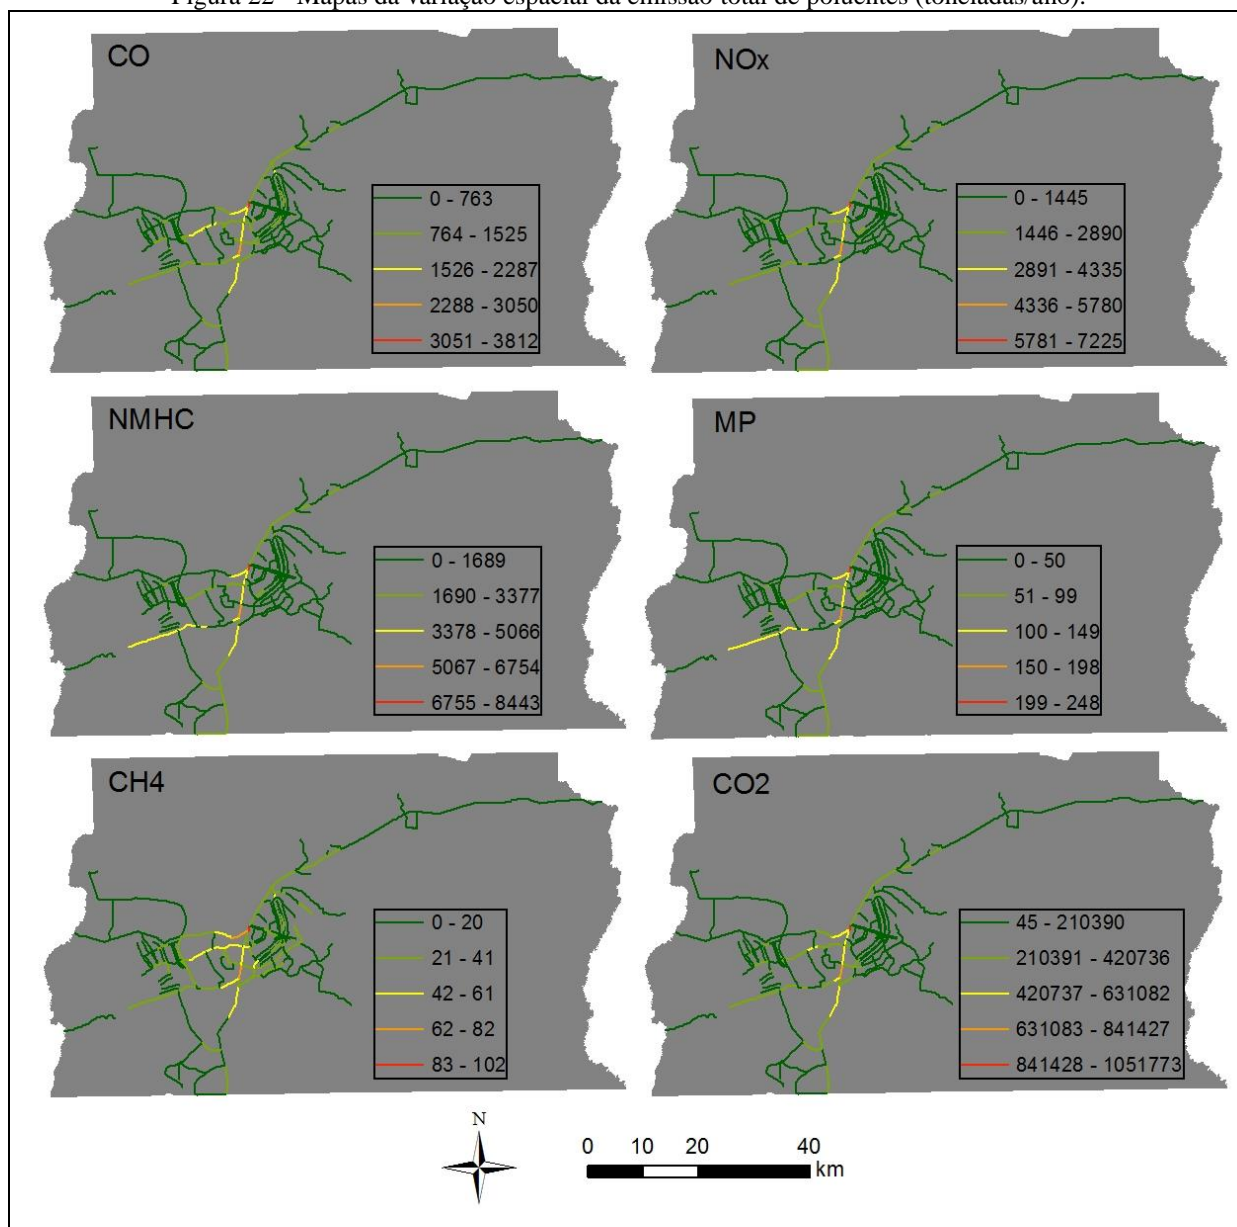
Figura 21 - Gráfico boxplot sobre a taxa de emissão total de poluentes (toneladas/ano).



Fonte: Produção do próprio autor.

Quanto à espacialização do total de poluentes lançados (Figura 22), observa-se que os mapas sobre às emissões dos poluentes apresentam similaridade quanto a variação espacial da emissão. As maiores taxas de poluentes emitidos se concentraram nas vias que circulam a maior parte dos veículos nos horários de pico e nas vias que possuem o maior tráfego de veículos pesados (Figura 18).

Figura 22 - Mapas da variação espacial da emissão total de poluentes (toneladas/ano).



Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado - intervalos iguais.



Quanto aos resultados da segunda parte do estudo, análise do comportamento espacial da emissão de poluentes inventariado, identificou-se inicialmente que as emissões classificadas por tipo de veículos e as emissões totais possuem um comportamento espacial do tipo agrupado (*clustered*), pois apresentaram índices de Moran's variando entre 0,071 a 0,024. A significância desse resultado está baseada nos valores de *z-score* e *p-value*. O valor de *z-score* positivo e *p-value* significativa indica que deve ser rejeitada a hipótese nula (distribuição randômica) e aceita a hipótese de que a distribuição é do tipo *clustered* (Tabela 7).

Tabela 7 - Resultado do teste Global Moran's I.

Grupo	Moran's index	<i>z-score</i>	<i>p-value</i>	Classificação
Veículos leves	0,071	6,529	<0,01	Clustered
Motocicletas	0,053	5,085	<0,01	Clustered
Veículos pesados	0,024	2,515	0,01	Clustered
Emissão total - CO	0,055	5,230	<0,01	Clustered
Emissão total - NMHC	0,025	2,623	<0,01	Clustered
Emissão total - CH <sub>4</sub>	0,070	6,509	<0,01	Clustered
Emissão total - NO <sub>x</sub>	0,025	2,640	<0,01	Clustered
Emissão total - MP	0,024	2,553	<0,01	Clustered
Emissão total - CO <sub>2</sub>	0,042	4,092	<0,01	Clustered

Em relação à análise da presença de cluster com baixos valores ou com altos valores, foi identificado somente para os veículos leves (*High-Clusters*). As emissões dos demais veículos e as emissões totais não apresentaram presença de *cluster* de alto ou baixo valores, sendo nesse caso, uma distribuição randômica (Tabela 8).

A significância do resultado apresentado pela Tabela 8 está baseada nos valores de *z-score* e *p-value*. Os valores de *z-score* positivo e *p-value* significativa indicam que deve ser rejeitada a hipótese nula (distribuição randômica) e aceita a hipótese de que há *cluster* com altos valores. E caso houvesse valor de *z-score* negativo e *p-value* significativa, indicaria a existência de *cluster* com baixos valores.

Tabela 8 - Resultado do teste Getis-Ord General G.

Grupo	General G	<i>z-score</i>	<i>p-value</i>	Classificação
Veículos leves	<0,001	3,228	<0,01	High-Clusters
Motocicletas	<0,001	-0,662	0,51	Random
Veículos pesados	<0,001	-0,587	0,55	Random
Emissão total - CO	<0,001	1,359	0,17	Random
Emissão total - NMHC	<0,001	-0,491	0,62	Random
Emissão total - CH <sub>4</sub>	<0,001	1,715	0,21	Random
Emissão total - NO <sub>x</sub>	<0,001	-0,437	0,66	Random
Emissão total - MP	<0,001	-0,556	0,58	Random
Emissão total - CO <sub>2</sub>	<0,001	0,999	0,32	Random

### 3.4 DISCUSSÃO

A presença significativa dos veículos categorizados como leves (91% do total de veículos) nas 233 vias avaliadas na presente análise foi determinante para que 68,9% do CO (82,2 mil toneladas), 93,6% do CH<sub>4</sub> (3,7 mil toneladas) e 57,9% do CO<sub>2</sub> (17,6 milhões de toneladas) fossem oriundos dessa categoria de automóvel. No caso dos veículos pesados (5% do total de veículos), nos quais emitiram 92,9% de NMHC (164,9 mil toneladas), 90,7% de NO<sub>x</sub> (139,8 mil toneladas) e 97,4% de MP (4,9 mil toneladas), o elevado fator de emissão considerado para os veículos movidos a diesel foi significativo para esse resultado.

Ueda e Tomaz (2011) realizaram um estudo na região metropolitana de Campinas, Brasil, e também encontraram resultados semelhantes. Os autores identificaram que 74% do CO são decorrentes dos veículos leves. Porém, em Campinas há uma maior taxa de emissão de CO tendo como fonte os veículos leves, foram emitidas 180 mil toneladas. Enquanto que no presente estudo, encontrou-se uma taxa de emissão de 82 mil toneladas de CO. Essa diferença pode estar associada à frota de veículos circulantes consideradas em ambos os estudos. Ueda e Tomaz (2011) ainda divulgaram que os veículos pesados são responsáveis pela emissão de 61% de NO<sub>x</sub> e 99,9% do MP.

O Rio de Janeiro foi outra área de estudo brasileira considerada nas pesquisas de inventário. Duarte et al. (2013) identificaram no Rio de Janeiro que os veículos leves emitem anualmente em torno de 51 mil toneladas de CO (60% do total), 8 mil toneladas de NO<sub>x</sub> (17% do total), 25 toneladas de MP (2,9% do total). Já os veículos pesados e as motos emitem respectivamente, 5,9% e 90% do total de MP.

Os resultados encontrados pelo presente estudo, Campinas e Rio de Janeiro são próximos. Além disso, os resultados estão em concordância com o relatório nacional de inventário divulgado pelo o Ministério do Meio Ambiente (MMA, 2011). A Tabela 9 apresenta essas comparações.

Tabela 9 - Comparação dos inventários de emissões veiculares entre DF, Rio de Janeiro, Campinas e inventário nacional.

Área de estudo	Veículo	Poluentes					
		CO	NMHC	CH <sub>4</sub>	NO <sub>x</sub>	MP	CO <sub>2</sub>
DF	L	68,9%	6,3%	93,6%	9,1%	2,2%	57,9%
	M	9,9%	0,8%	6,4%	0,2%	0,4%	0,7%
	P	21,2%	92,9%	*	90,7%	97,4%	41,4%
	Total	100%	100%	100%	100%	100%	100%
RJ	L	54,7%	**	**	15,6%	2,7%	**
	M	33%	**	**	1,4%	5,9%	**
	P	12,3%	**	**	**	91%	**
	Total	100%	-	-	100%	100%	-
CP	L	74%	**	**	38,07	*	**
	M	6,5%	**	**	0,93%	*	**
	P	19,5%	**	**	61%	99,9%	**
	Total	100%	-	-	100%	100%	-
BR	L	48%	49%	68%	8%	2,5%	35%
	M	35%	26%	32%	*	0,5%	3%
	P	17%	25%	*	92%	97%	62%
	Total	100%	100%	100%	100%	100%	100%

Nota: L = veículos leves, M = motocicletas, P = veículos pesados, DF = Distrito Federal - presente análise, RJ = Rio de Janeiro, CP = Campinas, BR = Brasil – inventário nacional, (\*) = valor insignificante, (\*\*) não calculado.

Destaca-se que o DF está localizado em uma área de 5.802 km<sup>2</sup> e possui uma população de 2,8 milhões de pessoas. Campinas e o Rio de Janeiro possuem respectivamente uma área de 790 km<sup>2</sup> e 1.200 km<sup>2</sup>. Quanto à população, Campinas tem 1,2 milhão e Rio de Janeiro 6,4 milhões.

O CO<sub>2</sub> foi o poluente que teve a maior carga de lançamento, passou de 30 milhões de toneladas. Em média, são emitidas em torno de 130 mil toneladas de CO<sub>2</sub> entre as 233 vias estudadas. Já o CH<sub>4</sub> teve a menor carga de emissão, foi em torno de 4 mil toneladas. Ueda e Tomaz (2011) mostraram que em Campinas o total de emissão de CO foi de 244.000 toneladas, enquanto que de NO<sub>x</sub> foi 46.000 toneladas e MP foi 2.000 toneladas.

A análise espacial das emissões estimadas revelou que há autocorrelação espacial (*cluster*) entre as 233 vias. Isso indica que vias vizinhas umas das outras apresentam valores de emissões próximos (Tabela 7). Observando somente os altos valores e os baixos valores de emissões, os únicos *clusters* identificados foram para os veículos do tipo leve, *high cluster* (Tabela 8).

Infere-se que no DF as emissões dos veículos leves se diferenciam dos demais veículos pelas seguintes razões: os veículos leves são a maioria, representam 91% de toda a frota de veículo estudada; os veículos leves têm o menor coeficiente de variação, conforme apresentado pela Tabela 4; a distribuição espacial dos veículos leves, sobretudo os outliers, é diferente dos demais veículos (Figura 18).

O uso do solo também pode ser um outro fator associado à presença de cluster de altos valores para os veículos leves. Enquanto que as maiores emissões dos veículos pesados estão concentradas fora do centro urbano do DF (rodovias, por exemplo), as emissões dos veículos leves se concentram dentro do centro urbano, onde há uma alta densidade de ruas e avenidas.

Esta análise de inventário apresenta algumas limitações. Por exemplo, não foi possível considerar a diferença entre veículos novos e velhos; as emissões durante os períodos do dia; as emissões de marcha lenta durante o tráfego; as emissões de funcionamento dos veículos. No entanto, destaca-se que os dados desta análise são de 233 vias do DF, aproximadamente 615 km, em uma área de 5.802 km<sup>2</sup>. No Brasil, e talvez em muitos países desenvolvidos, não há disponibilidade acurada de informações de tráfego (idade do veículo, tráfego por horário, velocidade etc.) para o tamanho de amostra que foi utilizada neste estudo (233 vias).

Também não foi possível fazer a validação dos resultados encontrados. Primeiro porque as estações de monitoramento no DF monitoram somente PTS, NO<sub>2</sub> e SO<sub>2</sub>. E segundo porque os resultados deste inventário estão na unidade de massa (toneladas), enquanto que os resultados das estações de monitoramento são expressos em concentração (µg/m<sup>3</sup>). A forma adotada para validar os resultados foi comparar com outros estudos similares no Brasil.

## Capítulo 4 - Avaliação espacial entre poluição do ar e saúde em áreas com limitação de dados

---

### 4.1 APRESENTAÇÃO

A poluição do ar é um grave problema de saúde pública a nível mundial (conforme apresentado no Capítulo 1). Os estudos que investigam a relação entre poluição atmosférica e saúde humana são a base para a gestão que visa promover o desenvolvimento urbano e, sobretudo, melhorar a qualidade de vida das pessoas (YERRAMILI et al., 2011; BATEMAN et al., 2013).

A disponibilidade de dados para os estudos em saúde ambiental é uma premissa inicial, especialmente para os estudos com enfoque epidemiológico (BEEVERS et al., 2013). No caso específico entre poluição do ar e saúde humana, os dados comumente utilizados são decorrentes das estações de monitoramento de poluição atmosférica (concentração do poluente) e dos órgãos de gestão em saúde (número de óbitos, internações), respectivamente.

Nesse sentido, é um desafio o desenvolvimento dos estudos em saúde ambiental em algumas regiões onde os dados possuem limitações ou até mesmo estão indisponíveis. Essa é a realidade de muitas áreas urbanas brasileiras. O desafio é maior quando se buscar avaliar as relações espaciais entre poluição e saúde (MADSEN et al., 2011).

Por exemplo, especificamente quanto aos dados de poluição do ar no Brasil, Alves et al. (2014) mostram que as cidades brasileiras ainda estão distantes do monitoramento ideal, em termos de quantidade e qualidade das estações. Conforme apresentado no Capítulo 3 - item 3.1, apenas 1,7% dos municípios brasileiros possuem monitoramento da qualidade do ar.

E quanto aos dados de saúde, a dificuldade é quanto à acurácia, precisão e integração de banco de dados. Por exemplo, os endereços residenciais das pessoas que compareceram aos hospitais brasileiros muitas das vezes são incompletos. Essa é uma informação importante nos estudos epidemiológicos com enfoque espacial (SU, J G et al., 2009; HOFFMAN et al., 2012). E quando algum endereço apresenta uma melhor precisão, o problema passa a ser para a integração em um banco de dados geográfico.

Diante desse cenário, no qual é a realidade de muitos centros urbanos, sobretudo brasileiros, este capítulo tem como objetivo propor um método para avaliação espacial entre poluição do ar e saúde em áreas urbanas que têm limitações na disponibilidade de dados. Destaca-se que a limitação de dados considerada neste estudo é baseada em quatro características: a) quando uma área urbana não possui rede de monitoramento da qualidade do ar; b) quando a rede de monitoramento da qualidade do ar da área urbana é incompleta ou não representativa, conforme o Conama (1990); c) quando os dados de saúde da área urbana não são integrados a um SIG; d) quando os dados de saúde da área urbana não são diretamente relacionados com outras bases de dados, tais como transporte, uso do solo e informações sócio econômicas.

Ressalta-se que as análises deste capítulo são referentes ao segundo e terceiro objetivos específicos desta tese – construção de um banco de dados geográficos para os dados de saúde e avaliação da relação entre saúde e emissões decorrentes das vias de tráfego. Destaca-se ainda que os resultados que serão descritos neste capítulo foram submetidos para a revista *Hygeia* – Revista brasileira de geografia médica. Até o fechamento desta tese o artigo submetido ainda estava em avaliação pelos revisores. O Apêndice B.2 apresenta o comprovante de submissão.

## **4.2 MÉTODO**

### **4.2.1 LIMITAÇÃO DE DADOS NA ÁREA DE ESTUDO**

O DF apresenta três (b, c, d) das quatro características definidas neste capítulo (item 4.1) como uma área que possui limitação de dados. Conforme já apresentado no Capítulo 3 - item 3.1, a rede de monitoramento de poluição atmosférica do DF ainda é incompleta e pouco representativa. A rede é composta por sete estações fixas que monitoram PTS, SO<sub>2</sub> e NO<sub>2</sub>. Vale destacar que dentre os materiais particulados, o PTS não é mais considerado como relevante pelos órgãos de referência internacional em padrões de qualidade do ar, EPA (EPA, 2013a) e OMS (OMS, 2010). Além disso, o DF possui uma relação de 0,8 estações por 1.000 km<sup>2</sup> e 0,32 estações para cada 100 mil habitantes. Comparando com redes consideradas eficientes, segundo Alves et al. (2014), só nos EUA e na Europa (áreas significativamente maiores que o DF) possuem 0,5 e 1,7 estações por 1.000 km<sup>2</sup>, respectivamente; e respectivos valores de 16 e 14,8 estações para cada 100 mil habitantes. Comparando as áreas do território brasileiro que possuem rede de monitoramento (Quadro 4), vê-se que o DF ainda carece de investimentos para melhoria da rede.

Quadro 4 - Áreas do território brasileiro que possuem rede de monitoramento.

Estado	Cobertura	Número de estações	Tipo de monitor (quantidade)
Distrito Federal	Brasília, Sobradinho e Taguatinga	7	Manual (7)
Espírito Santo	Vitória	8	Automático (8)
Minas Gerais	Belo Horizonte	9	Automático (9)
Paraná	Curitiba	12	Manual (4), automático (7), semiautomático (1)
Rio de Janeiro	Região Sul, Região metropolitana, Médio Paraíba e Norte Fluminense	108	Semiautomático (53), automático (55)
Bahia	Salvador	21	Automático (21)
Rio Grande do Sul	Porto Alegre, Rio Grande, Caxias do Sul e região Serrana	24	Automático (14), manual (10)
São Paulo	São Paulo, Campinas, Baixada Santista, Vale do Paraíba, Litoral Norte e cidades do interior	83	Semiautomático (12), automático (43), manual (28)
Sergipe	Aracaju	1	Manual (1)

Fonte: Instituto de Energia e Meio Ambiente (IEMA, 2014).

E quanto ao sistema de saúde do DF, especificamente quanto ao banco de dados dos pacientes, também apresenta uma série de limitações. Por exemplo, não são integrados a um SIG e não são relacionados com outras bases de dados, tais como, transporte, meio ambiente ou dados socioeconômicos.

#### 4.2.2 DADOS

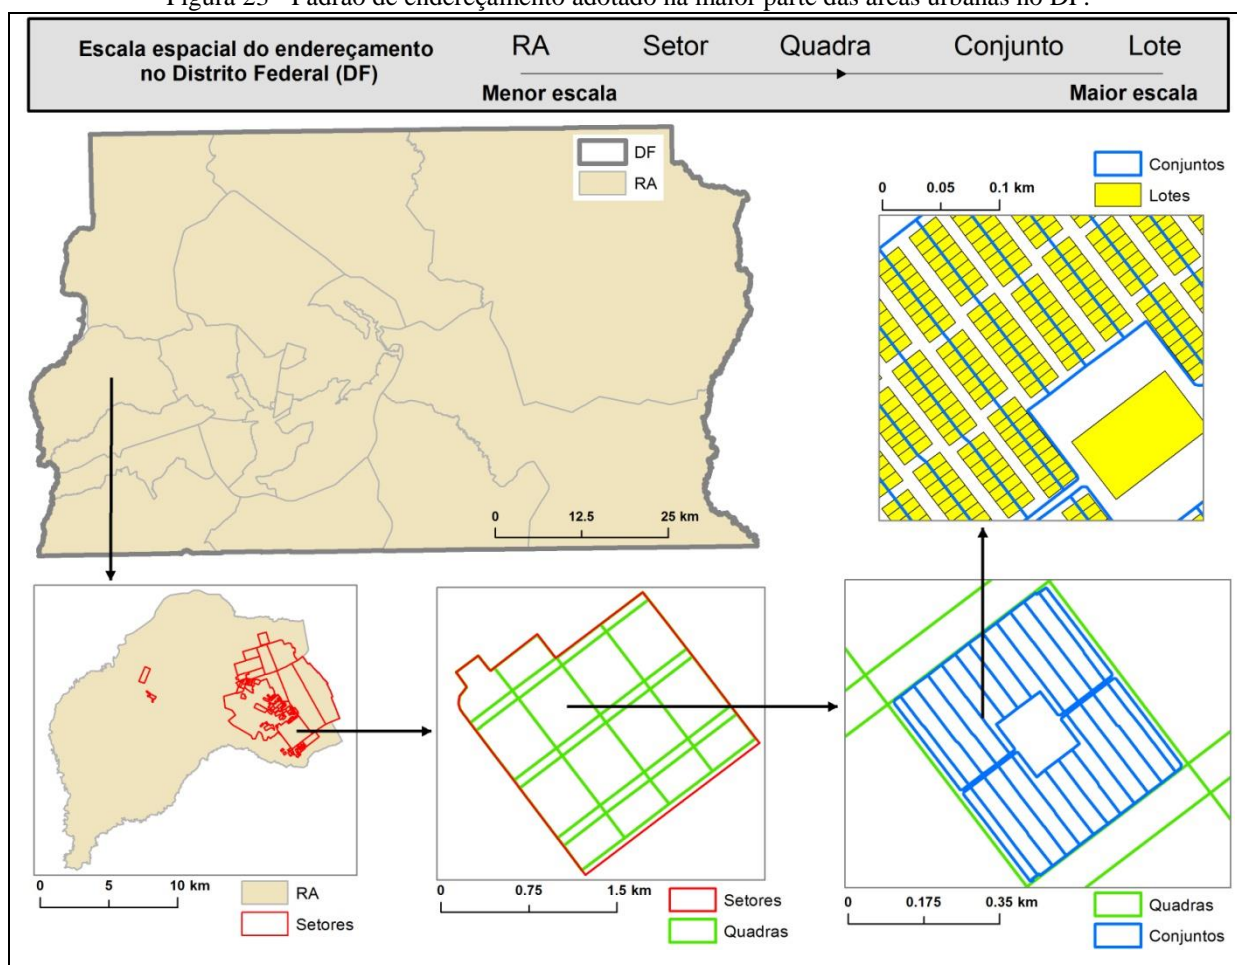
Neste estudo foram utilizados quatro conjuntos de dados: inventário de poluição, saúde, endereçamento residencial e setor censitário.

Quanto aos dados de inventário, o objetivo é mostrar que é um dado alternativo no caso de áreas que não possuem uma rede de monitoramento, ou quando a rede ainda é ineficiente. Os dados de inventário são decorrentes dos resultados apresentados pelo Capítulo 3 - Distribuição espacial do inventário de emissões veiculares.

Em relação aos dados de saúde, foram fornecidos pelo Ministério da Saúde – Datasus (DATASUS, 2013) por meio de solicitação formal. Os dados são referentes às pessoas atendidas e internadas nos hospitais do DF durante o período de 2008 a 2013 (com informações diárias) por motivo de doenças do sistema respiratório e circulatório. Os dados fornecidos apresentaram a classificação pessoal de cada paciente quanto à idade e o endereço residencial. Especificamente quanto ao endereço, não foram fornecidos o exato endereço com vista à preservação da integridade dos pacientes. Destaca-se que os dados originais fornecidos pelo Ministério se apresentam em formato de planilha eletrônica.

Quanto aos dados de endereçamento residencial, foram fornecidos pela Sedhab (2012). Os dados têm o formato espacial vetorial do tipo polígono, são referentes ao ano de 2012 e são sobre o sistema de endereçamento de todo o DF. Não há no DF uma padronização de endereçamento para toda área urbana. Mas em geral, o endereçamento é classificado segundo a seguinte ordem hierárquica: regiões administrativas (RA), setores, quadras, conjuntos e lotes (Figura 23).

Figura 23 - Padrão de endereçamento adotado na maior parte das áreas urbanas no DF.



Fonte: Produção do próprio autor.

E em relação aos dados do setor censitário, foram fornecidos pelo IBGE (2012b). Os dados utilizados se referem ao número de pessoas classificados por idade que vivem em cada setor censitário. Essa base de dados tem o formato espacial vetorial do tipo polígono e se refere ao ano de 2010.

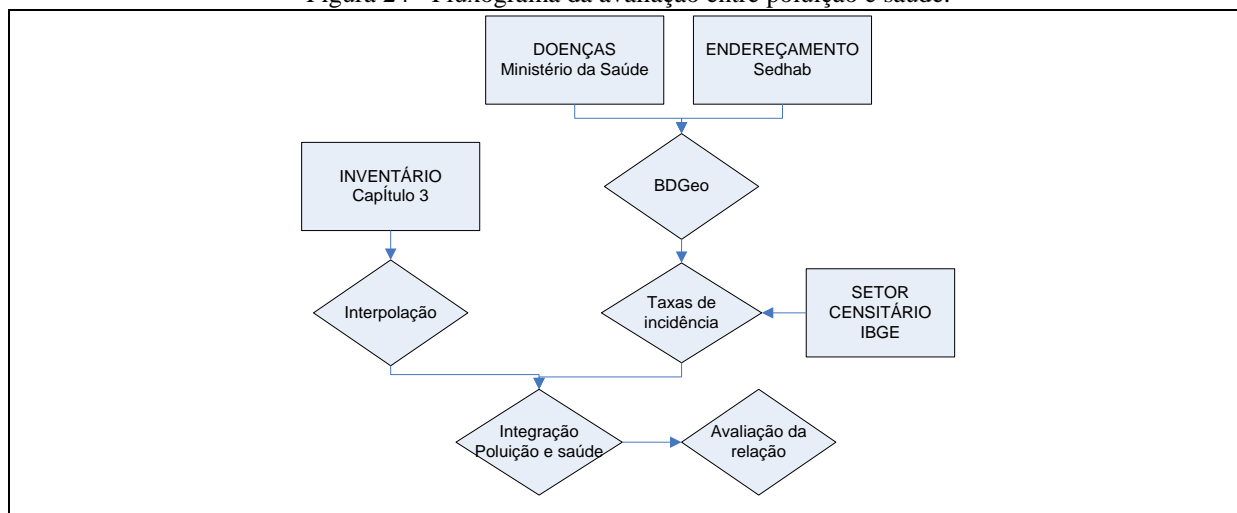


### 4.2.3 ANÁLISES

Inicialmente, o dado original sobre a ocorrência de doenças foi relacionado com a base de dados espacial da Sedhab (2012). O objetivo desse processo foi criar o banco de dados geográfico (BDGeo). O endereço dos pacientes foi o parâmetro base para a criação desse BDGeo. O endereço estava disponível em ambas as fontes, Ministério da Saúde (endereço dos pacientes) e Sedhab (sistema de endereçamento). Porém, a definição de endereçamento entre o Ministério da Saúde e a Sedhab não são correlacionáveis, o que necessitou a padronização das informações para posterior sincronização das bases de dados. Essa padronização foi feita de forma manual.

Em seguida, foi calculada uma taxa de incidência para os dados de saúde do BDGeo usando como referência a população residente de cada nível de endereçamento considerado (dados do IBGE). As taxas de incidências foram integradas (relacionamento espacial) junto com os dados de poluição (inventário). Essa integração permitiu estimar a quantidade de poluente em cada endereço de paciente. Por fim, foi avaliada a relação entre o local de residência de cada paciente com a poluição atmosférica. A Figura 24 apresenta o fluxo dos procedimentos realizados no estudo.

Figura 24 - Fluxograma da avaliação entre poluição e saúde.



Fonte: Produção do próprio autor.

Destaca-se que os dados de inventário decorrentes do Capítulo 3 se referem a cada segmento de via estudado. Para a análise do presente capítulo, foi necessário estimar uma superfície de poluição identificada pelo inventário. Para isso, usou-se o método de interpolação conhecido como IDW – *inverse distance weighting*. O IDW estima os valores em função da distância e magnitude dos pontos adjacentes amostrados (PHILIP, 1982 apud ESRI, 2008). A equação 1 apresenta a formulação algébrica utilizado pelo IDW.

$$Z_j = \frac{\sum Z_i / d_{ij}^\beta}{\sum 1 / d_{ij}^\beta}$$

Equação 7

Em que,  $Z_j$  é o ponto a ser interpolado,  $d_{ij}$  a distância de  $Z_j$  a amostra  $Z_i$ , e  $\beta$  é o peso estipulado. E quanto à avaliação da relação entre saúde e poluição, foi utilizado o teste de correlação de Pearson e uma análise de regressão espacial OLS – *Ordinary Least Squares*. Como o objetivo do presente estudo não foi criar um modelo que represente a ocorrência de doenças do sistema cardiorrespiratório, o método OLS foi utilizado somente com o intuito de verificar a direção e significância do coeficiente  $\beta$  de cada variável preditora (poluição do ar). Por fim, destaca-se que foram utilizados os programas ArcGis e SPSS v.20 como ferramenta operacional na análise deste capítulo.

### 4.3 RESULTADOS

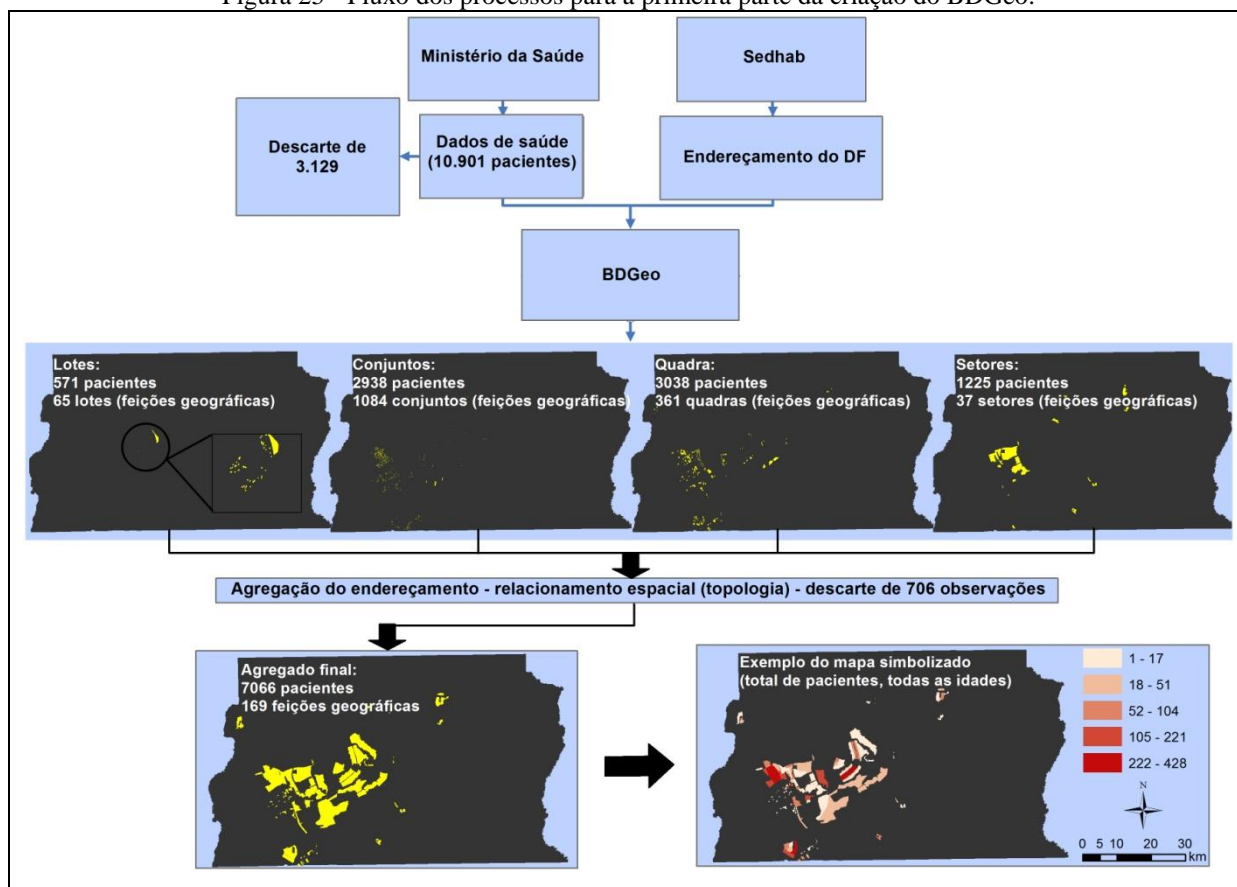
#### 4.3.1 BANCO DE DADOS EM SIG

A criação do banco de dados em SIG foi dividida em duas partes. A primeira relacionada à criação do banco de dados geográfico e a segunda para o cálculo da taxa de incidência. Quanto à primeira parte, o processo iniciou com o tratamento dos dados fornecidos pelo Ministério da Saúde - Datasus. A planilha eletrônica dos dados de saúde apresentou um total de 10.901 pacientes. Considerou-se a partir desse número o descarte, que nesse estudo foi de 3.129 (28,7%). Esse descarte foi realizado para aqueles endereços que se apresentavam de forma incompleta, sendo impossível identificar o local da residência. Os motivos do endereço incompleto podem ser, por exemplo, o erro de preenchimento da ficha cadastral pelo funcionário no momento que o paciente compareceu ao hospital. Não se rejeita também a possibilidade de o paciente ocultar informações do endereço residencial no preenchimento da ficha, com o intuito de agilizar o atendimento; ou até mesmo esquecer o endereço.

Com os endereços validados, criou-se o BDGeo. Esse banco foi composto por quatro níveis de endereçamento – lotes, conjuntos, quadras e setores (os quatro primeiros níveis de endereço do DF - Figura 23). Essa diferenciação foi devido ao nível de endereçamento disponível na planilha original do Ministério da Saúde. Por exemplo, para os pacientes que tinham informação

do setor, quadra, conjunto e lotes, foram consolidados no banco dos lotes (65 lotes, 571 pacientes). Para os pacientes que tinham informação do setor, quadra e conjuntos, foram consolidados no banco dos conjuntos (1.084 conjuntos, 2.938 pacientes). Para os pacientes que tinham informação do setor e quadras, foram consolidados no banco das quadras (361 quadras, 3.038 pacientes). E para os pacientes que tinham informação somente dos setores, foram consolidados no banco dos setores (37 setores, 1.225 pacientes). Por fim, optou-se por consolidar todas as informações em um único nível de endereçamento. Para isso, utilizou-se a inteligência do banco de dados geográficos (orientação a objeto – pai e filho), em que as informações dos polígonos internos (filhos) eram agrupadas e transferidas para os polígonos envoltórios (pais). Esse processo gerou uma perda de 706 observações, no qual esse relacionamento espacial não pode ser mantido. Como resultado final, obteve-se 169 feições geográficas, e um total de 7.066 pacientes, cobrindo toda a área urbana do DF. A Figura 25 apresenta o fluxo de todo o processo para a primeira parte do método.

Figura 25 - Fluxo dos processos para a primeira parte da criação do BDGeo.



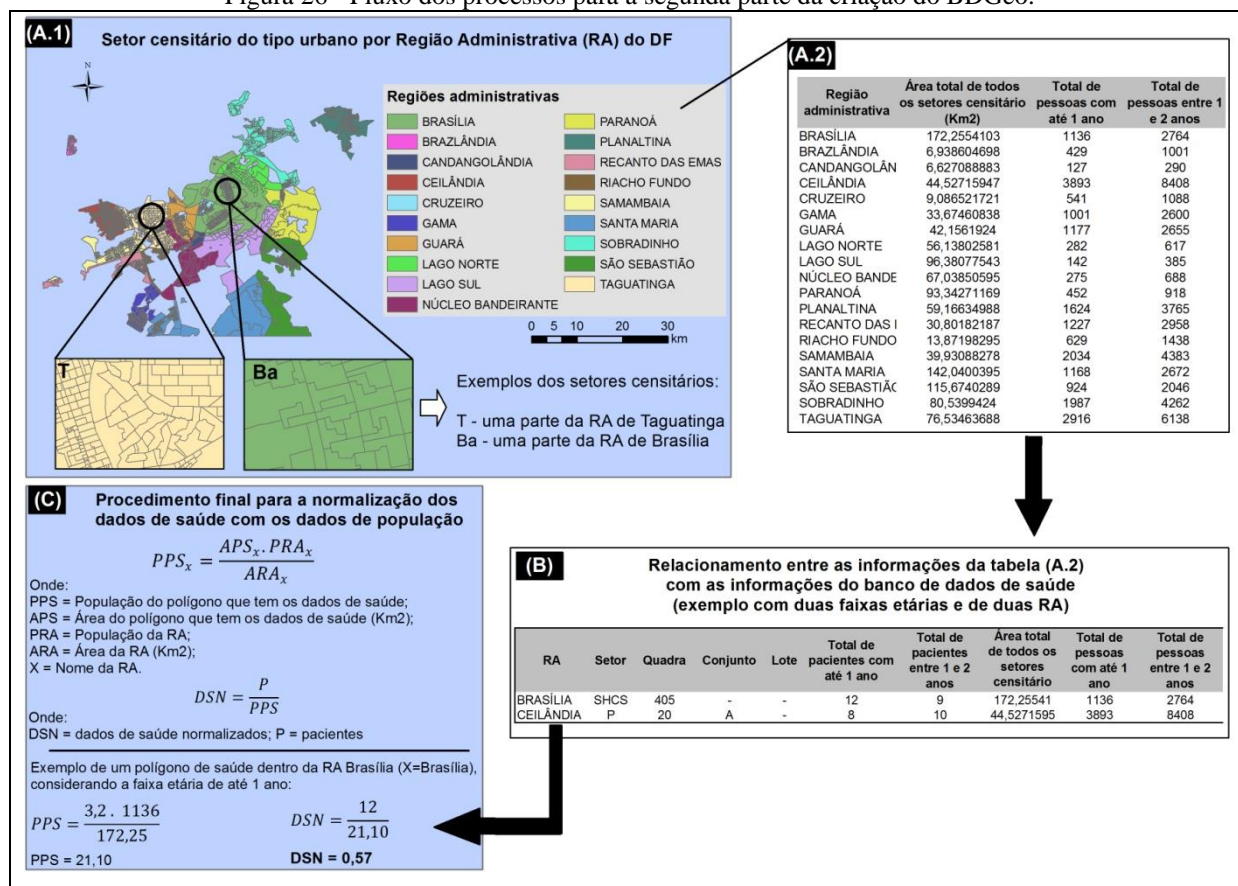
Fonte: Produção do próprio autor.

Em relação à segunda parte para criação do banco, referiu-se à criação da taxa de incidência dos dados de saúde contidos no banco de dados em SIG. O cálculo da taxa de incidência foi caracterizado pela relação do número de pacientes em cada feição geográfica entre o total de pessoas residentes na respectiva feição geográfica.

A feição geográfica do dado sobre a quantidade de pessoas residentes - setor censitário, Figura 26 (A.1) - não coincide com a feição geográfica do dado de saúde - Figura 25, agregado final. Portanto, assumiu-se que há uma relação linear entre a quantidade de pessoas por área.

Dessa forma, inicialmente foram relacionados os dados do setor censitário (Figura 26 – A.2) com os dados do banco de dados em saúde (Figura 25, agregado final). Esse relacionamento foi possível usando as Regiões Administrativas (RA) do DF como fator chave. Como resultado, foi possível ter a informação sobre a quantidade de pacientes e informações do setor censitário por cada RA do DF (Figura 26 – B). Por fim, procedeu-se com a normalização dos dados, conforme apresentado pela Figura 26 – C.

Figura 26 - Fluxo dos processos para a segunda parte da criação do BDGeo.

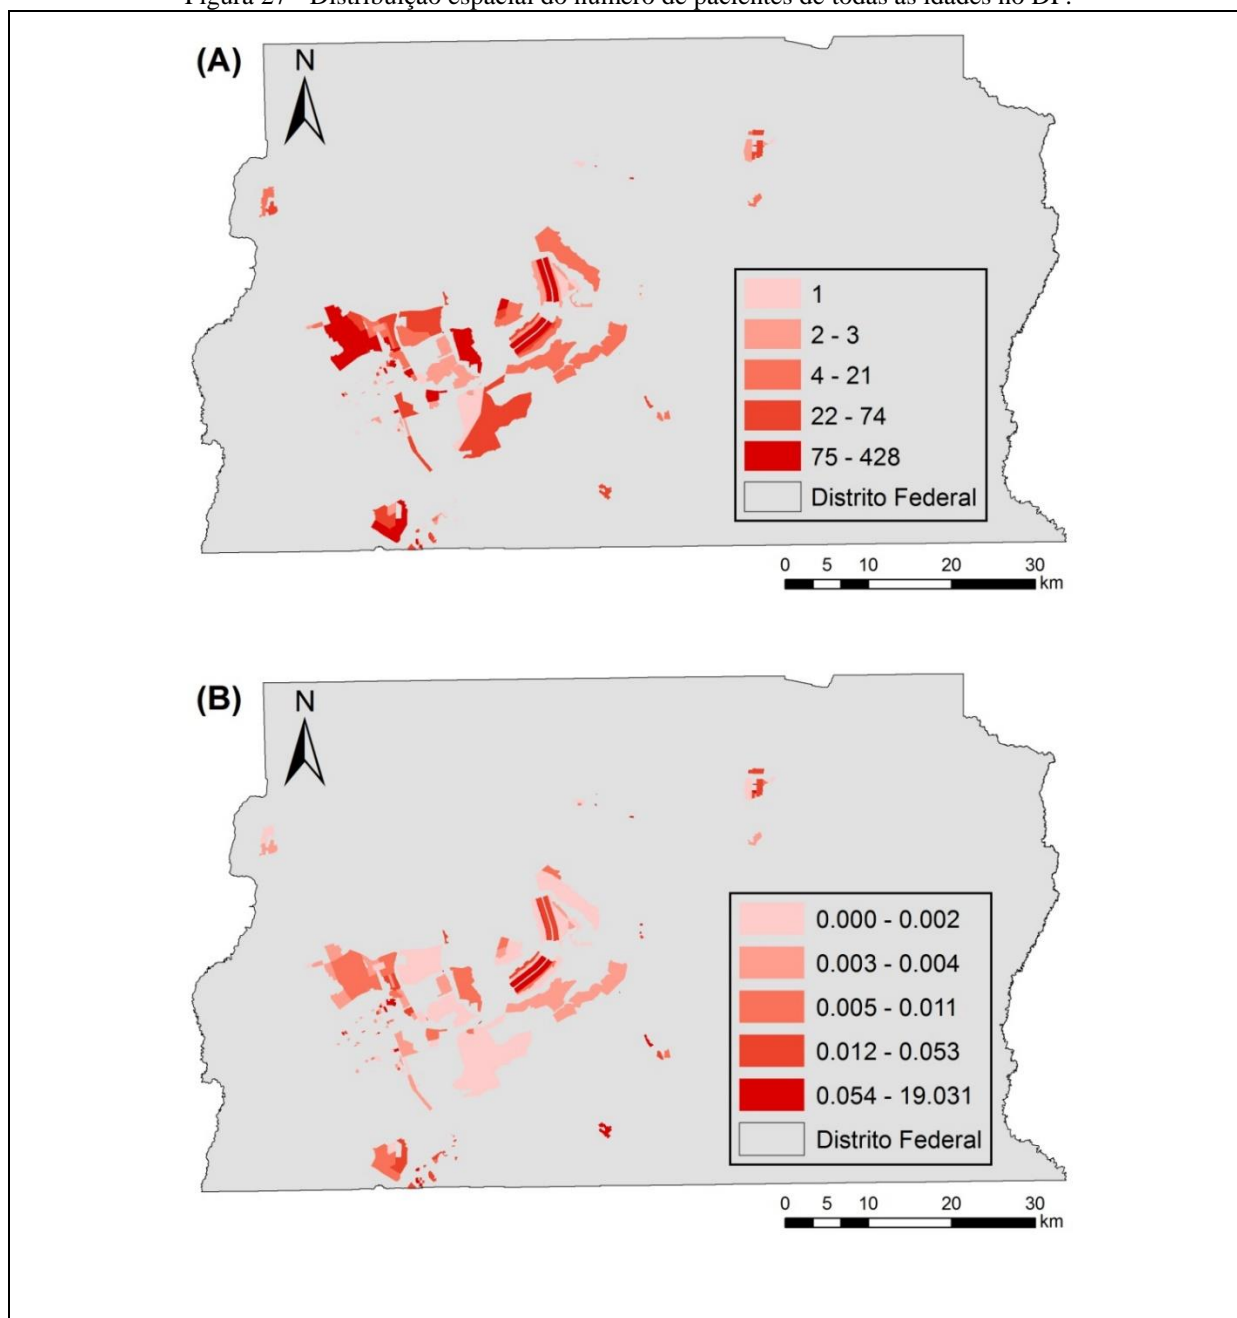


Fonte: Produção do próprio autor.

Nota: Mapa dos setores censitários do DF, classificados por RA (A.1); Tabela de atributos do mapa dos setores censitários (A.2); Tabela de atributos após o relacionamento com os dados do setor censitário (B); Procedimento final para o cálculo da taxa de incidência (C).

O comportamento da distribuição espacial referente ao número de pacientes de todas as idades nos grupos de endereços do DF pode ser observado na Figura 27, sendo o primeiro mapa (A) para os dados sem a taxa de incidência, conforme a primeira parte do método apresentado pela Figura 25; e o segundo mapa (B) para os dados com a taxa de incidência, conforme a segunda parte do método apresentado pela Figura 26.

Figura 27 - Distribuição espacial do número de pacientes de todas as idades no DF.



Nota 1: Número de pacientes sem a taxa de incidência (A); Número de pacientes com a taxa de incidência (B).

Nota 2: Método de classificação utilizado - quantile.

Nota 3: O apêndice C.1 também apresenta o mapa (A).

#### 4.3.2 AVALIAÇÃO DA RELAÇÃO ENTRE SAÚDE E POLUIÇÃO

O grupo etário dos pacientes de até 5 anos e dos pacientes com mais de 59 anos foram os únicos que apresentaram significância. Sendo que o grupo dos pacientes de até 5 anos apresentou significância somente para o poluente CO<sub>2</sub> e o CH<sub>4</sub>. Além disso, encontrou-se significância na correlação quando a análise foi para todas as idades. Os valores significantes de  $r$  (coeficiente de Pearson) variaram entre 0,2 e 0,3 (Tabela 10).

Tabela 10 - Matriz de correlação entre saúde e poluentes inventariados (valores de coeficiente de Pearson).

Poluentes	Até 5 anos	Entre 6 e 17 anos	Entre 18 e 59 anos	Acima de 59 anos	Todas as idades
NO <sub>x</sub>	0,14	0,07	0,12	0,25*	0,21*
NMHC	0,16	0,09	0,14	0,27*	0,22*
PTS	0,16	0,06	0,15	0,27*	0,22*
CO <sub>2</sub>	0,23*	0,09	0,13	0,29*	0,27*
CO	0,16	0,08	0,08	0,26*	0,25*
CH <sub>4</sub>	0,23*	0,12	0,12	0,31*	0,29*

\* correlação significativa ( $p \leq 0,01$ ).

Quanto à análise de regressão espacial, em todos os casos os valores dos coeficientes foram positivos, confirmando uma relação positiva entre o aumento da quantidade de poluente e o aumento de pacientes. Somente para o grupo etário de pacientes entre 6 e 17 anos não encontrou significância do coeficiente  $\beta$  (Tabela 11).

Tabela 11 - Resultado da análise de regressão espacial OLS.

Variável dependente	Variável preditora	Coefficiente $\beta$	Erro padronizado	Estatística-t	Probabilidade
Pacientes até 5 anos	NO <sub>x</sub>	0,296	0,136	2,173	0,031*
	NMHC	0,329	0,134	2,454	0,014*
	PTS	0,326	0,134	2,430	0,016*
	CO <sub>2</sub>	0,368	0,115	3,182	0,001*
	CO	0,353	0,122	2,891	0,004*
	CH <sub>4</sub>	0,377	0,112	3,347	0,001*
Pacientes entre 6 e 17 anos	NO <sub>x</sub>	0,071	0,046	1,533	0,127
	NMHC	0,080	0,045	1,756	0,080
	PTS	0,069	0,046	1,518	0,130
	CO <sub>2</sub>	0,053	0,040	1,335	0,183
	CO	0,071	0,042	1,691	0,092
	CH <sub>4</sub>	0,082	0,039	2,106	0,036*
Pacientes entre 18 e 59 anos	NO <sub>x</sub>	0,310	0,120	2,574	0,010*
	NMHC	0,329	0,118	2,784	0,005*
	PTS	0,334	0,118	2,822	0,005*
	CO <sub>2</sub>	0,302	0,103	2,935	0,003*
	CO	0,278	0,109	2,550	0,011*
	CH <sub>4</sub>	0,343	0,100	3,435	0,000*
Pacientes acima de 59 anos	NO <sub>x</sub>	0,346	0,112	3,088	0,002*
	NMHC	0,361	0,110	3,286	0,001*
	PTS	0,370	0,110	3,369	0,000*
	CO <sub>2</sub>	0,356	0,095	3,746	0,000*
	CO	0,323	0,101	3,199	0,001*
	CH <sub>4</sub>	0,340	0,093	3,643	0,000*
Pacientes de todas as idades	NO <sub>x</sub>	0,405	0,151	2,675	0,008*
	NMHC	0,431	0,148	2,898	0,004*
	PTS	0,434	0,148	2,917	0,004*
	CO <sub>2</sub>	0,456	0,128	3,555	0,000*
	CO	0,445	0,135	3,286	0,001*
	CH <sub>4</sub>	0,482	0,124	3,866	0,000*

\*  $p \leq 0,01$ .

#### 4.4 DISCUSSÃO

O principal desafio deste trabalho foi a organização e a consolidação da base de dados de saúde. Esse desafio esteve relacionado especificamente com a precisão da informação sobre o endereço do paciente. A burocracia e o sistema de endereçamento brasileiro são os principais fatores ligados a essa precisão.

A burocracia brasileira dificulta o acesso a certos tipos de dados. Neste estudo, por exemplo, os dados de saúde fornecidos não são precisos quanto à localização exata do endereço de cada paciente. Mesmo informando ao Ministério da Saúde que os dados seriam utilizados exclusivamente para pesquisa científica, o Ministério alegou que não poderia disponibilizar o número da residência dos pacientes, pois comprometeria a privacidade de cada paciente. Caso fosse disponibilizado o endereço completo, provavelmente iria diminuir o número de perda das observações deste estudo, que foi de 3.835 pacientes. Além disso, a consolidação dos dados no BDGeo seria mais eficiente, em termos de acurácia e precisão espacial.

Em relação ao sistema de endereçamento brasileiro, não há padronização. Cada cidade brasileira possui um padrão distinto. No DF, por exemplo, a ordem hierárquica entre lotes, quadras, conjuntos e setores nem sempre é obedecida em toda RA. Por exemplo, em muitas RAs não há conjuntos. Esse foi outro motivo que gerou descarte e perda de observações nas operações de criação do BDGeo.

Visto que não é viável a mudança do sistema de endereçamento brasileiro, ou a mudança dos endereços de áreas urbanas consolidadas, como as do DF, sugere-se a adoção do CEP como o principal classificador de endereço para criação de um BDGeo. Essa prática já é adotada, por exemplo, nos EUA.

Já há uma cultura entre a população americana de que o número do CEP residencial (*zipcode*, em inglês) é uma informação primordial para as atividades do dia-dia, tais como ir ao museu ou comparecer ao hospital para um atendimento. Além disso, nos EUA os dados do CEP são facilmente integrados com os dados do setor censitário, o que facilita a inclusão de variáveis sócio econômicas no BDGeo. Estudos epidemiológicos com enfoque espacial (GAN et al., 2010; BRUGGE et al., 2013; VILLANUEVA et al., 2013; ZOU et al., 2014; CHUM; O'CAMPO, 2015) têm se beneficiado dessa facilidade da disponibilidade dos dados nos EUA. Por fim, destaca-se que com a padronização do CEP, um BDGeo poderia ser criado automaticamente (neste estudo o BDGeo foi criado manualmente), por meio da ferramenta *Geocoding*, disponível nos programas de SIG.



Quanto aos resultados do teste de correlação e de regressão OLS, os resultados mostraram que há uma relação espacial significativa de causa e efeito entre poluição do ar e saúde humana, sobretudo para as crianças e para os idosos. Essa relação, em especial para esse grupo etário, já foi identificada anteriormente por Réquia e Abreu (2011), no quais avaliaram com base nos dados regionais do Datasus (não específico por endereços residenciais) e com base nas estações de monitoramento do DF. Além do DF, as crianças e os idosos também já foram identificados como os grupos mais vulneráveis em outras áreas, tais como, Curitiba (BAKONYI et al., 2004), Amazonas (OLIVEIRA, DE et al., 2012), São Paulo (ARBEX et al., 2012).

Este estudo apresenta algumas limitações. Primeiro, há uma divergência entre o número total de pacientes dos dados fornecidos para esta pesquisa (10.901 pacientes) e do número total de pacientes disponível no site do Datasus (DATASUS, 2015), que é 399.564 pacientes. Destaca-se que os dados disponíveis no site não apresentam informação do endereço residencial, por isso não foram utilizados. Portanto, os resultados deste estudo devem ser interpretados como uma amostra do total número de pacientes internados por doenças cardiorrespiratórias no DF entre 2008 e 2013. Outra limitação do estudo é quanto ao processo adotado para o cálculo da taxa de incidência (dados de saúde por população). Não é uma regra de que em todos os casos haverá uma relação linear entre a população residente e a respectiva área ocupada. Dessa forma, futuros estudos podem testar a aplicação da técnica de modelos dasimétricos, como já foi feito por Poulsen e Kennedy (2004), Freitas et al. (2012), Maantay et al. (2013). E por fim, a análise deste capítulo apresenta a limitação relacionada ao possível viés da distribuição espacial da ocorrência de internações. Esse viés está relacionado aos dados de saúde utilizados. Os dados de saúde são referentes às pessoas internadas nos hospitais públicos do DF, ou seja, não estão sendo consideradas as internações dos hospitais particulares. As informações dos hospitais particulares são fornecidas pelos planos de saúde e não pelo Datasus.

Sugere-se também para estudos futuros no DF a avaliação espacial de outras variáveis, tais como temperatura, umidade, renda, educação, uso do solo, fontes de poluição. O BDGeo proposto pelo presente artigo comporta facilmente a importação de dados de outros temas. A inclusão dessas variáveis é importante em estudos epidemiológicos, pois são consideradas como variáveis controles (ROBAA, 2011; SINGHE; JAMAL, 2012b; WANG et al., 2013; ZOU et al., 2014). Dessa forma, seria possível sugerir um modelo espacial para prever a ocorrência de doenças no DF, o que não foi o objetivo do presente estudo. A ausência dessas variáveis controles pode ter sido o motivo dos valores baixos de  $r$  da correlação de Pearson e dos coeficientes da regressão linear, conforme apresentado nos resultados desta análise.

Este foi um estudo inicial que objetivou mostrar que há meios alternativos para avaliar a relação entre saúde e poluição nas áreas urbanas com limitação na disponibilidade de dados. Nesse caso, dados de inventário é uma opção para suprir os dados de estações de monitoramento. E uma base geográfica de endereços juntamente com os dados do censo é a alternativa para espacializar os dados de saúde.

## Capítulo 5 - Análise espacial da ocorrência de doenças cardiorrespiratórias

---

### 5.1 APRESENTAÇÃO

Conforme apresentado na Introdução desta tese, as doenças cardiorrespiratórias são consideradas um problema sério de saúde pública (MORTIMER et al., 2012). A Organização Mundial de Saúde - *World Health Organization* (WHO, 2014b) – mostra que em 2012 as doenças do sistema cardiovascular e do sistema respiratório foram responsáveis pela morte de 17,5 milhões de pessoas e 4 milhões de pessoas, respectivamente. As crianças e os idosos são o grupo etário mais susceptíveis para apresentarem doenças cardiorrespiratórias (IGNOTTI et al., 2010; XU et al., 2013).

Ning et al. (2012) e Troncoso et al. (2012) destacam que o melhor entendimento da relação espacial da ocorrência de doenças pode contribuir para a gestão mais eficiente das políticas em sistemas de saúde e meio ambiente. Além do benefício ao bem estar humano, a implantação dessas políticas tem relação direta para a redução dos gastos públicos (TAYRA et al., 2012; BRAJER et al., 2012).

Estudos recorrentes têm utilizado métodos geoestatísticos para avaliar a relação espacial de causa e efeito entre duas ou mais variáveis, como por exemplo, a ocorrência de doenças em decorrência de fatores ambientais (SCOGGINS et al., 2004; HSU et al., 2012; GONZALEZ-BARCALA et al., 2013; LEIVA et al., 2013). No entanto, poucos estudos têm considerado a avaliação espacial da variável resposta como uma pré-etapa nas análises de causa e efeito. Como exemplo desses poucos estudos, cita-se o trabalho de Zou et al. (2014), no qual foi analisado o agrupamento espacial da exposição humana à poluentes atmosféricos nos EUA.

Mitchell (1999) e Kurland et al. (2012) destacam que a análise dos padrões espaciais é uma importante verificação antes de qualquer avaliação espacial de causa e efeito entre duas ou mais variáveis. Identificar os padrões espaciais é uma técnica que permite um melhor entendimento dos fenômenos geográficos. Além disso, é um guia para visualização das condições espaciais, para o cálculo de mudanças temporais e para comparação entre populações (MITCHELL, 1999).

Portanto, este capítulo apresentará a análise espacial da ocorrência de doenças do sistema cardiorrespiratório no DF. Essa análise foi baseada em quatro questionamentos: a) o tipo de distribuição espacial da ocorrência das doenças é agrupado (*clustered*), randômica (*random*) ou dispersa (*dispersed*)? b) qual é o grau de agrupamento para os valores altos ou valores baixos de ocorrência de doenças? c) qual é o comportamento da dependência espacial? d) considerando a variação espacial, em qual distância o tipo de distribuição (agrupada, randômica ou dispersa) começa a mudar?

Ressalta-se que as análises deste capítulo são referentes ao quarto objetivo específico desta tese – avaliação dos padrões de distribuição espacial da ocorrência de doenças cardiorrespiratórias. Destaca-se ainda que os resultados que serão descritos por este capítulo foram apresentados no evento *Urban Environmental Pollution*, realizado em Toronto, Canadá, no ano de 2014 (Apêndice A.2.2); e publicados no *Journal Health* (Apêndice B.3).

## 5.2 MÉTODO

### 5.2.1 DADOS

Os dados utilizados nesta análise se referem ao número de pacientes atendidos e internados nos hospitais do DF durante o período de 2008 a 2013 por motivo de doenças cardiorrespiratórias. Cada caso de atendimento está agrupado pelo polígono do endereço residencial do paciente. O total de observações desta análise foi de 7.066 pacientes, agrupados em 169 grupos de endereços residenciais. Nesse caso, os setores residenciais foram utilizados como nível de endereçamento para o processo de agrupamento. Com objetivo de atender o princípio da proporcionalidade do número de pacientes e o número total de pessoas, cada um dos 169 grupos de endereços (setores) de pacientes foi normalizado pelo dado demográfico, criando-se assim a taxa de incidência dos dados de saúde.

Destaca-se que os dados utilizados nesta análise são decorrentes do processamento dos dados do Datasus (2013), da Sedhab (2012) e do IBGE (2012b), conforme apresentado pelo Capítulo 4 - geodatabase para dados de saúde.

## 5.2.2 ANÁLISES

Todas as análises realizadas neste capítulo foram feitas pelos programas ArcGis - versão 10.2 (ESRI, 2013a) e GeoDA (LUC ANSELIN, 2015). Inicialmente, foi realizada uma análise exploratória dos dados. Nessa parte, foi avaliado o comportamento estatístico descritivo dos dados, além da forma com que os dados se apresentaram espacialmente após o processo da normalização do número de pacientes pela população.

Em seguida, foram aplicados quatro métodos de geoestatística com objetivo de responder os questionamentos apresentados no início deste capítulo. Os métodos aplicados foram: Global Moran's I (resposta à questão "a"); Getis-Ord General G (resposta à questão "b"); análises de semivariogramas (resposta à questão "c"); e multi-distance spatial cluster – K function (resposta à questão "d"). Devido ao predomínio da literatura internacional como meio de divulgação desses métodos, serão adotados nesta tese os nomes em inglês para alguns métodos.

### 5.2.2.1 Global Moran's I

O teste Global Moran's I tem o objetivo de avaliar a autocorrelação espacial. Especificamente neste estudo, trata-se da autocorrelação entre os 169 grupos de endereços de pacientes. A autocorrelação é avaliada com base em dois parâmetros: localização (grupos de endereços) e valor (número de pacientes em cada grupo de endereço). O resultado desse teste visa identificar se a distribuição dos dados é dispersa, randômica ou agrupada (*cluster*).

Destaca-se que este teste foi aplicado nas análises do Capítulo 3 - o teste foi apresentado no item 3.2.3. Porém, com objetivo de facilitar a leitura deste capítulo, será apresentada novamente a estrutura matemática utilizada pelo teste Global Moran's I (Equação 8).

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n W_{i,j} Z_i Z_j}{S_0 \sum_{i=1}^n Z_i^2}$$

Equação 8

Onde  $I$  é o Moran's index,  $Z_i$  é o desvio do número de pacientes para os polígonos que representam cada um dos 169 grupos de endereços;  $W_{i,j}$  é o peso espacial entre os polígonos  $i$  e  $j$ ;  $n$  é o número total dos grupos de endereços, que neste estudo foi 169; e  $S_0$  é o agregado de todos os pesos espaciais, representado pela Equação 9.

$$S_o = \sum_{i=1}^n \sum_{j=1}^n W_{i,j}$$

Equação 9

Vale destacar que o valor de  $I$  maior que zero indica que os valores dos números de pacientes são agrupados, ou seja, grupos de endereços vizinhos possuem quantidade de pacientes semelhantes. Por outro lado, valor de  $I$  igual a zero indica que a distribuição é randômica. E valores de  $I$  menor que zero indica que a distribuição é dispersa.

Por fim, destaca-se que essa classificação conforme o valor de  $I$  só pode ser aceita após o teste de hipóteses. Neste caso, a hipótese nula do teste Global Moran's  $I$  é que o valor de cada polígono (neste estudo, o número de pacientes) é randomicamente distribuído. A hipótese nula é rejeitada em duas situações. A primeira, quando o  $p$ -value é  $\leq 0,10$  e o  $z$ -score é  $\geq 1,65$ , então a distribuição é agrupada estatisticamente significativa. E a segunda, quando o  $p$ -value é  $\leq 0,10$  e o  $z$ -score é  $\leq -1,65$ , então a distribuição é dispersa estatisticamente significativa. Esse teste de hipótese foi apresentado de forma esquemática no Capítulo 3 - Figura 17.

### 5.2.2.2 Getis-Ord General G

O teste Getis-Ord General G tem o objetivo de identificar o grau de agrupamento - "cluster" entre os 169 grupos de pacientes observados. Especificamente, esse teste identifica os agrupamentos com valores altos (*Highs cluster*) ou baixos (*Lows cluster*), ou seja, se há agrupamentos de grupos de endereços com muitos pacientes ou agrupamentos de grupos de endereços com poucos pacientes.

Destaca-se que este teste também foi aplicado nas análises do Capítulo 3 - o teste foi apresentado no item 3.2.3. Porém, com objetivo de facilitar a leitura deste capítulo, será apresentada novamente a estrutura matemática utilizada por esse teste (Equação 10).

$$G = \frac{\sum_{i=1}^n \sum_{j=1}^n W_{i,j} X_i X_j}{\sum_{i=1}^n \sum_{j=1}^n X_i X_j}, \forall_j \neq i$$

Equação 10

Onde  $G$  é valor de General  $G$ ,  $X_i$  e  $X_j$  são os valores referentes a quantidade de pacientes para cada polígono  $i$  e  $j$  dos grupos de endereços;  $W_{i,j}$  é o peso espacial entre os polígonos  $i$  e  $j$  dos grupos de endereços;  $n$  é o número total de grupos de endereços, que neste estudo foi 169; e  $\forall_j \neq i$  indica que os polígonos  $i$  e  $j$  não podem ser o mesmo.

Vale destacar que os valores elevados de  $G$  indicam presença de agrupamento dos polígonos que possuem alto número de pacientes. Por outro lado, baixos valores de  $G$  indicam agrupamento dos polígonos com baixo número de pacientes.

A hipótese nula do teste Getis-Ord General  $G$  é que não há agrupamentos espaciais. A hipótese nula pode ser rejeitada em duas situações. Primeiro, quando o  $p$ -value é  $\leq 0,10$  e o  $z$ -score é  $\geq 1,65$ , então a distribuição é agrupada para valores altos. E a segunda, quando o  $p$ -value é  $\leq 0,10$  e o  $z$ -score é  $\leq -1,65$ , então a distribuição é agrupada para valores baixos. Esse teste de hipótese foi apresentado de forma esquemática no Capítulo 3 - Figura 17.

Por fim, destaca-se que o teste Getis-Ord General  $G$  é sensível a escolha da distância que é utilizada para o cálculo do relacionamento entre os polígonos. Neste estudo, foi escolhida a distância fixa, na qual cada polígono é analisado em termos do contexto dos polígonos vizinhos.

### 5.2.2.3 Análises de semivariogramas

De acordo com Chun and Griffith (2013), as análises de semivariogramas têm o objetivo de avaliar a dependência espacial do dado. Na análise de semivariograma pode ser testada a hipótese de que as observações mais próximas estão mais relacionadas entre si que as observações mais distantes - primeira lei da geografia, lei de Tobler – “*Everything is related to everything else, but near things are more related than distant things*” (TOBLER, 1970). Para isso, é utilizado um semivariograma empírico, no qual é representado pela diferença paritária entre os valores de dois pontos (Equação 11).


$$\gamma(d) = 0.5 \times \text{Average} \left[ (A_i - A_j)^2 \right]$$

Equação 11

Onde  $\gamma$  é o valor do semivariograma;  $d$  é a distância;  $A_i$  é o valor no local  $i$ ; e  $A_j$  é o valor no local  $j$ . Nesta análise, esses valores foram definidos pelo número de pacientes em cada local.

O resultado do semivariograma empírico é um gráfico no qual mostra todos os pares que foram comparados. No eixo X é apresentada a distância entre a localização dos pontos, e no eixo Y é apresentado os valores do semivariograma. A interpretação é baseada em: quanto menor o valor de Y, mais próximos estão os valores dos pontos comparados para a distância X. A Figura 28 apresenta um gráfico exemplificando os resultados de um semivariograma.

Figura 28 - Exemplo de um semivariograma.



Fonte: ESRI (2013).

Notas: modelo (model); média (averaged); distância (distance); metro (meter).

#### 5.2.2.4 Multi-distance spatial cluster – K function

O método K-function é usado para examinar as possíveis mudanças no tipo de distribuição espacial (distribuição agrupada ou dispersa) considerando variações de distância (MITCHELL, 1999). O processo matemático do método é apresentado pela Equação 12.

$$L(d) = \sqrt{\frac{A \sum_{i=1}^n \sum_{j=1}^n k_{i,j}}{\pi n(n-1)}}$$

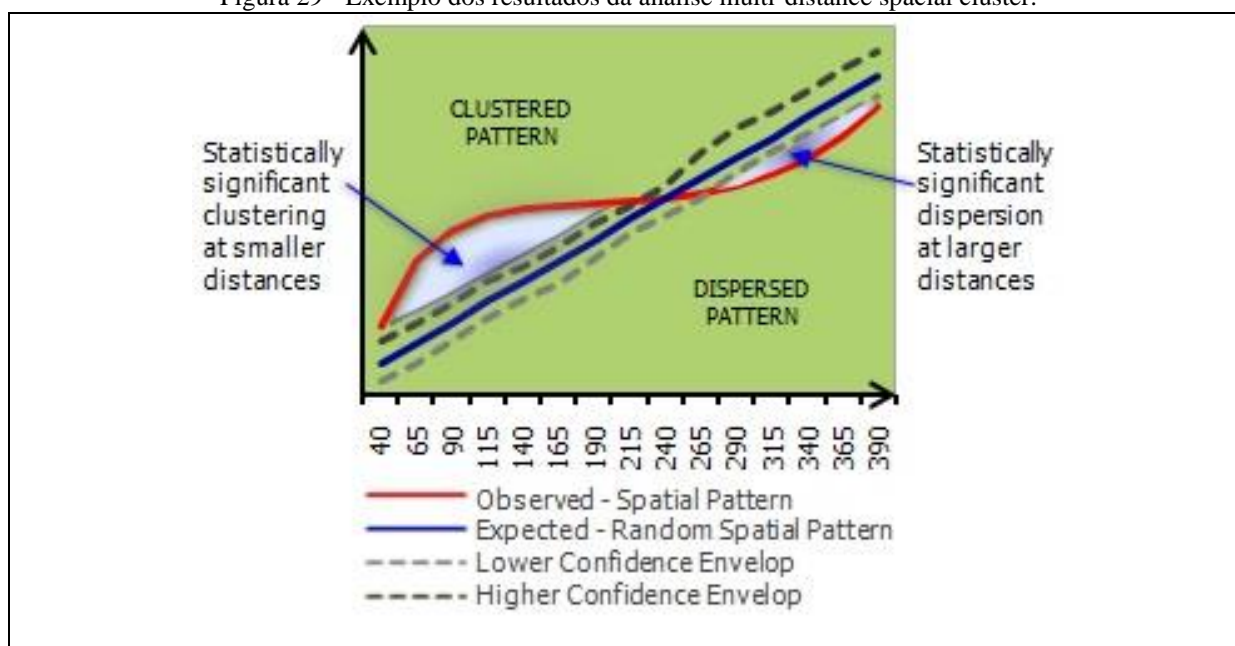
Equação 12



Onde  $L(d)$  é o valor de K-function;  $d$  é a distância;  $n$  é o total de grupos de endereços, que nesta análise foi 169;  $A$  é a área total dos grupos de endereços; e  $k_{i,j}$  é o peso. Esse peso terá o valor igual a 1 quando a distância entre  $i$  e  $j$  for menor que  $d$ , caso contrário, o peso será igual a zero.

O valor de  $k$  é calculado em várias distâncias e apresentado em um gráfico. Nesse gráfico são apresentados os valores observados, os valores esperados e o intervalo de confiança. A interpretação do gráfico é feita com observação nos seguintes parâmetros. Quando o valor observado de  $k$  para uma distância particular estiver acima da linha dos valores esperados, a distribuição é considerada agrupada. Quando o valor de  $k$  estiver abaixo da linha dos valores esperados, a distribuição é considerada dispersa. Quando o valor de  $k$  for maior que o limite superior do intervalo de confiança, o agrupamento para a distância em análise será estatisticamente significativa. E quando o valor de  $k$  for menor que o limite inferior do intervalo de confiança, a dispersão para a distância em análise será estatisticamente significativa (MITCHELL, 1999). A Figura 29 apresenta um gráfico exemplificando os resultados decorrentes das análises de multi-distance spatial cluster – K function.

Figura 29 - Exemplo dos resultados da análise multi-distance spatial cluster.



Fonte: ESRI (2013).

Notas: padrões de agrupamento (clustered pattern); padrões de dispersão (dispersed pattern); agrupamentos estatisticamente significante em distâncias curtas (statistically significant clustering at smaller distances); dispersão estatisticamente significante em distâncias longas (statistically significant dispersion at larger distances); valor observado – padrão espacial (observed – spatial pattern); valor esperado – padrão espacial randômico (expected – random spatial pattern); limite inferior do intervalo de confiança (lower confidence envelop); limite superior do intervalo de confiança (higher confidence envelop).

## 5.3 RESULTADOS

### 5.3.1 ANÁLISE EXPLORATÓRIA

Do total de 7.066 pacientes observados no estudo, 3.381 (47,8%) são pacientes da faixa etária de até 5 anos. O menor número foi do grupo de pacientes com idade entre 6 e 17 anos, no qual apresentou um total de 177 (2,5%). Quanto ao grupo de pacientes na faixa de 18 a 59 anos e o grupo dos que são maiores de 59 anos, tiveram um total de 1.908 e 1.600, respectivamente. Com o foco em uma análise descritiva espacial sem considerar a taxa de incidência dos dados, os 7.066 pacientes observados e distribuídos nos 169 grupos de endereços do DF tiveram uma média de distribuição de 41,81 ( $\pm 76,93$ ) pacientes por setor. Delimitando o foco para a análise de faixa etária, o grupo de pacientes de até 5 anos se destacou com a maior média, 20,1 ( $\pm 42,13$ ) pacientes por setor residencial. De forma geral, a média de distribuição de pacientes entre os setores teve uma variação elevada. Essa constatação é demonstrada pelo desvio padrão que se apresentou maior que o dobro da média (Tabela 12).

Tabela 12 - Estatística descritiva da distribuição de pacientes - dados sem a taxa de incidência.

Estatística descritiva	Até 5 anos	De 6 a 17 anos	De 18 a 59 anos	Acima de 59 anos	TODAS AS IDADES
Máximo	272	25	105	128	428
Soma	3.381	177	1.908	1.600	7.066
Média	20,10	1,05	11,29	9,47	41,81
Desvio padrão	42,13	2,71	19,58	17,76	76,93

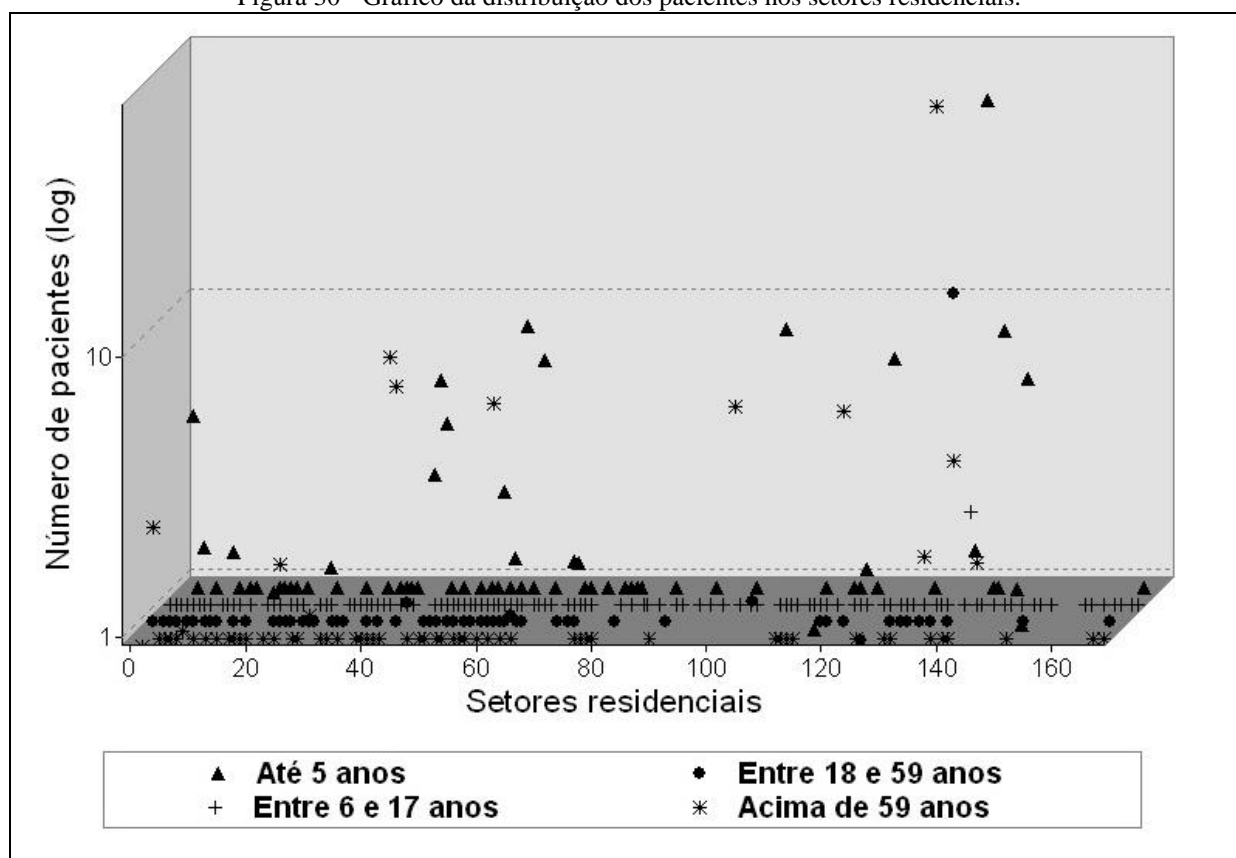
A Tabela 13 mostra os resultados da estatística descritiva espacial com os dados com as taxas de incidência (normalizados pela quantidade de pessoas residentes). O grupo etário acima de 59 anos apresentou a maior média 0,81 ( $\pm 5,85$ ). Em seguida teve o grupo das pessoas com até 5 anos, com média igual a 0,78 ( $\pm 4,18$ ). A menor média foi apresentada pelo grupo de 6 a 17 anos 0,02 ( $\pm 0,16$ ), idem quando os dados foram avaliados sem a taxa de incidência.

Tabela 13 - Estatística descritiva da distribuição de pacientes - dados com a taxa de incidência (número de pacientes / população).

Estatística descritiva	Até 5 anos	De 6 a 17 anos	De 18 a 59 anos	Acima de 59 anos	TODAS AS IDADES
Máximo	51,81	2,01	13,92	74,78	19,03
Soma	131,72	4,07	21,81	136,63	35,55
Média	0,78	0,02	0,13	0,81	0,21
Desvio padrão	4,18	0,16	1,08	5,85	1,48

O grupo das pessoas mais novas e o grupo dos mais idosos são os que apresentaram o maior número de pacientes (taxa de incidência). Outro ponto a se destacar é que os grupos de endereços residenciais com baixa ocorrência de pacientes praticamente foram os mesmos para as pessoas de todas as idades. Já os grupos de endereços que apresentaram número elevado de pacientes diferenciaram, sobretudo, entre as pessoas mais novas e as mais velhas (Figura 30).

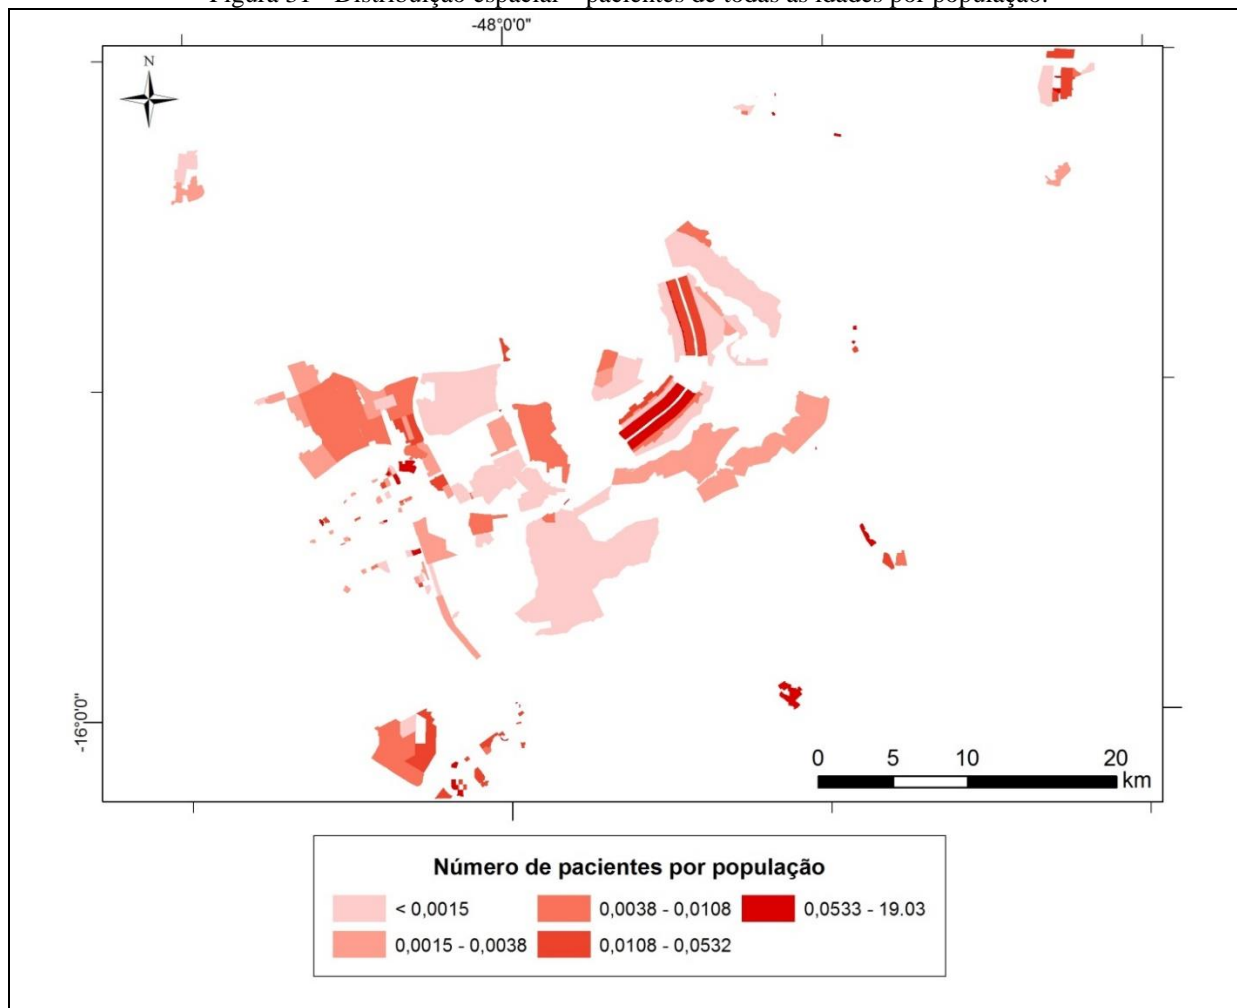
Figura 30 - Gráfico da distribuição dos pacientes nos setores residenciais.



Fonte: Produção do próprio autor.

A Figura 31 apresenta a distribuição espacial referente ao número de pacientes de todas as idades (taxa de incidência) nos grupos de endereços do DF.

Figura 31 - Distribuição espacial – pacientes de todas as idades por população.

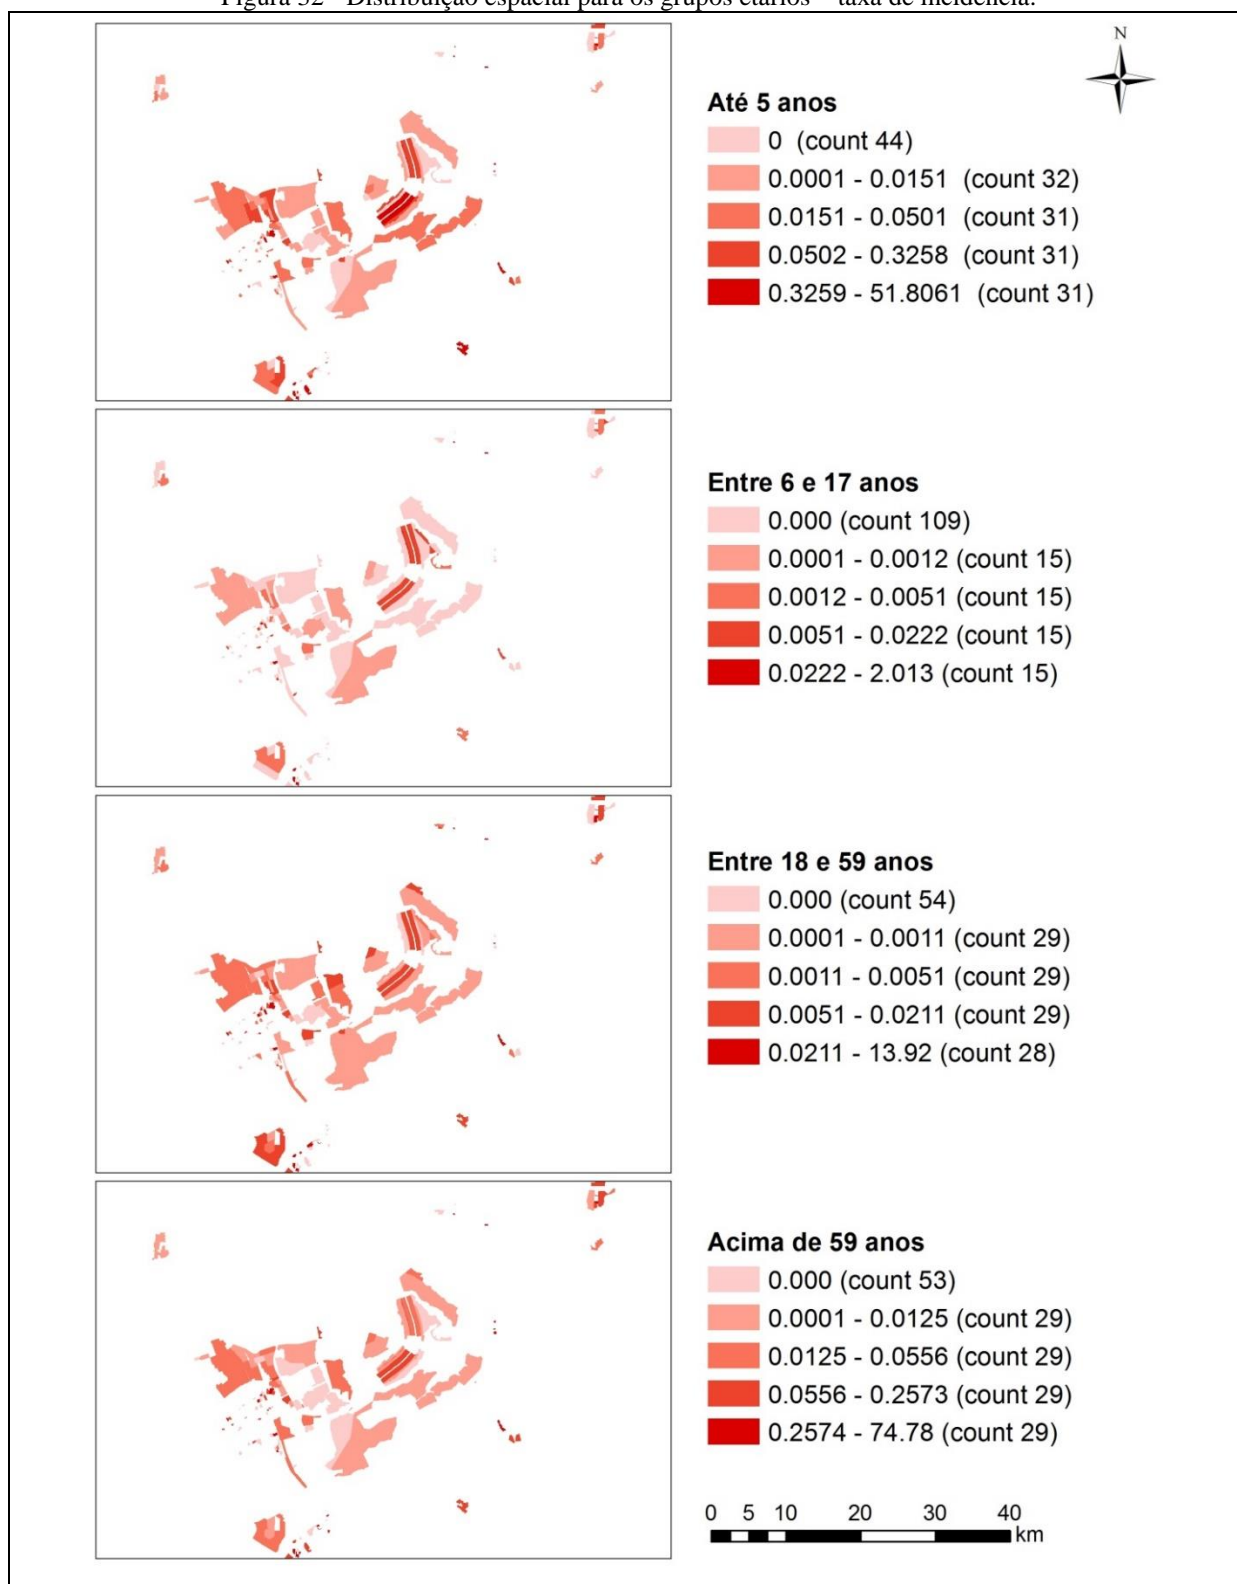


Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado - quantile.

A Figura 32 apresenta a distribuição espacial do número de pacientes conforme o grupo etário. Dentre os grupos apresentados, é possível perceber que os pacientes com idade entre 6 e 17 anos foram os menos afetados. Em 109 grupos de endereços (64%) não apresentaram casos de pessoas entre 6 e 17 anos. Por outro lado, o grupo dos pacientes com até 5 anos foram os mais afetados por doenças relacionadas ao sistema cardiorrespiratório. É possível perceber também que a distribuição espacial do grupo dos pacientes mais novos - até 5 anos (Figura 32) é semelhante à distribuição apresentada pela Figura 31 - todas as idades. Essa constatação reforça a ideia de que o grupo etário de até 5 anos são os mais vulneráveis a ter doenças cardiorrespiratórias.

Figura 32 - Distribuição espacial para os grupos etários – taxa de incidência.



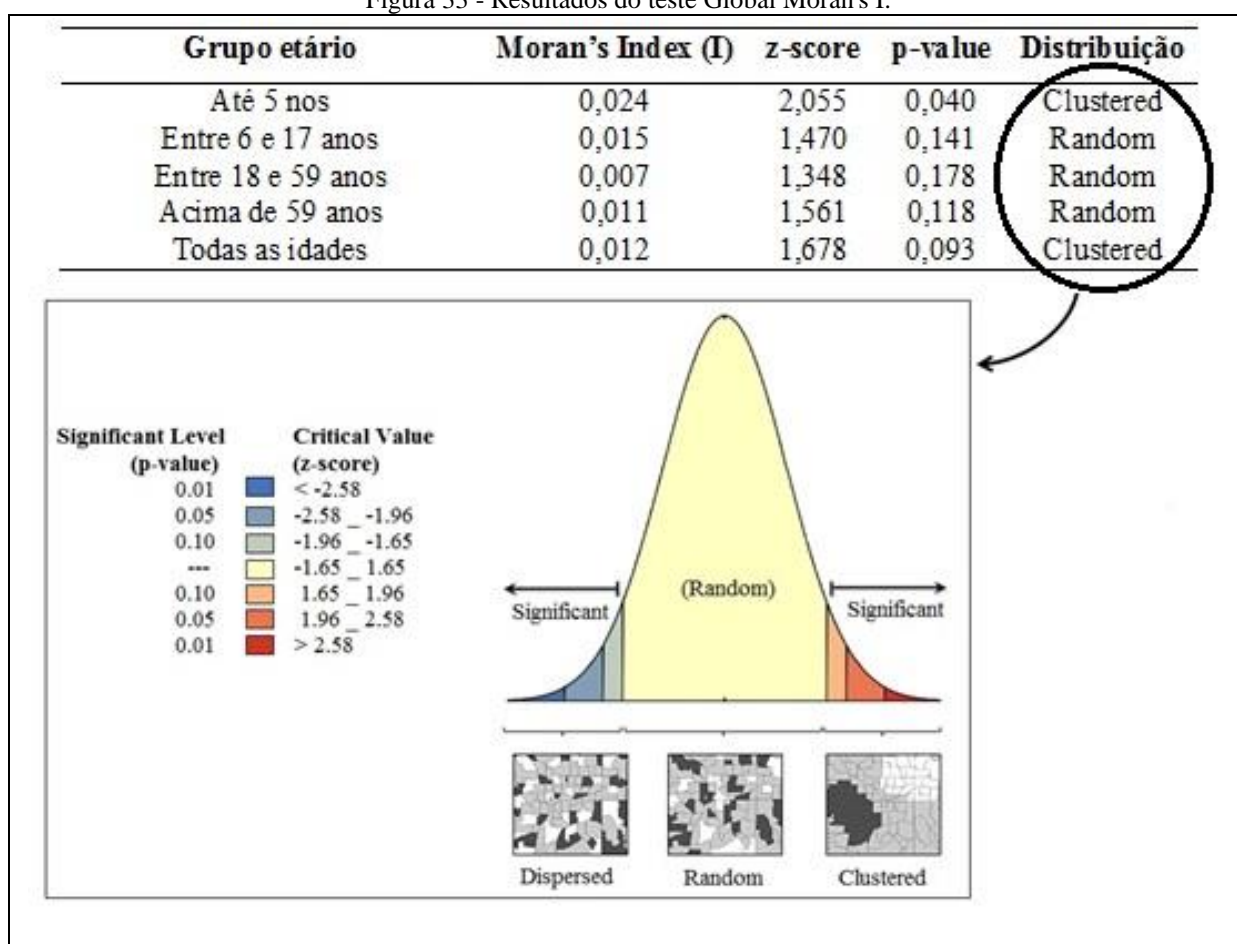
Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado - quantile; número de polígonos, ou seja, número de grupos de endereços (count).

### 5.3.2 AUTOCORRELAÇÃO ESPACIAL – GLOBAL MORAN'S I

Houve presença de autocorrelação espacial significativa do tipo *cluster* ( $I > 0$ ) quando a análise foi feita considerando as pessoas de todas as idades ( $I=0,012$ ,  $p<0,10$ ). Já com a análise separada por faixa etária, o grupo das pessoas com até 5 anos foi o único que apresentou autocorrelação espacial significativa ( $I=0,024$ ,  $p<0,10$ ), também do tipo *cluster*. Ainda vale destacar que as demais faixas etárias apresentaram tendência para distribuição do tipo *cluster* ( $I > 0$ ), mas sem significância (Figura 33).

Figura 33 - Resultados do teste Global Moran's I.



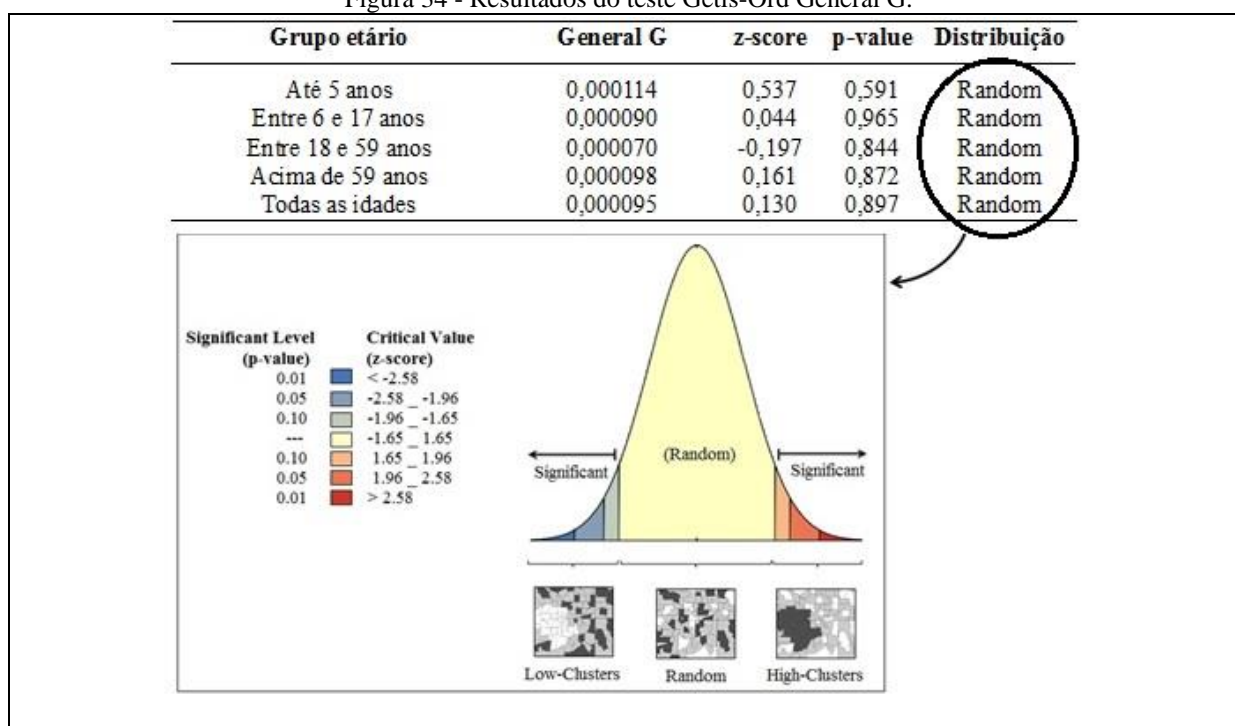
Fonte: Produção do próprio autor. Porém, a imagem sobre o gráfico do teste de significância tem como fonte a ESRI (2013), com edição.

Nota: distribuição agrupada (clustered); distribuição randômica (random); distribuição dispersa (dispersed); valores significantes (significant); valores críticos (critical value); nível de significância (significant level).

### 5.3.3 GRAU DE AGRUPAMENTO PARA VALORES ALTOS E BAIXOS – GETIS-ORD GENERAL G

Não houve presença de agrupamentos (*cluster*) espaciais para os grupos de endereços com muitos pacientes ou com poucos pacientes. Em todas as análises do teste Getis-Ord General G o tipo de distribuição se apresentou do tipo randômica devido aos valores de *z-score* próximos de zero (Figura 34).

Figura 34 - Resultados do teste Getis-Ord General G.






Fonte: Produção do próprio autor. Porém, a imagem sobre o gráfico do teste de significância tem como fonte a ESRI (2013), com edição.  
 Nota: distribuição agrupada com baixos valores (*low clusters*); distribuição randômica (*random*); distribuição agrupada com altos valores (*high clusters*); valores significantes (*significant*); valores críticos (*critical value*); nível de significância (*significant level*).

### 5.3.4 DEPENDÊNCIA ESPACIAL – ANÁLISES DE SEMIVARIOGRAMAS

A maior concentração dos pontos em todas as análises dos variogramas estão localizados na região dos baixos valores. O que significa que o número de pacientes é relacionado (semelhantes) no decorrer de todas as distâncias. Somente para os grupos etários dos pacientes mais novos (até 5 anos) e dos pacientes mais velhos (acima de 59 anos), houve presença de pontos nas regiões de altos valores. Os altos valores nessas regiões estão com maior concentração nas distâncias entre 1.500 e 5.000 m (Figura 35 e Figura 36).

Figura 35 - Gráficos de semivariogramas (grupos etários de até 59 anos).





Fonte: Produção do próprio autor.

Nota: até 5 anos (A); entre 6 e 17 anos (B); entre 18 e 59 anos (C); eixo X (distância); eixo Y (valor do variograma).



Figura 36 - Gráficos de semivariogramas (grupo etário acima de 59 anos e grupo de todas as idades).



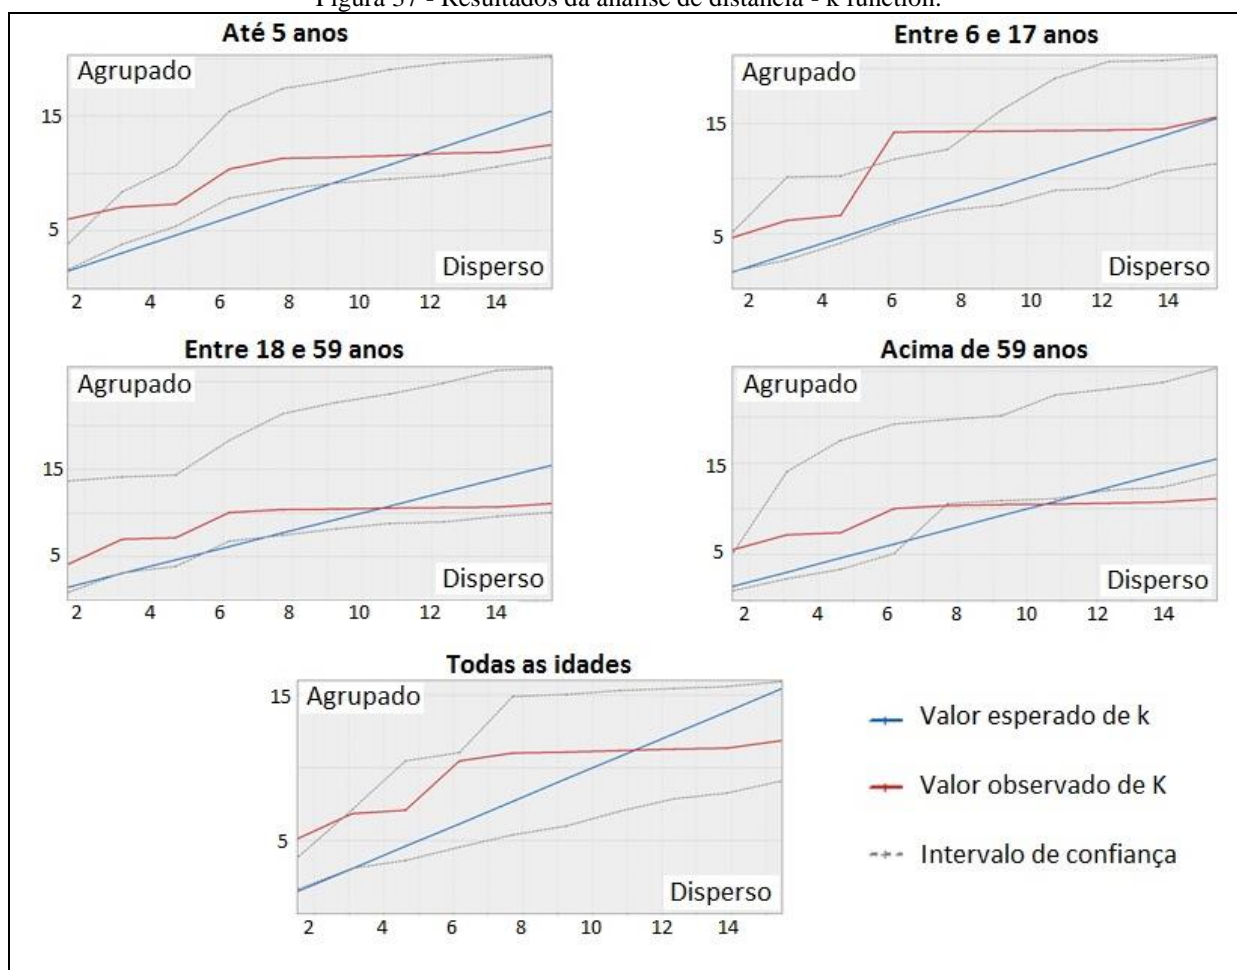
Fonte: Produção do próprio autor.

Nota: acima de 59 anos (D); todas as idades (E); eixo X (distância); eixo Y (valor do variograma).

### 5.3.5 ANÁLISE DA VARIAÇÃO CONFORME A DISTÂNCIA – K FUNCTION

As mudanças no tipo de distribuição são sensíveis às distâncias em todas as análises realizadas. Para os pacientes de até 5 anos de idade, há *cluster* significativo até  $\pm 2.500$ m. Acima dessa distância a distribuição espacial é randômica. Para os grupos de 6 a 17 anos e 18 a 59 anos, a distribuição espacial é randômica, com exceção dos pacientes entre 6 a 17 na distância de  $\pm 5.500$  e  $8.000$  m, no qual a distribuição se apresentou significativamente do tipo *cluster*. Para os pacientes mais idosos (acima de 59 anos), há *cluster* significativo nas distâncias curtas ( $\pm <1.000$  m) e entre  $\pm 7.500$  e  $\pm 10.500$  m. Acima de  $\pm 10.500$  m, a distribuição se apresenta do tipo dispersa para os pacientes mais idosos. E considerando todos os grupos de idades, há *cluster* significante até  $\pm 2.500$  m (Figura 37).

Figura 37 - Resultados da análise de distância - k function.



Fonte: Produção do próprio autor.

Nota: eixo X representa a distância na ordem de  $10^3$ ; eixo Y representa  $L(d)$  na ordem de  $10^3$ .

## 5.4 DISCUSSÃO

As crianças e os idosos representam o maior número da taxa de pacientes (pacientes por população) na análise realizada (média da taxa de pacientes por setores residenciais). Esse é um resultado esperado, pois a literatura tem mostrado que esse grupo etário são os mais vulneráveis a ter doenças cardiorrespiratórias (FAN et al., 2012; NANDASENA et al., 2012; HOFFMAN et al., 2012; ZOU et al., 2014).

O grupo dos pacientes de até 5 anos e o grupo de todas as idades foram os únicos que apresentaram autocorrelação espacial positiva, o que indica agrupamento espacial (*cluster*). Esse resultado sugere que pode haver um fator comum influenciando na ocorrência de doenças do sistema cardiorrespiratório nesses dois grupos. Considerando que esse fator pode estar relacionado com o meio ambiente (conforme apresentado na revisão da literatura desta tese), a distribuição espacial de alguma fonte de poluição atmosférica no DF é um exemplo desse possível fator.

Apesar da presente análise não ter tido como foco a avaliação dos agentes causadores das doenças cardiorrespiratórias, bem como a identificação do fator responsável pelo agrupamento (*cluster*) para os grupos de até 5 anos e todas as idades, sugere-se os meios de transportes (importante fonte de poluição atmosférica) como uma potencial variável explicativa. Estudos anteriores a este provaram que os poluentes atmosféricos emitidos pelos veículos automotores explicam o tipo de distribuição espacial da ocorrência de doenças cardiorrespiratórias nos EUA (ZOU et al., 2014). No entanto, essa hipótese ainda precisa ser testada no DF.

Especificamente para o grupo de todas as idades, destaca-se que há a possibilidade de que os pacientes mais novos (até 5 anos) estejam influenciando no resultado que indica agrupamento, pois os pacientes mais novos representam 47,8% da amostra estudada.

Apesar do grupo dos pacientes de até 5 anos e do grupo dos pacientes de todas as idades terem apresentado autocorrelação espacial positiva, não houve agrupamentos para valores baixos ou altos. Provavelmente porque esses valores são considerados geograficamente isolados no DF, ou seja, são *outliers*.

A análise de variogramas mostrou que a maior concentração dos pontos possui valores baixos no variograma, o que significa valores homogêneos quanto ao número de pacientes por setor residencial. O diferencial ocorreu somente para o grupo etário de até 5 anos e maior que 59 anos, no qual há uma pequena concentração de valores elevados no variograma, sobretudo entre

1.500 e 5.000 m. Esse diferencial demonstra que a distribuição espacial do número de pacientes é menos homogênea para o grupo de até 5 anos e para o grupo maior que 59 anos.

Especificamente para as análises da distribuição espacial conforme a distância (k function), o grupo de até 5 anos e o grupo acima de 59 anos apresentaram *cluster* significante em distâncias curtas (máximo até 2.500 m). Acima dessa distância a distribuição teve característica do tipo randômica ou dispersa. Esse resultado pode ser comparado com o resultado do semivariograma. Ou seja, a maior concentração dos pontos heterogêneos dos grupos dos mais novos e mais idosos estão entre 1.500 e 5.000 m (conforme apresentado no variograma). A heterogeneidade nessa faixa de distância pode estar influenciando a mudança de distribuição para randômica ou dispersa.

A análise apresentada por este capítulo possui algumas limitações. A primeira se refere à diferença de escala espacial entre os polígonos que representam os dados de saúde e os polígonos que representam os dados de população (conforme mencionado no Capítulo 4 - item 4.4). Sugere-se, portanto, a aplicação do método dasimétrico (POULSEN et al., 2004; FREITAS et al., 2012; SILVA, A. P. DA et al., 2013; MAANTAY et al., 2013) em futuros estudos com objetivo de comparação dos resultados. A segunda limitação está relacionada com o formato do dado geográfico usado para a análise espacial. O formato do dado é do tipo polígono, no qual representa a agregação dos dados de saúde. Dessa forma, foi considerado o centroide de cada polígono para a avaliação dos padrões espaciais. Essa é a técnica aplicada em SIG quando os dados de entrada não são do tipo ponto. Portanto, o uso dos centroides para cada polígono pode influenciar na identificação de alguns padrões, sobretudo, porque os polígonos não são uniformes. No entanto, destaca-se que essa limitação não invalida os resultados encontrados, visto que é uma limitação ligada à disponibilidade dos dados. Os estudos de Cook et al. (2013), Zou et al. (2014) e Tian et al. (2010) são exemplos de análises que já apresentaram resultados com base no centroide de cada polígono.

Destaca-se que este estudo foi o primeiro no Brasil sobre avaliação espacial das doenças cardiorrespiratória para todos os grupos etários (crianças, adolescentes, adultos e idosos). Além disso, foi o primeiro estudo em saúde ambiental para as cidades brasileiras que testou os métodos de geoestatística – autocorrelação, nível de *cluster*, semivariogramas e k-function.

Tendo como parâmetro de observação mais geral nos estudos epidemiológicos brasileiros, o presente estudo complementa as pesquisas nacionais que já utilizaram alguma abordagem geoestatística para avaliações epidemiológicas. Cita-se, por exemplo, as pesquisas que já avaliaram a ocorrência de tuberculose em São Paulo (BARROZO, 2014), o risco relativo de

nascimento pré-termo em São Paulo (MIRANDA et al., 2014), a prevalência de hipertensão arterial e diabetes na população de Botucatu - São Paulo (CAMPOS et al., 2008), a ocorrência de suicídio em São Paulo (BANDO et al., 2012), a distribuição espacial da mortalidade por doenças cardiovasculares no Paraná (MULLER et al., 2012), a ocorrência das doenças respiratórias em São Paulo (ALMEIDA, 2013).

Portanto, o presente estudo identificou que há uma heterogeneidade na ocorrência de internações por doenças cardiorrespiratórias no DF, sobretudo quando se observa grupos etários de pacientes. Este estudo compõe um conjunto de ferramentas e orientações para o desenvolvimento de políticas públicas em saúde, meio ambiente e planejamento urbano.

## Capítulo 6 - Áreas prioritárias para mensuração da exposição humana à poluição atmosférica

---

### 6.1 APRESENTAÇÃO

Conforme apresentado no Capítulo 1, a poluição atmosférica em centros urbanos tem sido uma das principais causas do surgimento de doenças ao ser humano, sobretudo as doenças vinculadas ao sistema respiratório e circulatório. Nesse sentido, a identificação de áreas prioritárias para a mensuração da exposição humana à poluição do ar é considerada uma relevante fonte de informação para gestão em saúde pública (KATSOYIANNIS et al., 2012; LEE et al., 2012).

O monitoramento da poluição do ar é o principal meio utilizado por instituições de pesquisas e governamentais para identificar a exposição que uma população está sujeita por respirar um ar poluído (CAMARGO et al., 2011; AUSTIN, E. et al., 2013). No entanto, a implantação de equipamentos que realizam amostragens da concentração de poluentes presentes na atmosfera ainda apresenta certos desafios. Esses desafios estão relacionados ao custo de implantação e operação (THAMBAVANI; PRATHIPA, 2012), e, sobretudo, à determinação do local para a instalação do equipamento (ADEME, 2002). Especificamente quanto à determinação do local de instalação, o que se percebe é que ainda não há um conjunto de critérios claros baseados em informações qualitativas e quantitativas, com base na realidade de cada área urbana.

Diante desse contexto, métodos de suporte à decisão baseados em análises espaciais podem conduzir para uma melhor escolha dos pontos de amostragem da qualidade do ar. Dentre o conjunto de métodos já apresentados pela literatura, destacam-se o modelo multicriterial conhecido como AHP (*Analytic Hierarchy Process*) e a modelagem em SIG.

Em síntese, o método AHP gera pesos de forma hierárquica para todos os atributos e indicadores que compõem um problema em análise (SAATY, 1991). O método foi desenvolvido por Saatty (1991) e vem sendo utilizado constantemente por diferentes áreas científicas, dentre elas, as ciências ambientais (BARROS et al., 2007; TARSO et al., 2009).

Quanto aos modelos em SIG, também são destacados por serem aplicados em várias áreas. Um dos diferenciais do SIG é a possibilidade de entender as relações espaciais das variáveis

estudadas, o que pode ser correlacionado com outras variáveis, levando a um melhor entendimento da questão em análise (LI et al., 2012).

Portanto, este capítulo apresentará uma proposta para a identificação de áreas prioritárias para o monitoramento da exposição humana às fontes de poluição do ar monitoramento da poluição do ar. Essa proposta é referente ao quinto objetivo específico desta tese.

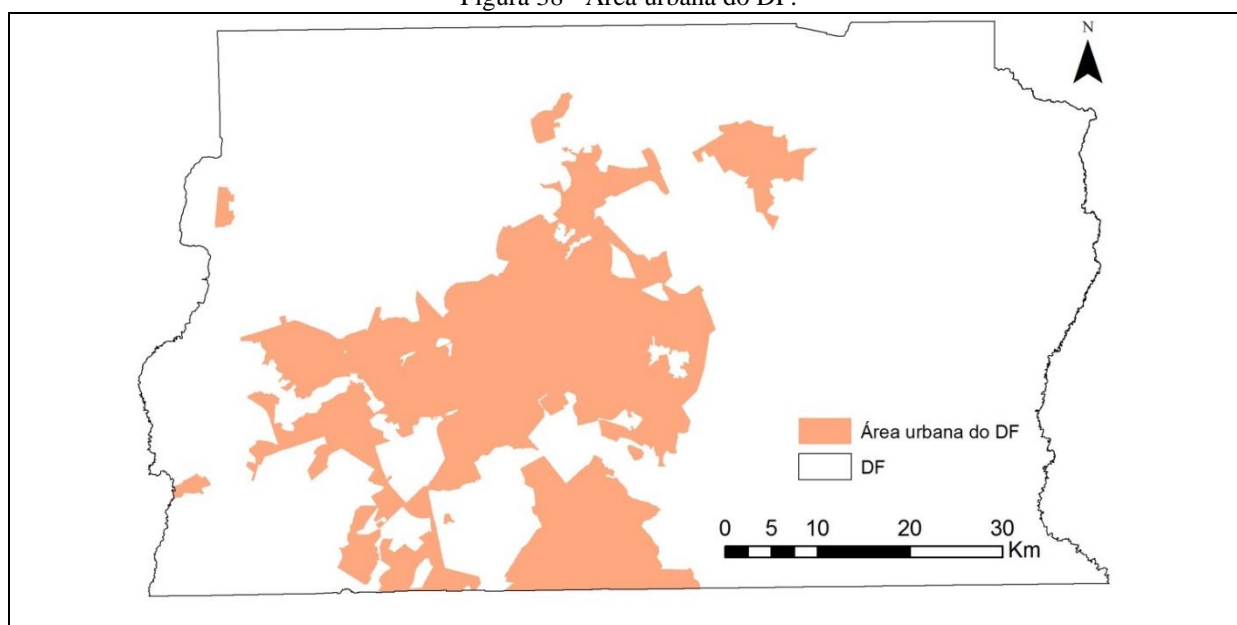
Destaca-se que os resultados que serão descritos neste capítulo foram apresentados no evento *Environmental Health*, realizado em Boston, USA, no ano de 2013 (Apêndice A1.1); no evento *Urban Environmental Pollution*, realizado em Toronto, Canadá, no ano de 2014 (Apêndice A.2.1); e publicados no *Journal of the Air & Waste Management Association* (Apêndice B.4).

## 6.2 MÉTODO

### 6.2.1 DELIMITAÇÃO DA ÁREA DE ESTUDO

Partindo do pressuposto de que a exposição humana à poluição atmosférica varia em função do tipo de ambiente, urbano ou rural (SCOGGINS et al., 2004; JOLY; PEUCH, 2012; CHOWDHURY et al., 2013; XIA et al., 2014), a presente análise foi delimitada somente para a área urbana do DF. A Figura 38 apresenta os limites da área urbana do DF, conforme os dados do setor censitário (IBGE, 2012a).

Figura 38 - Área urbana do DF.



Fonte: Produção do próprio autor.

## 6.2.2 ANÁLISE MULTICRITÉRIO DO TIPO AHP

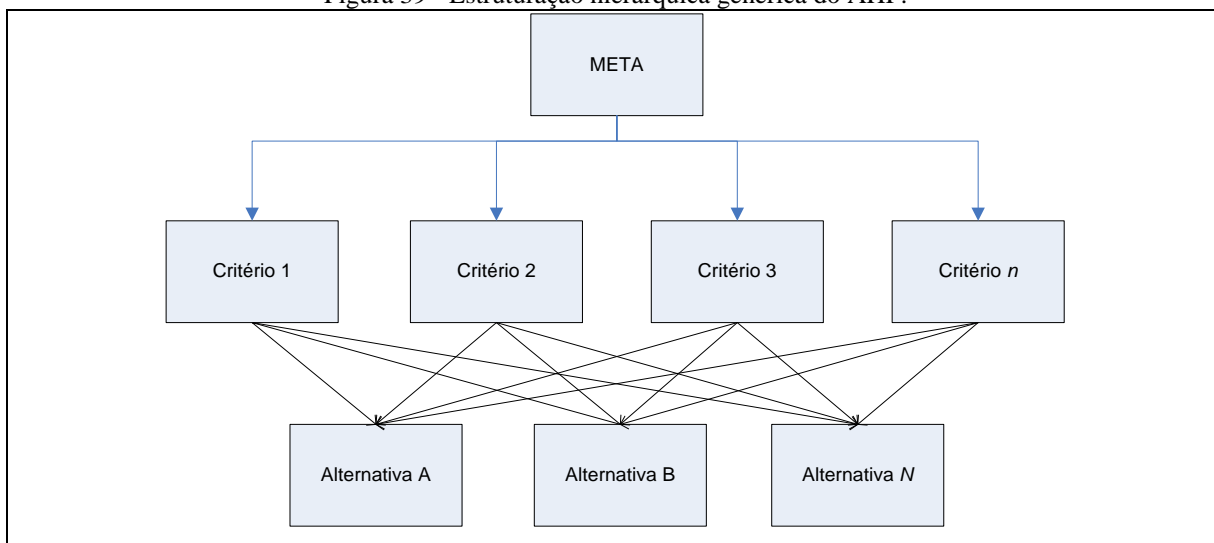
As análises multicritérios são conhecidas por fornecerem subsídios às tomadas de decisões quando está se tratando de um problema com multiopções. No meio acadêmico, é conhecida pelos Métodos Multicritérios de Apoio à Decisão - MMAD (GARTNER, 2001, 2010).

Os tipos de MMAD começaram a ser desenvolvidos a partir da década de 60. Dentre os que foram desenvolvidos, pode-se destacar o *Analytic Hierarchy Process* - AHP, o *Measuring Attractiveness by a Categorical Based Evaluation Technique* - MACBETH, o *Preference Ranking Organization Method for Enrichment Evaluations* - PROMETEE, o *Elimination et Choix Traduisant la Réalité* - ELECTRE (GARTNER, 2001, 2010).

Os métodos MMAD são característicos pela multidisciplinaridade. Em meio às opções, o AHP é um dos mais utilizados para as análises ambientais, como: auxílio para determinação das áreas de influência, planejamento de bacias hidrográficas, apoio à gestão de resíduos, planejamento para o sistema de energia e avaliação de impactos ambientais (GREENING; BERNOW, 2004; GARTNER; GAMA, 2005; FONTANA et al., 2013).

O AHP foi desenvolvido por Saatty (1991) na década de 70. O método tem como premissa a geração de pesos para todos os critérios e alternativas que compõem um problema em análise. Destaca-se que o problema a ser analisado é determinado pela meta do modelo, compondo assim, uma rede hierárquica entre os critérios e alternativas (ROY; VINCKE, 1984; SAATY, 1990, 1991; GARTNER, 2001) - Figura 39.

Figura 39 - Estruturação hierárquica genérica do AHP.



Fonte: Saatty (1991).



Após a definição da rede hierárquica do modelo AHP, conforme o modelo genérico apresentado pela Figura 39, a etapa seguinte se passa pela atribuição dos pesos. Os pesos são julgados de forma paritária, obedecendo cada nível hierárquico estabelecido. A escala de pesos proposta por Saatty (1991) varia de 1 a 9, sendo que: 1 = importância igual; 3 = importância fraca; 5 = importância forte; 7 = importância muito forte; 9 = importância absoluta; e 2, 4, 6, 8 são os valores de importância intermediária. Após o julgamento, os valores de importância são modelados conforme o sistema matricial (A) descrito pela Equação 13.

$$A = \begin{bmatrix} a_{11} & \dots & a_{1j} & \dots & a_{1n} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ a_{i1} & \dots & a_{ij} & \dots & a_{in} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ a_{n1} & \dots & a_{nj} & \dots & a_{nn} \end{bmatrix}$$

Equação 13

Em que,  $a_{ij}$  é o valor de  $\alpha$ ;  $a_{ji} = \frac{1}{\alpha}$ ;  $a =$  comparação paritária;  $\alpha$  é o valor da importância. A solução da matriz (A) é encontrada pelo cálculo do autovalor  $V_i$ , descrito pela Equação 14.

$$V_i = \left( \prod_{j=1}^n a_{ij} \right)^{1/n}$$

Equação 14

A normalização da Equação 14 gera o autovetor de prioridades W, no qual representa as importâncias relativas, ou seja, os pesos de cada um dos critérios e subcritérios definidos na estrutura hierárquica. O cálculo de W é representado pela Equação 15.

$$W_{n \times 1} = \begin{bmatrix} W_1 = V_1 / \sum_{i=1}^n V_i \\ W_2 = V_2 / \sum_{i=1}^n V_i \\ W_3 = V_3 / \sum_{i=1}^n V_i \\ W_n = V_n / \sum_{i=1}^n V_i \end{bmatrix}$$

Equação 15

A multiplicação da matriz (A) pelo valor formado por cada ponderação  $W = (W_1, W_2, \dots, W_n)$  gera o valor de  $Aw$ , conforme apresentado pela Equação 16.

$$A = \begin{bmatrix} W_1/W_1 & \dots & W_1/W_j & \dots & W_1/W_n \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ W_i/W_1 & \dots & W_i/W_j & \dots & W_i/W_n \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ W_n/W_1 & \dots & W_n/W_j & \dots & W_n/W_n \end{bmatrix} \begin{bmatrix} W_1 \\ \vdots \\ W_j \\ \vdots \\ W_n \end{bmatrix} = n \begin{bmatrix} W_1 \\ \vdots \\ W_j \\ \vdots \\ W_n \end{bmatrix} = nW$$

Equação 16

O valor de  $a_{ij}$  é subjetivo, pois foi definido pelos decisores que fizeram o julgamento dos pesos. Portanto, deve haver uma distância entre  $a_{ij}$  e os valores atuais de  $W_i / W_j$ . Assim, a relação  $Aw = nW$  não pode ser calculada diretamente. Saaty (1991) sugere a Equação 17 e Equação 18 como cálculo dessa relação.

$$\lambda_{max} = \frac{1}{n} \left( \frac{W_1}{W_1} + \frac{W_2}{W_2} + \dots + \frac{W_n}{W_n} \right)$$

Equação 17

Portanto,

$$Aw = \lambda_{max}w$$

Equação 18

Dessa forma, é obtido o vetor de prioridades. Saaty (1991) ainda propõe uma validação para os pesos atribuídos. A validação é realizada pelo valor do índice de inconsistência, conforme demonstrado pela Equação 19.

$$IC = \frac{\lambda_{max} - n}{n - 1}$$

Equação 19

É recomendável que o valor de IC seja menor que 0,10; o que assegurará a lógica racional no processo de julgamento. Por fim, o valor global dos pesos para cada alternativa e critério é estabelecido pela Equação 20.

$$V(a) = \sum_{j=1}^n W_j v_j(a)$$

Equação 20

Em que,  $V(a)$  é o valor global;  $W_j$  é a importância relativa do critério  $j$ ;  $v_j$  é o nível de preferência da alternativa no critério  $j$ . Destaca-se que a Equação 20 deve satisfazer as seguintes relações:

$$\sum_{j=1}^n W_j = 1 \quad v_j(a)$$

$$0 < W_j < 1 \quad (j = 1, \dots, n)$$

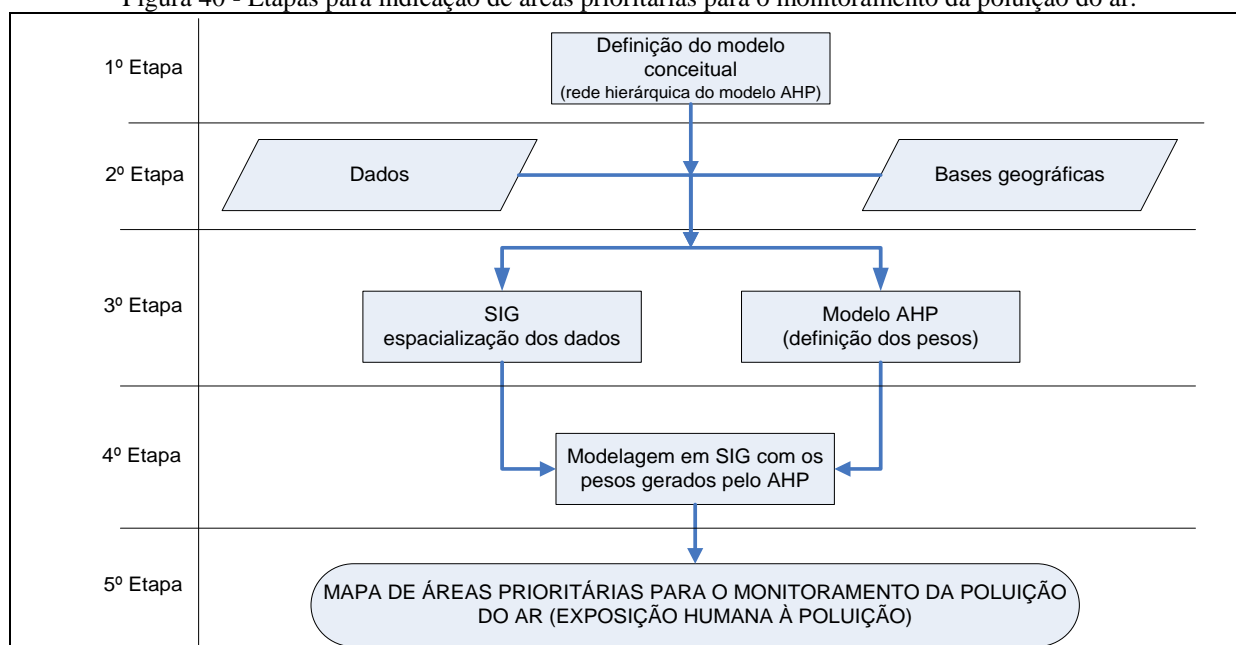
Por fim, Saatty (1991) apresenta as seguintes vantagens do uso do AHP como método colaborativo ao processo de tomada de decisão:

- a) Unidade: o AHP fornece um único e flexível modelo para uma variedade de problemas que necessitam de estruturas;
- b) Repetição do processo: o AHP possibilita as pessoas a refinarem a definição do problema e melhorar o julgamento por meio do processo de repetição;
- c) Julgamento e consenso: o AHP opera com a representação dos resultados decorrente da possibilidade de uma diversidade de julgamentos;
- d) Consistência: o AHP possui uma lógica na consistência dos julgamentos utilizados para a definição das prioridades;
- e) Mensuramento: o AHP fornece uma escala para o mensuramento das prioridades;
- f) Estrutura hierárquica: o AHP reflete na tendência natural da mente para a classificação dos elementos de um sistema com diferentes níveis e grupos;
- g) Interdependência: o AHP permite a interdependência por meio do pensamento não linear;
- h) Complexidade: o AHP integra a abordagens dedutivas para a solução de problemas complexos.

### 6.2.3 ETAPAS PARA IDENTIFICAÇÃO DAS ÁREAS PRIORITÁRIAS

A proposta para identificação de áreas prioritárias para o monitoramento da qualidade do ar foi dividida em 5 etapas. A primeira foi caracterizada pela definição do modelo conceitual, no qual já foi possível estabelecer a rede hierárquica do modelo AHP. A segunda etapa representou o levantamento dos dados juntamente com as bases geográficas. A terceira consistiu na espacialização dos dados levantados e na definição dos pesos para o modelo AHP. Na quarta etapa foi realizado o processo de modelagem com as informações oriundas da terceira etapa. E na última fase foi gerado um mapa que indica as áreas prioritárias para a mensuração da exposição humana à poluição do ar (Figura 40).

Figura 40 - Etapas para indicação de áreas prioritárias para o monitoramento da poluição do ar.

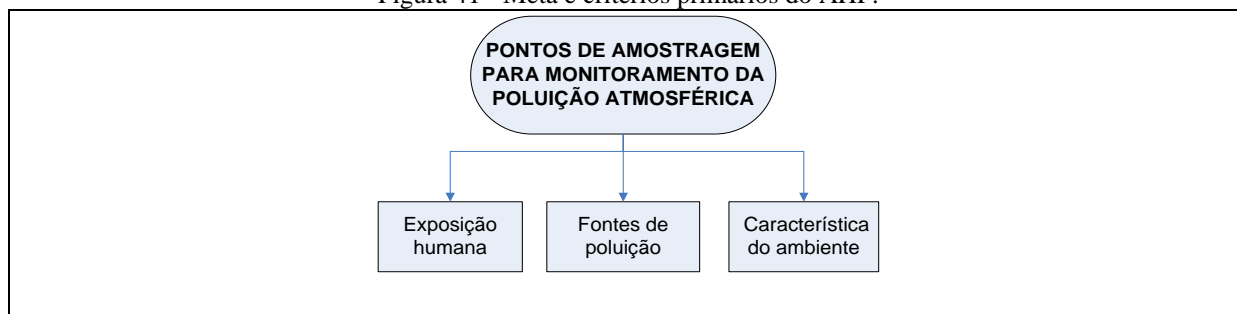


Fonte: Produção do próprio autor.

#### 6.2.3.1 Modelo conceitual, dados e bases geográficas

O modelo conceitual é representado pela própria rede hierárquica definida pelo AHP. Lembrando-se que a exigência do método AHP é que inicialmente deve-se identificar a meta a ser atingida, para então, estruturar hierarquicamente os respectivos critérios e alternativas, conforme ilustrado pela Figura 39. Assim, tendo como meta desta pesquisa a identificação das áreas prioritárias para a amostragem da poluição atmosférica, o modelo estruturado se iniciou com três critérios primários: exposição humana, fontes de poluição e característica do ambiente (Figura 41).

Figura 41 - Meta e critérios primários do AHP.



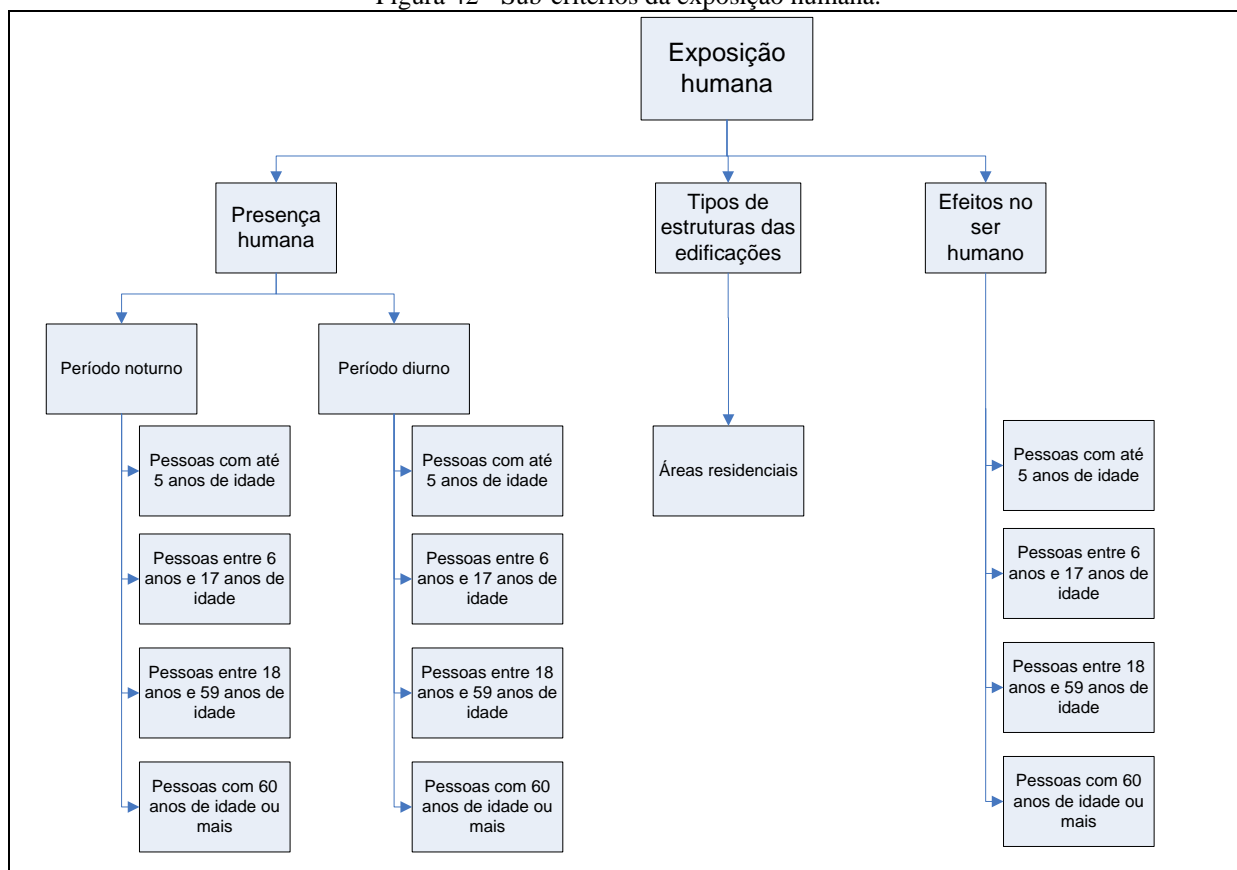
Fonte: Produção do próprio autor.

### 6.2.3.1.1 Exposição humana

A escolha do critério exposição humana foi baseada na própria definição inicial que motivou o desenvolvimento desta análise. Ou seja, que o monitoramento da poluição atmosférica é a principal ferramenta para mensurar a exposição de uma população ao ar poluído.

O critério exposição humana foi representado pelos subcritérios presença humana, tipos de estruturas das edificações e efeitos no ser humano (Figura 42).

Figura 42 - Sub-critérios da exposição humana.



Fonte: Produção do próprio autor.

O subcritério presença humana, que é a densidade demográfica da população do DF, foi classificado com base na variação temporal e de faixa etária da população. Essa classificação foi realizada pelo fato de que há uma diferença na concentração de poluentes atmosféricos entre o período diurno e o período noturno (DESHMUKH et al., 2012; DIAS et al., 2012), além de que a vulnerabilidade aos efeitos do ar poluído pode ser diferenciada conforme a faixa etária de uma pessoa (ROSENLUND; PICCIOTTO; et al., 2008; SOLOMON et al., 2011).

Assim, para o período noturno, utilizaram-se as informações do censo do DF do ano de 2010, levando-se em consideração a faixa etária (IBGE, 2012b). O levantamento demográfico do censo tem como referência a quantidade de pessoas por residência, na qual podem ser agrupadas pelo setor censitário. Nesse sentido, foi estimado que à noite a maior parte da população estaria concentrada nas próprias residências, conforme o dado do censo.

Já no período diurno, estimou-se que as pessoas com até 17 anos de idade estariam concentradas nas instituições educacionais. O ensino infantil representaria as pessoas com até 5 anos de idade, e o ensino fundamental e médio representariam as pessoas entre 6 e 17 anos. Nesse sentido, os dados da SEDF (2012) foi a base para as informações referentes a quantos alunos estavam matriculados nas instituições educacionais do DF, conforme o nível escolar. Os dados brutos da SEDF (2012) são disponibilizados em formato de planilha Excel, tendo como via de acesso o website da Secretaria Educacional do DF. Para transformar os dados da SEDF (2012) em uma informação espacial, foi utilizada a base geográfica da Sedhab (2012), na qual apresenta a localização pontual de todos os estabelecimentos de ensino do DF. A ferramenta *Join* do programa ArcGis (ESRI, 2013a) foi utilizada para o relacionamento dessas duas bases de dados.

Para as pessoas entre 18 e 59 anos do período diurno, foram levados em consideração os pontos de geração de empregos, que podem ser definidos pelas áreas comerciais e de serviços e públicas. Estimou-se que a maior parte da população com essa idade estaria presentes nesses lugares durante o período diurno. Dessa forma, os dados utilizados foram referentes ao consumo de água registrado pelos hidrômetros de áreas comerciais, áreas de serviços e áreas públicas no ano de 2011. O raciocínio foi que, quanto maior o consumo de água, maior o número de pessoas. Esses dados foram disponibilizados pela (CAESB, 2011).

E para as pessoas acima de 60 anos do período diurno, estimou-se que grande parte desse grupo populacional não estaria mais ativa na área profissional, o que possivelmente estariam em casa durante o dia. Assim, utilizaram-se as mesmas informações para as pessoas acima de 60 anos do período noturno.

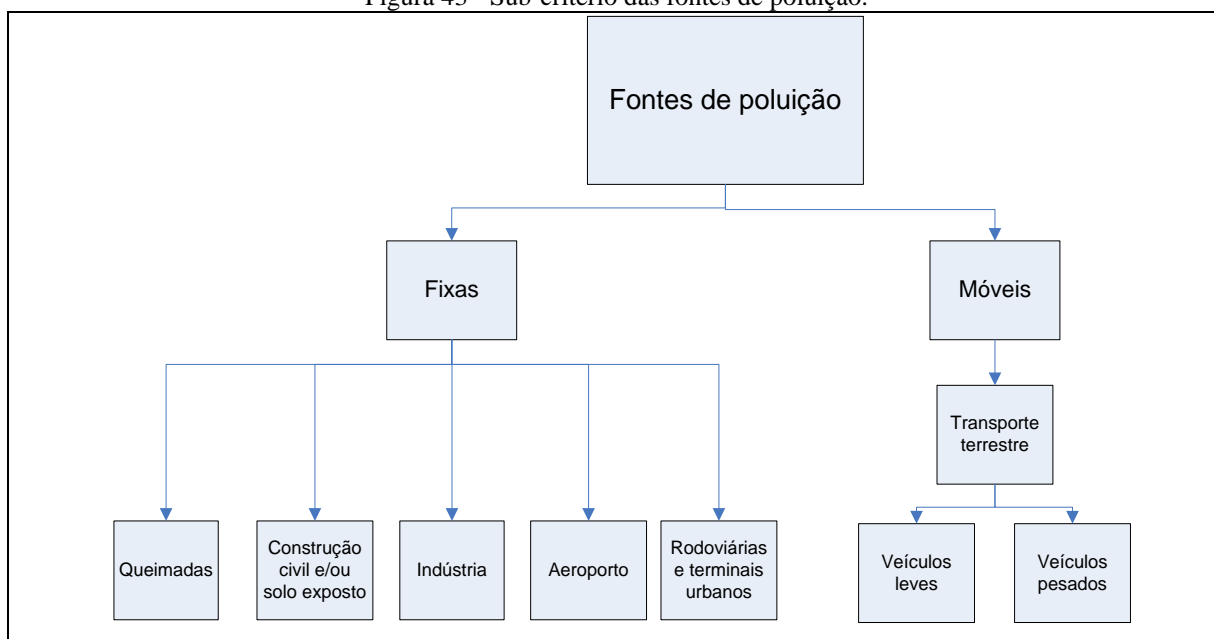
O critério tipos de estruturas para as edificações foi elaborado com base na classificação entre poluição *indoor* e *outdoor*. Pesquisas recorrentes têm demonstrado a vulnerabilidade significativa das pessoas à poluição do ar em ambientes fechados, como residências, escritórios etc. (JUNG et al., 2011; CRISTALE et al., 2012). O problema consiste na presença das fontes de poluição interna, aparelhos eletrônicos, ar condicionados, fogões. Além disso, na facilidade que a poluição externa tem para se concentrar em ambientes fechados. A passagem da poluição externa para os ambientes internos pode ocorrer em decorrência dos tipos de estruturas das edificações, janelas, portas, sistemas de ventilação (MACNEILL et al., 2012; LEE et al., 2014). Assim, devido à dificuldade de levantar esse tipo de informação para toda área urbana do DF, foi considerado que a faixa de renda por domicílio (IBGE, 2012a) influencia no tipo de estrutura da residência. Aquelas residências que apresentam estruturas que impedem com mais eficiência a entrada do ar poluído, são de famílias com renda elevada. Pesquisas recentes têm relatado que áreas residenciais de alto padrão aquisitivo possuem um ar mais limpo (ŠAUER; MÁDR, 2012; DAVIS, 2012). Por fim, ressalta-se, que o critério tipos de estruturas das edificações foi considerado somente para as áreas residenciais, pois não foi possível levantar o mesmo nível de informação para as demais áreas, como comerciais e industriais.

E para o critério efeitos no ser humano, é justificado pelos estudos que já comprovaram a relação positiva entre ar poluído e efeitos negativos à saúde humana (RÉQUIA JÚNIOR; ABREU, 2011; ARBEX et al., 2012; NANDASENA et al., 2012). O dado utilizado para representar esse critério é decorrente do processamento dos dados do Datasus (2013), conforme apresentado pelo Capítulo 4 - dados das pessoas internadas por doenças cardiorrespiratórias. A classificação de faixa etária foi a mesma definida para o critério presença humana.

#### 6.2.3.1.2 Fontes de poluição

Outro objetivo para implantação de uma rede de monitoramento da qualidade do ar é conhecer a participação de cada fonte de emissão. O tipo e a quantidade de fontes de emissões são determinantes para a mensuração da exposição humana à poluição atmosférica (FAN et al., 2012; WILLIAMS et al., 2012). As fontes de emissões definidas por esta análise foram classificadas em fixas e móveis, conforme apresentado pela Figura 43.

Figura 43 - Sub-critério das fontes de poluição.



Fonte: Produção do próprio autor.

As fontes fixas foram representadas pelos pontos de queimadas, pelas áreas de construção civil e/ou solo exposto, pelas áreas industriais, pela área do aeroporto e pelas áreas das rodoviárias e terminais de ônibus urbanos.

Quanto às queimadas, foi definida como um subcritério devido às indicações apontadas por estudos que avaliaram as relações da poluição do ar com a queimada (IGNOTTI et al., 2010; COHEN et al., 2012). Os dados para representar esse critério foram consultados no website do Inpe (2013), no qual é disponibilizado em formato de planilha Excel. O Inpe monitora os focos de queimadas a partir dos satélites que possuem sensores óticos operando na faixa termal-média de 4 $\mu$ m. As queimadas monitoradas estão associados à localização geográfica de ocorrência do foco. A escala temporal dos dados utilizados na presente pesquisa corresponde aos anos de 2010 a 2012, sendo dados diários. Destaca-se que o Inpe assume um erro na localização dos focos, em média, 400 m. Além disso, os focos com frente de fogo menor que 30m x 1m não são identificados pelos satélites.

Em relação às áreas de construção civil e/ou solo exposto, a justificativa de escolha desse critério se baseia na significativa emissão de material particulado decorrente do solo (conhecido também como formação de poeira). Deshmukh et al. (2012) afirmam que o impacto da poeira é intensificado devido a capacidade de dispersão. Os dados para representar esse critério são decorrentes da Sedhab (2012).



As indústrias também constituem uma das fontes significativas de poluição do ar em um ambiente urbano. Grandes polos industriais têm gerado impactos expressivos na população vizinha de ambientes urbanos (WANG, QIONG et al., 2012). Apesar da região do DF não se apresentar como um polo industrial, as poucas indústrias existentes podem ter um papel expressivo para a qualidade do ar da região (RÉQUIA; ABREU, 2011). A base de dados da Sedhab (2012) foi utilizada para representar as áreas industriais do DF.

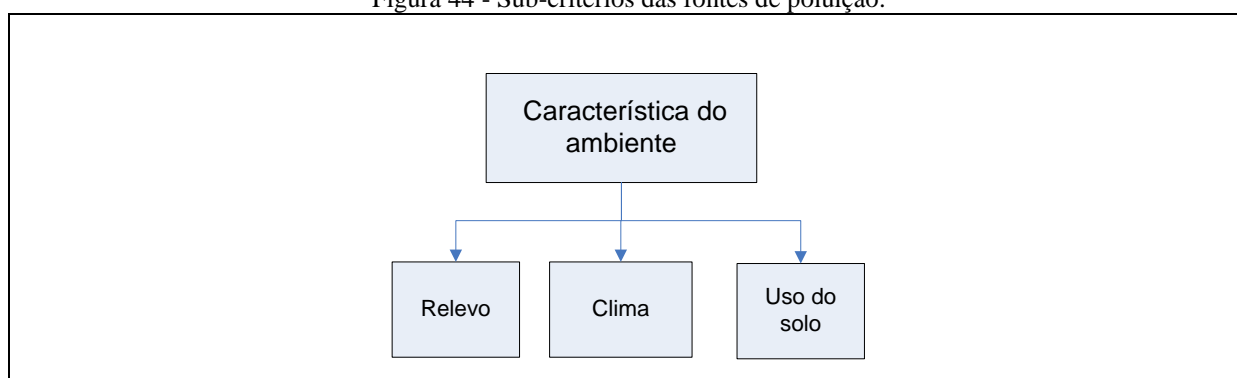
E quanto aos espaços de aeroportos, rodoviárias e terminais de ônibus urbanos, foram levados em consideração pelo fato de que concentram diariamente veículos automotores parados, porém em funcionamento. Esses espaços passam então a serem considerados como uma fonte fixa de poluição atmosférica. Já foi identificado que os veículos que trafegam nesses espaços emitem quantidades elevadas de gases e partículas (HSU et al., 2012; SAEB et al., 2012). Quanto aos dados, a localização do aeroporto foi identificada de forma manual (procedimento visual, vetorização de formato polígono) com base nas imagens do programa Google Earth (GOOGLE, 2013), datada de 2013. E quanto à localização das rodoviárias e terminais de ônibus urbanos, inicialmente foi consultada a lista de endereço dos terminais e rodoviárias no site da Secretaria de Estado de Mobilidade do Distrito Federal (SEMOB, 2013). Esse dado é disponibilizado em formato PDF. Como complemento, foi levantada a informação sobre a quantidade de linhas de ônibus que circulam em cada rodoviária e terminal. Essa informação foi consultada no PDTU (GDF, 2008). Em seguida, as informações dessas duas consultas (Dftrans e PDTU) foram agrupadas. Por fim, de forma manual, foram vetorizados os pontos de cada rodoviária e terminal com base no programa Google Earth (GOOGLE, 2013) - imagem de 2013.

E em relação às fontes móveis, foram classificados pelos veículos terrestres leves, e pelos veículos terrestres pesados. Essa classe foi realizada com objetivo de sintetizar os tipos de veículos considerados no modelo. A justificativa de escolha desse critério se baseia no fato de que os meios de transporte terrestres são avaliados como um dos maiores emissores de poluentes atmosféricos (CAI et al., 2009; KIMBROUGH et al., 2012). O dado utilizado para representar esse critério é decorrente do processamento dos dados do Detran (2009), DER (2010) e GDF (2008), conforme apresentado pelo Capítulo 3 - número de veículos circulando nas principais vias do DF. No entanto, destaca-se que para a análise deste capítulo, o número de motocicletas foi adicionado ao grupo dos veículos leves.

### 6.2.3.1.3 Característica do ambiente

A concentração de poluentes atmosféricos é dependente não só das fontes de emissão, mas também de algumas condições do ambiente, como por exemplo, o relevo (SOKHI, 2011), o clima (MOON et al., 2009) e o tipo de ocupação urbana – uso do solo (MADSEN et al., 2011). Nesse sentido, foram incorporados no modelo critérios relacionados às características ambientais (Figura 44).

Figura 44 - Sub-critérios das fontes de poluição.



Fonte: Produção do próprio autor.

Os dados que representaram o relevo e o uso do solo foram oriundos da base da Sedhab (2012). E os dados do clima foram da base do Ibram (2013). O critério temperatura foi o único para representar o clima devido a dois impedimentos: inexistência de dados espaciais (com escala alta) referentes à velocidade do vento no DF; e os dados de umidade não estavam acessíveis até o momento de finalização da análise deste capítulo. Especificamente quanto aos dados de temperatura levantados na base do Ibram (2013), destaca-se que os dados têm a delimitação temporal de julho de 2012 a dezembro de 2013. Os dados têm o formato de planilha eletrônica com o endereço dos pontos de amostragem da temperatura. Assim, de forma manual e com o auxílio do programa Google Earth (GOOGLE, 2013) - imagem de 2013, foram vetorizadas a localização dos pontos de amostragem.

Por fim, destaca-se que o Apêndice C exibe a representação espacial de todos os dados mencionados neste item 6.2.3.1, com exceção dos dados de faixa etária para o critério efeito no ser humano, nos quais são apresentados no Capítulo 5 - item 5.3.1. Destaca-se ainda que os dados de faixa etária para o critério presença humana – período noturno são apresentados no Apêndice C considerando toda a população (sem classificação por faixa etária).

### 6.2.3.2 Espacialização dos dados e definição dos pesos pelo AHP

Um parâmetro de pré-requisito que foi definido para o desenvolvimento do modelo de identificação das áreas prioritárias para o monitoramento da poluição atmosférica é que todos os dados deveriam estar espacializados para a área de estudo. Assim, algumas técnicas de SIG foram utilizadas para espacialização das variáveis que não abrangiam toda a área estudada. Dentre as técnicas empregadas, cita-se: simbolização normalizada, ou sem normalização; densidade do tipo kernel; interpolação do tipo krigagem; modelo de superfície contínua (Quadro 5). Ressalta-se, que o produto de cada técnica foi um mapa matricial (apresentados no Apêndice D), e, que a escolha da técnica foi baseada em parâmetros empíricos.

Após a confirmação de que todos os dados estavam espacializados, foram criadas alternativas para o conjunto de critérios e subcritérios. Pois, a rede hierárquica do modelo AHP é concluída somente com o estabelecimento das alternativas para cada critério. Vale mencionar que a técnica de SIG para espacialização dos dados já é interligada com a operação de definição das alternativas. As alternativas foram elaboradas de forma escalar, iniciando pelo ponto considerado ideal para o monitoramento (A1) - prioridade muito alta, e decrescendo de maneira ordenada para os pontos menos relevantes (A2, A3, A4, ..., An), (Quadro 5).

Quadro 5 - Alternativas do modelo AHP e descrição da técnica utilizada.

(Continua)

Critérios e subcritérios	Alternativas	Descrição da técnica utilizada
Exposição humana>Presença humana>Período noturno>Pessoas com até 5 anos de idade	(A1) ≥ 2000 (A2) 1000   2000 (A3) 500   1000 (A4) 50   500 (A5) < 50	<p style="text-align: center;">Simbolização normalizada:</p> $\frac{TC}{A}$ <p>Onde: TC = total de pessoas com faixa etária referente ao critério estabelecido; A = área do setor censitário (km<sup>2</sup>). Unidade final: pessoas / área do setor censitário (km<sup>2</sup>).</p>
Exposição humana>Presença humana>Período noturno>Pessoas entre 6 e 17 anos	(A1) ≥ 2000 (A2) 1000   2000 (A3) 500   1000 (A4) 50   500 (A5) < 50	
Exposição humana>Presença humana>Período noturno>Pessoas entre 18 e 59 anos	(A1) ≥ 10000 (A2) 5000   10000 (A3) 1000   5000 (A4) 50   1000 (A5) < 50	
Exposição humana>Presença humana>Período noturno>Pessoas com 60 anos ou mais	(A1) ≥ 2000 (A2) 1000   20000 (A3) 500   1000 (A4) 50   500 (A5) < 50	
Exposição humana>Presença humana>Período diurno>Pessoas com até 5 anos de idade	(A1) ≥ 400 (A2) 300   400 (A3) 200   300 (A4) 100   200 (A5) < 100	
Exposição humana>Presença humana>Período diurno>Pessoas entre 6 e 17 anos	(A1) ≥ 2000 (A2) 1500   2000 (A3) 1000   1500 (A4) 500   1000 (A5) < 500	<p style="text-align: center;">Densidade de kernel:</p> $\lambda(u) = \frac{1}{\tau^2} \sum_{i=1}^n k\left(\frac{d(u_i; u)}{\tau}\right)$ <p>Onde: λ = estimador Kernel; u<sub>1</sub>, u<sub>2</sub>, ..., u<sub>n</sub> = localizações dos colégios observados com base no número de alunos; τ = tamanho do raio em torno de cada colégio, que nesse caso, foi 1000 m; d = distância entre a posição e a i-ésima amostra; k= função de estimação com propriedades de suavização. Unidade final: alunos / área (km<sup>2</sup>).</p>
Exposição humana>Presença humana>Período diurno>Pessoas entre 18 e 59 anos	(A1) ≥ 200000 (A2) 150000   200000 (A3) 100000   150000 (A4) 50000   100000 (A5) < 50000	<p style="text-align: center;">Densidade de Kernel:</p> $\lambda(u) = \frac{1}{\tau^2} \sum_{i=1}^n k\left(\frac{d(u_i; u)}{\tau}\right)$ <p>Onde: λ = estimador Kernel; u<sub>1</sub>, u<sub>2</sub>, ..., u<sub>n</sub> = localizações dos hidrômetros observados; τ = tamanho do raio em torno de cada hidrômetro, que nesse caso foi 1000 m; d = distância entre a posição e a i-ésima amostra; k= função de estimação com propriedades de suavização. Unidade final: consumo de água / área (km<sup>2</sup>).</p>

Critérios e subcritérios	Alternativas	Descrição da técnica utilizada
Exposição humana / Presença humana / Período diurno / Pessoas com 60 anos ou mais	(A1) $\geq 2000$ (A2) 1000   20000 (A3) 500   1000 (A4) 50   500 (A5) $< 50$	Simbolização normalizada: $\frac{TC}{A}$ Onde: TC = total de pessoas com faixa etária referente ao critério estabelecido; A = área do setor censitário (km <sup>2</sup> ). Unidade final: pessoas / área do setor censitário (km <sup>2</sup> ).
Exposição humana / Tipos de estruturas das edificações / Áreas residenciais	(A1) 0   1244 (A2) 1244   2488 (A3) 2488   6220 (A4) 6220   12440 (A5) $\geq 12440$	Simbolização normalizada: $\frac{TR}{D}$ Onde: TR = total de rendimento mensal em um setor censitário (R\$); D = número de domicílios do setor censitário. Unidade final: rendimento mensal total / número de domicílios.
Exposição humana / Efeitos no ser humano / Pessoas com até 5 anos de idade	(A1) $\geq 40$ (A2) 30   40 (A3) 20   30 (A4) 10   20 (A5) $< 10$	As alternativas representam o número de pacientes atendidos e internados.
Exposição humana / Efeitos no ser humano / Pessoas entre 6 e 17 anos	(A1) $\geq 20$ (A2) 10   20 (A3) $< 10$	
Exposição humana / Efeitos no ser humano / Pessoas entre 18 e 59 anos	(A1) $\geq 40$ (A2) 30   40 (A3) 20   30 (A4) 10   20 (A5) $< 10$	
Exposição humana / Efeitos no ser humano / Pessoas com 60 anos ou mais	(A1) $\geq 40$ (A2) 30   40 (A3) 20   30 (A4) 10   20 (A5) $< 10$	

Critérios e subcritérios	Alternativas	Descrição da técnica utilizada
Fontes de poluição / Fixas / Queimadas	(A1) $\geq 1,6$ (A2) 1,2   1,6 (A3) 0,8   1,2 (A4) 0,4   0,8 (A5) $< 0,4$	Densidade de kernel: $\lambda(u) = \frac{1}{\tau^2} \sum_{i=1}^n k\left(\frac{d(u_i; u)}{\tau}\right)$ Onde: $\lambda$ = estimador Kernel; $u_1, u_2, \dots, u_n$ = localizações dos pontos de queimadas observados; $\tau$ = tamanho do raio em torno de cada ponto, que nesse caso foi 2000 m; $d$ = distância entre a posição e a $i$ -ésima amostra; $k$ = função de estimação com propriedades de suavização. Unidade final: pontos de queimadas / área (km <sup>2</sup> ).
Fontes de poluição / Fixas / Construção civil e/ou solo exposto	(A1) $< 500$ (A2) 500   1000 (A3) 1000   2000 (A4) 2000   3000 (A5) $\geq 3000$	Modelo de superfície contínua: distância contínua de afastamento a partir de cada área de construção civil e solo exposto observada. Unidade final: metros.
Fontes de poluição / Fixas / Indústria	(A1) $< 500$ (A2) 500   1000 (A3) 1000   2000 (A4) 2000   3000 (A5) $\geq 3000$	Modelo de superfície contínua: distância contínua de afastamento a partir de cada área industrial observada. Unidade final: metros.
Fontes de poluição / Fixas / Aeroporto	(A1) $< 500$ (A2) 500   1000 (A3) 1000   2000 (A4) 2000   3000 (A5) $\geq 3000$	Modelo de superfície contínua: distância contínua de afastamento a partir da área do aeroporto. Unidade final: metros.
Fontes de poluição / Fixas / Rodoviárias e terminais urbanos	(A1) $\geq 40$ (A2) 30   40 (A3) 20   30 (A4) 10   20 (A5) $< 10$	Densidade de kernel: $\lambda(u) = \frac{1}{\tau^2} \sum_{i=1}^n k\left(\frac{d(u_i; u)}{\tau}\right)$ Onde: $\lambda$ = estimador Kernel; $u_1, u_2, \dots, u_n$ = localizações dos pontos de rodoviárias e terminais observados com base no número de linhas; $\tau$ = tamanho do raio em torno de cada terminal e rodoviária, que nesse caso foi de 1700 m; $d$ = distância entre a posição e a $i$ -ésima amostra; $k$ = função de estimação com propriedades de suavização. Unidade final: média diária de linhas de ônibus / área (km <sup>2</sup> ).

Critérios e subcritérios	Alternativas	Descrição da técnica utilizada
Fontes de poluição / Móveis / Transporte terrestre / Veículos leves	(A1) ≥ 200000 (A2) 150000   200000 (A3) 100000   150000 (A4) 50000   100000 (A5) < 50000	<p>Densidade de kernel:</p> $\lambda(u) = \frac{1}{\tau^2} \sum_{i=1}^n k\left(\frac{d(u_i; u)}{\tau}\right)$
Fontes de poluição / Móveis / Transporte terrestre / Veículos pesados	(A1) ≥ 12000 (A2) 9000   12000 (A3) 6000   9000 (A4) 3000   6000 (A5) < 3000	<p>Onde: <math>\lambda</math> = estimador Kernel; <math>u_1, u_2, \dots, u_n</math> = localização de n eventos observados com base na quantidade de veículos que trafegam em cada via; <math>\tau</math> = tamanho do raio em torno de u, que nesse caso foi de 250 m; d = distância entre a posição e a i-ésima amostra; k= função de estimação com propriedades de suavização. Unidade final: média diária de veículos / área (km<sup>2</sup>).</p>
Característica do ambiente / Relevo	(A1) Muito alta (A2) Alta (A3) Média (A4) Baixa (A5) Muito baixa	<p>Simbolização gerada com base nas próprias informações quantitativa do dado secundário utilizado. Unidade final: altimetria (m)</p>
Característica do ambiente / Clima	(A1) ≥ 29,0 (A2) 27,5   29,0 (A3) 26,0   27,5 (A4) 24,5   26,0 (A5) < 24,5	<p>Interpolação do tipo krigagem:</p> $\hat{Y}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(X_i) - Z(X_i + h)]^2$ <p>Onde: <math>\hat{Y}</math> é a semivariância estimada para cada distância entre os pares de pontos, N é o número de pares mensurados, h é a distância, <math>X_i</math> os pontos amostrados, e <math>Z(X_i)</math> é o valor associado à função randômica. Unidade final: graus Celsius.</p>
Característica do ambiente / Uso do solo	(A1) Área urbana (A2) Mineração (A3) Pastagem (A4) Chácaras (A5) Área verde urbana (A6) Formações florestais e outras (A7) Corpos de água	<p>Simbolização gerada com base nas próprias classes do dado secundário utilizado.</p>

(Conclusão)

Os limites de classes das alternativas (Quadro 5) foram baseadas na literatura existente. Porém, em alguns casos, os limites foram estabelecidos por definições empíricas. Assim sendo, para as alternativas pertencentes aos critérios presença humana e efeitos no ser humano, os limites foram formados com base na melhor visualização espacial. Em relação às alternativas dos tipos de estruturas das edificações, foram classificadas conforme a divisão das classes sociais no Brasil (IBGE, 2012b). Quanto às alternativas para as fontes de poluição, foram baseadas em algumas recomendações de estudos já realizados, como os de Su et al. (2009) e Ignotti et al. (2010). E para as alternativas referentes à característica do ambiente foram orientadas pelos estudos de Rivera et al. (2012), Singh A. e Palazoglu (2012).

Após a definição da rede hierárquica do modelo AHP, composta por atributos e alternativas, a etapa seguinte foi do julgamento paritário entre os critérios definidos. Como resultado do julgamento, foi possível determinar os pesos para cada critério, conforme demonstrado pelo processo matemático do AHP na seção 6.2.2. Destaca-se, que o julgamento paritário para a determinação dos pesos foi feito de forma individual pelo autor e pelo orientador da presente tese. O peso final foi definido pela média dos julgamentos individuais. Para auxiliar no processo de julgamento e dos cálculos dos pesos atribuídos foi utilizado o programa Expert Choice.

### **6.2.3.3 Modelagem em SIG e mapa de áreas prioritárias**

Nesta etapa, o programa ArcGis foi utilizado como ferramenta operacional. Inicialmente, as alternativas criadas para cada subcritério foram indexadas (operação *reclassific*) de forma que obedecessem ao range de preferência para os pontos de monitoramento. Em seguida, executou-se as operações algébricas dos mapas matriciais (célula de 10 m) com os valores dos pesos atribuídos pelo método AHP. Operações algébricas em SIG podem ser definidas como funções matemáticas com constante escalar que geram novos valores de atributos espaciais resultantes das operações realizadas (CÂMARA et al., 2001). As variáveis manipuladas nessas operações algébricas são campos geográficos (geo-campo), no qual cada geo-campo passa a descrever uma informação diferente (SMITH et al., 2007). Câmara et al. (2001) citam que a possibilidade de realizar operações algébricas para as análises espaciais são o que diferenciam o SIG de outros tipos de sistema de informação. Portanto, especificamente para esta análise, as operações algébricas foram realizadas conforme a ordem hierárquica de cada critério e subconjunto de critérios, até que chegasse na meta final - o mapa de áreas prioritárias para o monitoramento da poluição atmosférica (exposição humana). O Quadro 6 apresenta as expressões utilizadas para cada um dos critérios e subcritérios.



Quadro 6 – Expressões utilizadas para o procedimento de álgebra de mapas.

CRITÉRIOS	SUB-CRITÉRIOS (Primeiro nível)	SUB-CRITÉRIOS (Segundo nível)	SUB-CRITÉRIOS (Terceiro nível)	EXPRESSÃO ALGÉBRICA PARA O ÚLTIMO NÍVEL DE SUB-CRITÉRIO - INÍCIO DO PROCEDIMENTO DE ALGEBRA DE MAPAS
Exposição humana (EX) $EX = W_{PH}PH + W_{TE}TE + W_{EH}EH$	Presença humana (PH) $PH = W_{PN}PN + W_{PD}PD$	Período noturno (PN)	Pessoas com até 5 anos (A)	$PN = W_A A + W_B B + W_C C + W_D D$
			Pessoas entre 6 anos e 17 anos (B)	
			Pessoas entre 18 anos e 59 anos (C)	
			Pessoas maiores de 59 anos (D)	
	Período diurno (PD)	-	Pessoas com até 5 anos (E)	$PD = W_E E + W_F F + W_G G + W_H H$
			Pessoas entre 6 anos e 17 anos (F)	
			Pessoas entre 18 anos e 59 anos (G)	
			Pessoas maiores de 59 anos (H)	
	Tipos de estruturas das edificações (TE)	Áreas residenciais (AR)	-	$TE = AR$
	Efeitos no ser humano (EH)	-	Pessoas com até 5 anos (I)	$EH = W_I I + W_J J + W_K K + W_L L$
Pessoas entre 6 anos e 17 anos (J)				
Pessoas entre 18 anos e 59 anos (K)				
Pessoas maiores de 59 anos (L)				
Fontes de poluição (FP) $FP = W_{FI}FI + W_{MO}MO$	Fixas (FI)	Queimadas (QE)	-	$FI = W_{QE}QE + W_{CC}CC + W_{ID}ID + W_{AP}AP + W_{RD}RD$
		Construção civil e/ou solo exposto (CC)	-	
		Indústria (ID)	-	
		Aeroportos (AP)	-	
		Rodoviárias e terminais urbanos (RD)	-	
	Móveis (MO)	Transporte terrestre (TT)	Veículos leves (VL)	$TT = W_{VL}VL + W_{VP}VP$
$MO = TT$	Veículos pesados (VP)			

CRITÉRIOS	SUB-CRITÉRIOS (Primeiro nível)	SUB-CRITÉRIOS (Segundo nível)	SUB-CRITÉRIOS (Terceiro nível)	EXPRESSÃO ALGÉBRICA PARA O ÚLTIMO NÍVEL DE SUB-CRITÉRIO - INÍCIO DO PROCEDIMENTO DE ALGEBRA DE MAPAS
Característica do ambiente (CA)	Relevo (RE)	-	-	$CA = W_{RE}RE + W_{CL}CL + W_{US}US$
	Clima (CL)	-	-	
	Uso do solo (US)	-	-	
<p>Valor Global (Va) – mapa final de áreas prioritárias para o monitoramento da poluição atmosférica (exposição humana):</p> $Va = W_{EX}EX + W_{FP}FP + W_{CA}CA$				

(Conclusão)

Nota:

- ( $W_n$ )  $W$  representa o peso do critério  $n$ ;

- Cada subcritério do último nível é representado por um mapa. Esse mapa é o produto do processo de espacialização dos dados, conforme apresentado pelo Quadro 5.

### 6.3 RESULTADOS

Dentre os critérios primários, o de exposição humana se apresentou com o maior peso,  $w=0.655$ . Quanto aos subcritérios da exposição humana, destacaram-se os pesos atribuídos à presença humana no período diurno,  $w = 0.855$ , aos efeitos no ser humano,  $w = 0.468$  e às pessoas com até 5 anos de idade,  $w = 0.540$ . Em relação aos subcritérios das fontes de poluição, as fontes móveis,  $w = 0.833$ , e respectivamente os veículos pesados,  $w = 0.821$ , representaram os maiores pesos. E quanto aos subcritérios da característica do ambiente, o uso do solo destacou-se com  $w = 0.563$  (Tabela 14).

Tabela 14 - Pesos atribuídos para cada critério e subcritério do modelo.

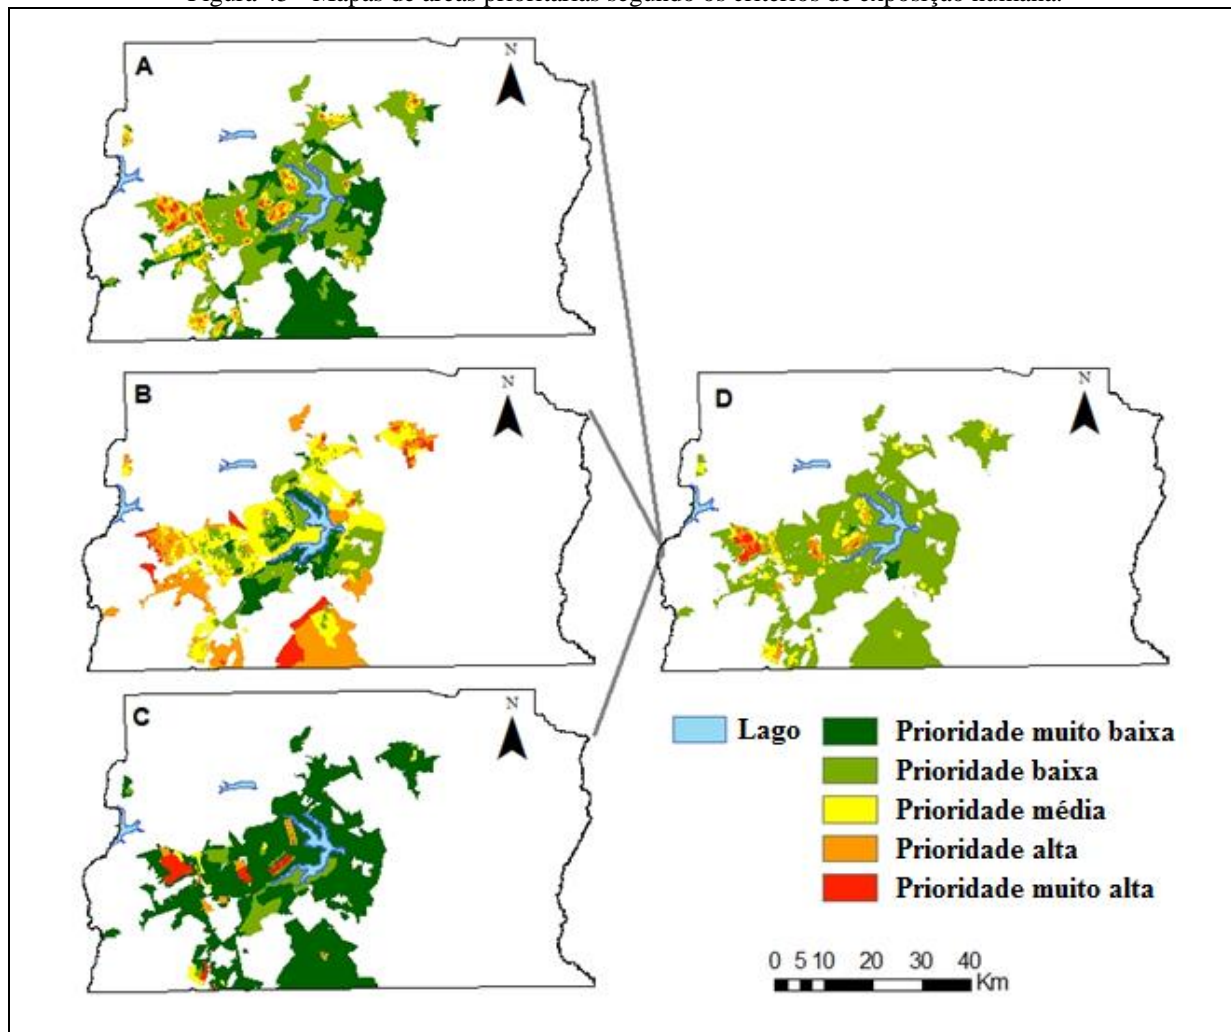
CRITÉRIOS E SUBCRITÉRIOS	PESO (W)
EXPOSIÇÃO HUMANA	0,655
PRESENÇA HUMANA	0,455
Período noturno	0,145
Pessoas com até 5 anos de idade	0,540
Pessoas entre 6 anos e 17 anos de idade	0,114
Pessoas entre 18 anos e 59 anos de idade	0,048
Pessoas 60 anos de idade ou mais	0,298
Período diurno	0,855
Pessoas com até 5 anos de idade	0,540
Pessoas entre 6 anos e 17 anos de idade	0,114
Pessoas entre 18 anos e 59 anos de idade	0,048
Pessoas 60 anos de idade ou mais	0,298
TIPOS DE ESTRUTURAS DAS EDIFICAÇÕES	0,076
Áreas residenciais	1,000
EFEITOS NO SER HUMANO	0,468
Pessoas com até 5 anos de idade	0,540
Pessoas entre 6 anos e 17 anos de idade	0,114
Pessoas entre 18 anos e 59 anos de idade	0,048
Pessoas 60 anos de idade ou mais	0,298
FONTES DE POLUIÇÃO	0,275
FIXAS	0,167
Queimadas	0,150

CRITÉRIOS E SUBCRITÉRIOS	PESO (W)
Construção civil e/ou solo exposto	0,047
Indústria	0,171
Aeroportos	0,034
Rodoviárias e terminais urbanos	0,598
MÓVEIS	0,833
Transporte terrestre	1,000
Veículos leves	0,179
Veículos pesados	0,821
CARACTERÍSTICA DO AMBIENTE	0,070
RELEVO	0,076
CLIMA	0,361
USO DO SOLO	0,563

(Conclusão)

Como ilustração do que foi apresentado pelo Quadro 6, destaca-se que os mapas gerados em cada critério e subcritério foram relacionados com os respectivos pesos (W) estabelecidos pelo método AHP, de forma que obedecesse a rede hierárquica criada. Por exemplo, a Figura 45 apresenta a sequência operacional que gerou o mapa para o critério de exposição humana. O mapa que representa o subcritério presença humana (Figura 45 - A), o mapa que representa o subcritério tipos de estruturas das edificações (Figura 45 - B) e o mapa que representa o subcritério efeitos no ser humano (Figura 45 - C) foram processados pela operação de álgebra de mapas com os respectivos pesos de  $W=0.455$ ,  $W=0.076$  e  $W=0.468$  para gerar o mapa do critério exposição humana (Figura 45 - D). Essa mesma lógica foi adotada para os demais mapas.

Figura 45 - Mapas de áreas prioritárias segundo os critérios de exposição humana.



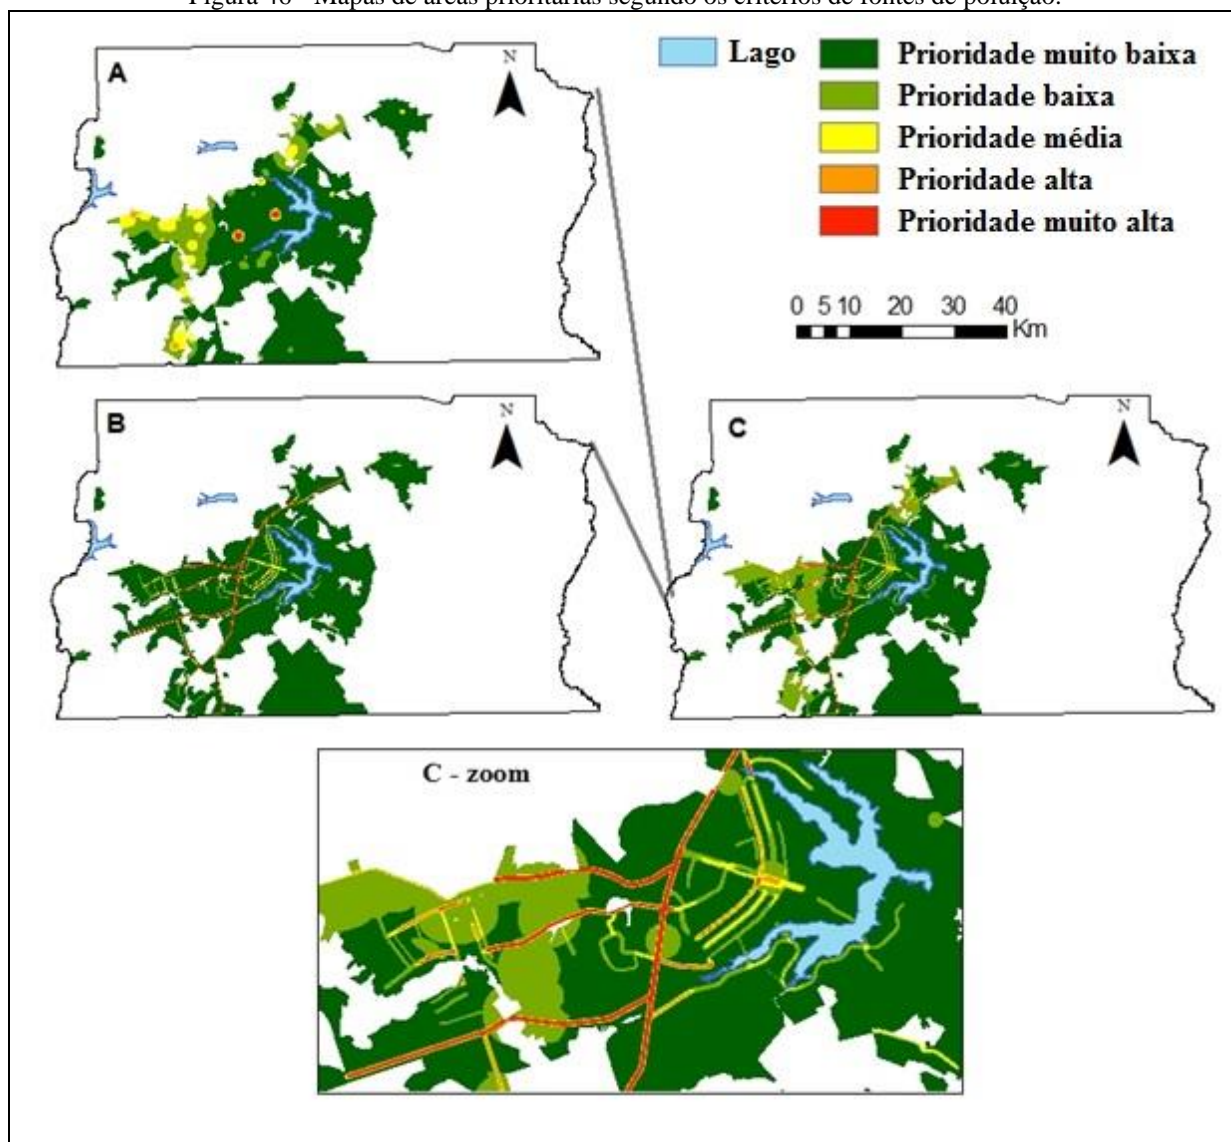
Fonte: Produção do próprio autor.

Nota: A- presença humana; B- tipos de estruturas das edificações; C- efeitos no ser humano; D- exposição humana.

Em decorrência dos pesos atribuídos aos subcritérios específicos para exposição humana, as áreas que contém a maior concentração de alunos nos colégios e as áreas que tiveram uma maior quantidade de pacientes com doenças respiratórias e circulatórias foram as mais relevantes para determinar as regiões com prioridade muito alta e prioridade alta para o monitoramento da poluição atmosférica com base somente nos critérios de exposição humana (Figura 45 - D).

Quanto às fontes de poluição (Figura 46), as fontes móveis (Figura 46 - B), sobretudo os veículos pesados, foram os que tiveram maior influência no modelo. As áreas apresentadas como prioridade muito alta na Figura 46 - C são justamente as vias de tráfego no DF com o maior número de veículos. Ainda se destaca que em relação às fontes fixas (Figura 46 - A), as áreas identificadas como prioridade muito alta são os pontos das duas principais rodoviárias do DF, uma interestadual e a outra de ônibus urbano.

Figura 46 - Mapas de áreas prioritárias segundo os critérios de fontes de poluição.

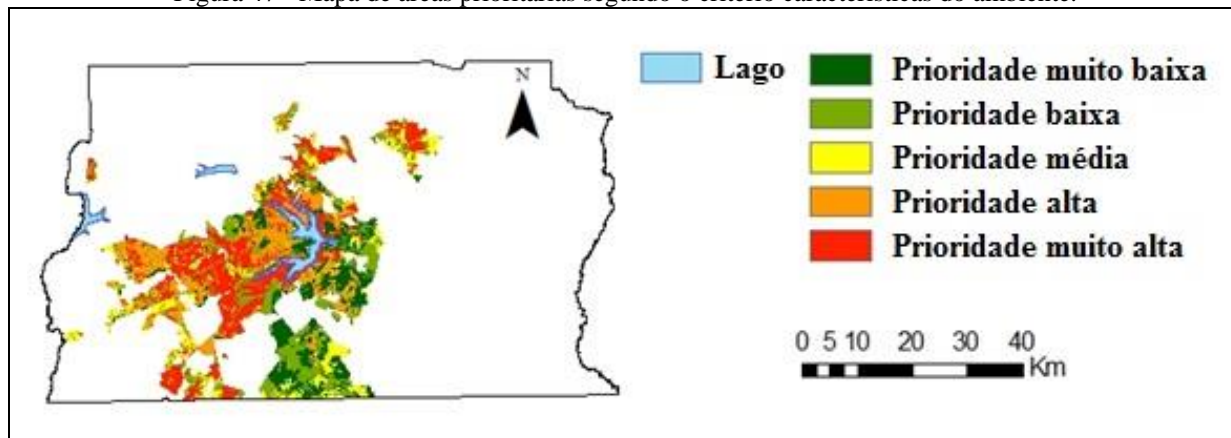


Fonte: Produção do próprio autor.

Nota: A- fontes fixas; B- fontes móveis; C- fontes de poluição.

E quanto ao mapa que apresenta os níveis de prioridade para o monitoramento da poluição do ar conforme o critério característica do ambiente (Figura 47), as regiões urbanas com concentração elevada de áreas construídas foram determinantes para estabelecerem um nível de prioridade alto a muito alto. Destaca-se também, que essas regiões são justamente as que apresentam uma maior densidade populacional.

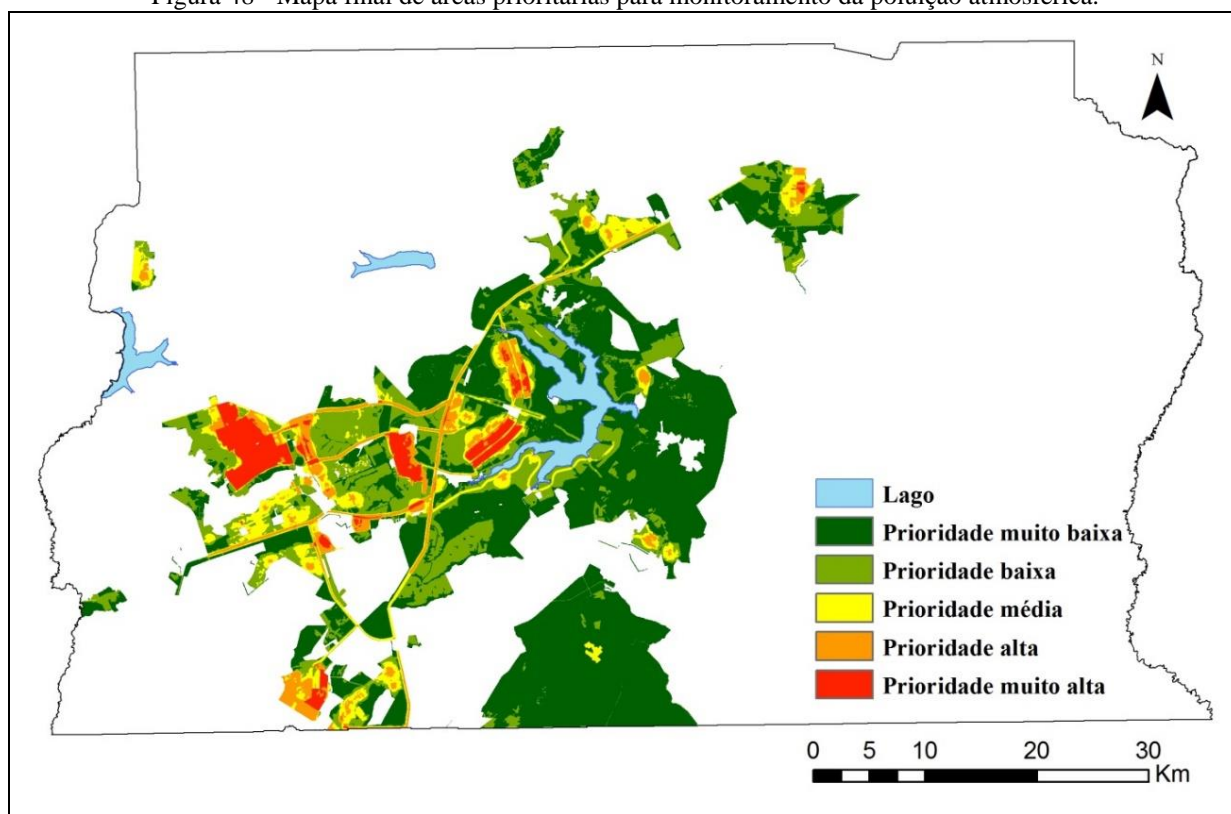
Figura 47 - Mapa de áreas prioritárias segundo o critério características do ambiente.



Fonte: Produção do próprio autor.

Assim, após a operação algébrica com os mapas representados pela Figura 45 - D, Figura 46 - C e Figura 47, gerou-se o mapa final de áreas prioritárias para o monitoramento da poluição atmosférica na região urbana do DF (Figura 48).

Figura 48 - Mapa final de áreas prioritárias para monitoramento da poluição atmosférica.



Fonte: Produção do próprio autor.

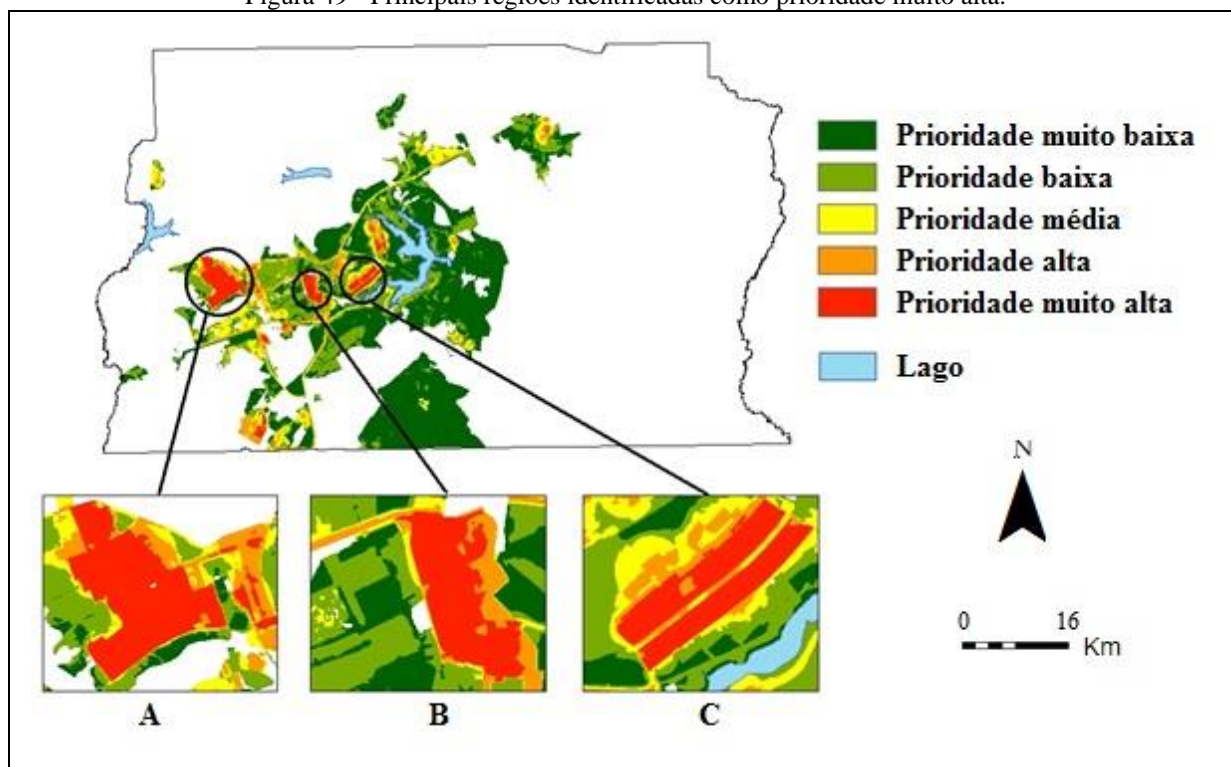


Podem-se selecionar três principais regiões no DF identificadas como prioridade muito alta para o monitoramento da poluição atmosférica, conforme apresentado pela Figura 49, regiões A, B e C. A região A reuni alguns conjuntos de fatores que explicam o nível de atenção altíssimo encontrado para a necessidade do monitoramento da poluição do ar. Pode-se citar: é a região do DF que concentram a maior densidade populacional, é uma das regiões com o menor rendimento per capita e é uma região com alto crescimento de atividades comerciais - o que consequentemente demanda um elevado fluxo de veículos.

Já a região B pode estar associada a um local que apresentou um número elevado de pacientes internados por motivos de doenças do sistema respiratório e circulatório, além de ser também um lugar com densidade populacional elevada.

E quanto ao nível de atenção altíssimo identificado na região C, pode ser explicado por: é uma região com alta densidade populacional, sobretudo, idosos; é uma região que concentra um elevado número de instituições educacionais (114 instituições), o que leva a apresentar uma densidade alta de crianças e adolescentes no período diurno (são entorno de 108 000 alunos); e é uma região que também apresentou um número elevado de pacientes com doenças do sistema respiratório ou circulatório.

Figura 49 - Principais regiões identificadas como prioridade muito alta.



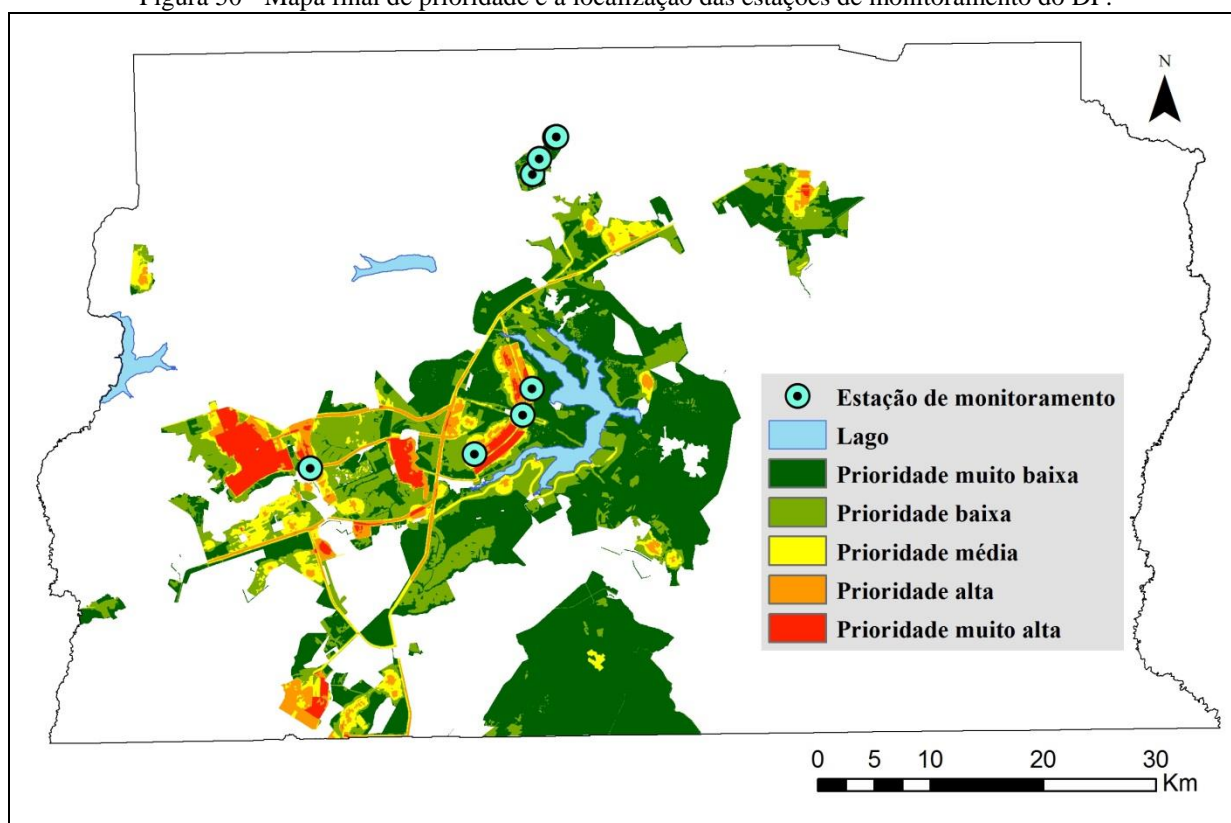
Fonte: Produção do próprio autor.

Nota: A, B e C- principais regiões identificadas como prioridade muito alta.



Portanto, comparando os resultados referentes aos níveis de prioridade identificados neste estudo com a localização das atuais estações de monitoramento do DF (Figura 50), percebe-se que, mesmo com a identificação de estações instaladas em lugares com prioridades muito alta, ainda há necessidade de realizar uma redistribuição do posicionamento de algumas estações. Por exemplo, do total de sete estações, três estão localizadas praticamente na mesma região, conforme observado no conjunto das estações mais ao Norte do mapa (Figura 50). Destaca-se também que algumas áreas identificadas como prioridade alta e prioridade muito alta não possuem estações de monitoramento. É o caso da área que foi identificada como região A - Figura 49, e algumas áreas ao Sul do mapa (Figura 50).

Figura 50 - Mapa final de prioridade e a localização das estações de monitoramento do DF.



Fonte: Produção do próprio autor.

## 6.4 DISCUSSÃO

As variáveis utilizadas especificamente nesta análise - Capítulo 6 - é vista como uma opção barata e operacional para muitos centros urbanos. Muitas cidades até dispõem de um banco de dados melhor e mais abrangente que os dados dispostos pelo governo do DF. Destaca-se ainda que muitas das variáveis utilizadas, por exemplo fontes de poluição e características do

ambiente, são as mesmas adotadas por modelos já conhecidos para cálculo da dispersão de poluentes, como o Aermod, o Cmaq e o Caline 3 (ZHENG et al., 2011; MISRA et al., 2013).

Atualmente, a escolha das áreas prioritárias para mensuração da exposição humana à poluição atmosférica é baseada em dois principais critérios: monitorar próximo as fontes de emissão e em regiões com densidade populacional alta (ADEME, 2002). Nesse contexto, os resultados encontrados pela presente análise abrem a possibilidade de parametrizar a escolha do ponto de monitoramento conforme a realidade de cada área. Além disso, esta análise também pode ser utilizada para orientar as estratégias que visam definir a quantidade de estações necessárias para uma área urbana, evitando assim a redundância do número de estações.

Vale destacar, que o método AHP é flexível ao ponto de permitir a revisão das áreas identificadas como prioritárias (TRAN et al., 2002). Ou seja, os agentes envolvidos no processo de reaplicação da presente análise (órgãos ambientais, centros de pesquisas etc.) possuem a liberdade de tratar os pesos de cada variável com base na experiência profissional e conforme o julgamento de valores previamente estabelecido. Por exemplo, se previamente o objetivo é conhecer melhor a exposição de estudantes às fontes móveis, dar-se, então, um peso maior para os critérios de fontes móveis e presença humana no período diurno (pessoas até 17 anos).

A presente análise vem acrescentar aos outros poucos estudos que já foram feitos e que tiveram como objeto de avaliação a questão dos pontos de monitoramento da poluição do ar. No trabalho de Zheng et al. (2011), por exemplo, foram consideradas variáveis semelhantes para representar a escolha dos pontos de mensuração de exposição na China, tais como, declividade e densidade populacional. Zheng et al. (2011) ainda mostraram que a densidade populacional tem um peso maior no processo. Essa mesma diferença dos pesos pode ser identificada pelos resultados encontrados pela presente análise, em que as áreas com maiores densidades de pessoas foram categorizadas com prioridade alta para o monitoramento.

Outro estudo foi o de Janssen et al. (2012), em que os autores identificaram que a classificação do uso do solo provê informações importantes para a representatividade das estações de monitoramento da qualidade do ar. Dessa forma, vale destacar que nesta análise o uso do solo teve o maior peso, 0.563, dentre o grupo de indicadores de condições do ambiente. Outra observação é que no modelo final (Figura 48), a característica de uso do solo na região urbana do DF teve uma relação com as prioridades estabelecidas para o monitoramento. Por exemplo, grande parte das áreas residenciais do DF foi considerada como nível de prioridade média a

muito alta. Já grande parte das áreas comerciais e de serviços foram consideradas com nível de prioridade alta a muito alta.

Sugere-se que o estudo seja replicado em áreas com propriedades diferentes, por exemplo, uma área rural. Os critérios, os pesos e a rede hierárquica definidos no modelo seria diferente para uma região rural. Essa diferença entre as áreas urbanas e rurais foi identificada pelo estudo de Joly e Peuch (2012), no qual foi avaliado as redes de monitoramento de algumas regiões da Europa. Outros exemplos de áreas que mereciam ser testadas pelo método do presente estudo, são as cidades que apresentam comportamentos diferentes das fontes de poluição, ou seja, cidades com outras fontes (exemplo: portos, usina termoeletrica para geração de energia) ou com intensidades distintas (exemplo: maior concentração de indústrias).

A análise apresentada por este capítulo tem algumas limitações. As limitações estão relacionadas com a acurácia e precisão dos dados utilizados para representar alguns critérios. Por exemplo, quanto aos critérios de presença humana, não necessariamente todas as pessoas acima de 59 anos estarão nas próprias residências no período diurno; o consumo de água registrado pelos hidrômetros não representa necessariamente a quantidade de pessoas entre 18 e 59 anos no período diurno. Quanto ao critério tipo de estrutura das edificações, representamos somente edificações de residências. Não tivemos acesso aos dados que pudessem representar comércios, prédios públicos etc. Ou seja, edificações onde grande parte da população passa em torno de 8 horas do dia expostas à exposição *indoor*.

No entanto, apesar do difícil acesso aos dados precisos e acurados para os critérios estabelecidos nesta análise, pode-se estimar que os dados utilizados representam entre o 1º e 3º quartil da distribuição real de cada critério.

## Capítulo 7 - Decaimento do risco de doenças cardiorrespiratórias relacionado com as características ambientais do bairro

---

### 7.1 APRESENTAÇÃO

As características do bairro têm importante influência para determinar a qualidade de vida das áreas urbanas. O uso e ocupação do solo (ambientes construídos), as condições socioeconômicas e os fatores ambientais dos bairros são variáveis preditoras para estimar, por exemplo, comportamento social e saúde humana (YEN; SYME, 1999; PAULEIT; DUHME, 2000; SAMPSON et al., 2002; BALDAUF et al., 2013).

Em relação à saúde humana, muitos estudos já mostraram que os aspectos ambientais dos bairros são associados com o número de fumantes nas residências (CHUANG et al., 2005), com obesidade (FRASER et al., 2012; WALL et al., 2012), doenças mentais (VILLANUEVA et al., 2013), doenças cardiovasculares (CHUM; O'CAMPO, 2015), índice de massa corporal (JAMES et al., 2014), ruído e exposição à poluição do ar (WEBER et al., 2014b). Outros estudos exploraram a relação entre características do bairro e saúde com objetivo de prever a ocorrência de atividades físicas entre os residentes, por exemplo, a prática de caminhada e ciclismo (LEE et al., 2007; BRIAN et al., 2012; SALLIS et al., 2012).

Os resultados dessas pesquisas têm orientado as políticas públicas que procuram promover o bem-estar da população de cada bairro. As políticas são relacionadas com a melhoria dos ambientes físico, social e de serviços ambientais dos bairros (DIEZ-ROUX, 2007; CBHA, 2015). Além disso, a eficiência dessas políticas públicas está diretamente associada com a economia da cidade. Por exemplo, Nowak and Heisler (2010) mostram que a presença de espaços verdes nos bairros dos Estados Unidos representam uma economia de 500 milhões de dólares por ano. Estudos indicam que a área verde promove economia para o governo pois é assumido que a vegetação é responsável pela remoção de uma parte da poluição do ar, e que a poluição do ar é uma importante causa de doenças cardiorrespiratórias (MORTIMER et al., 2012; VALDÉS et al., 2012; BUONANNO, GIORGIO et al., 2013). Além disso, Wang et al.

(2005) mostram que a cada um dólar investido em ciclovias e trilhas para atletismo está associado com a redução de três dólares em custos médicos para o governo.

Apesar de que muitos estudos já examinaram a relação entre as características ambientais do bairro e saúde humana, nenhum estudo ainda investigou o decaimento dessa relação com intuito de criar um mapa de risco. Além disso, a maior parte dos estudos conduziram análises com um pequeno número de aspectos que representam as características ambientais do bairro. Portanto, este capítulo apresentará a avaliação do decaimento do risco de doenças cardiorrespiratórias relacionado com 28 aspectos que representam as características ambientais de bairro. Por fim, foi criado um mapa de risco decorrente dessa avaliação realizada. A avaliação deste capítulo representa o sexto objetivo específico desta tese.

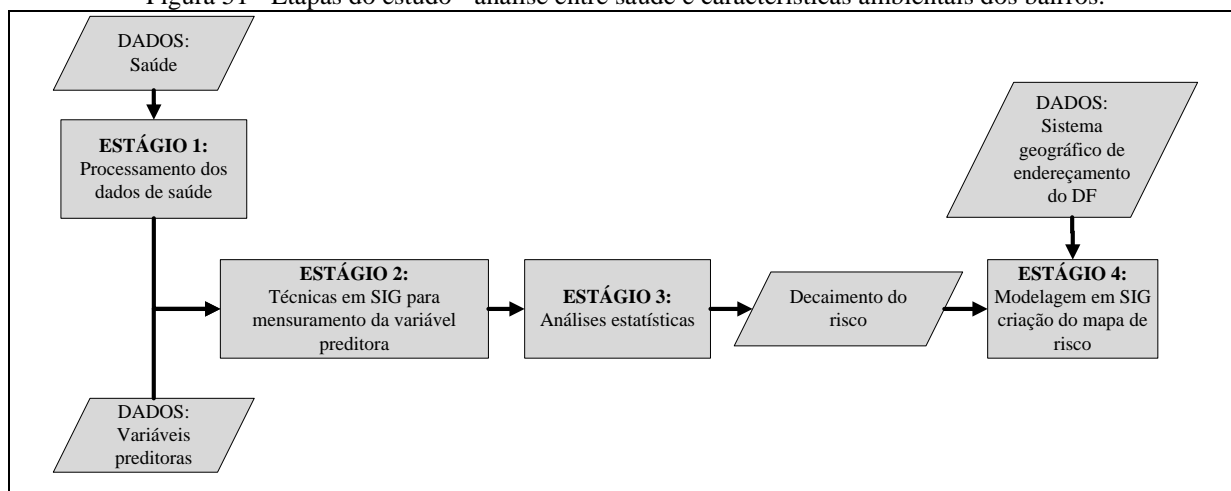
## 7.2 MÉTODO

### 7.2.1 DESIGN DO ESTUDO

O estudo deste capítulo foi do tipo ecológico com uma análise cross-sectional da associação entre as características ambientais dos bairros e as internações por doenças cardiorrespiratórias.

Quatro estágios representaram a análise deste capítulo (Figura 51). No primeiro estágio os dados de saúde foram processados. A segunda etapa foi representada pelo uso das técnicas de SIG para a estimação das variáveis preditoras. Na terceira etapa foi realizada a análise estatística. E no quarto estágio foram gerados os mapas com o risco de doenças cardiorrespiratórias.

Figura 51 - Etapas do estudo - análise entre saúde e características ambientais dos bairros.



Fonte: Produção do próprio autor.

## 7.2.2 PROCESSAMENTO DOS DADOS DE SAÚDE

O dado de saúde utilizado foi decorrente do processamento dos dados do Datasus (2013), conforme apresentado pelo Capítulo 4 - Avaliação entre poluição e saúde em áreas com limitação de dados. No entanto, com objetivo de aumentar o número de observações na análise (número de blocos de endereços, em que estão consolidados os números de internações), não foi considerada a agregação do endereçamento, conforme apresentada no Capítulo 4 - Figura 25. Destaca-se que o maior número de observações (no mínimo mil) é indicado para a análise estatística realizada neste capítulo. Assim, foi utilizado na análise do presente capítulo o somatório do número de blocos de endereços de cada nível de endereçamento, o que totalizou 1.547 polígonos (blocos de endereços) e 7.307 internações. Por fim, foram excluídos 20 blocos de endereços no qual apresentaram população menor que 1 (totalizando 1.527 polígonos). Lembrando-se que o dado de população foi estimado com base na relação linear entre a área de cada polígono (os detalhes foram apresentados no Capítulo 4). A Tabela 15 apresenta o ajuste feito nos dados de saúde para a análise do presente capítulo.

Tabela 15 - Dados de saúde.

Nível de endereçamento	Número de blocos de endereços (Polígonos)	Número de internações em todos os blocos
Setor	37	1.286
Quadra	361	3.090
Conjunto	1.084	2.371
Lote	65	560
<b>SOMATÓRIO (TOTAL)</b>	<b>1.547</b>	<b>7.307</b>
<b>RESULTADO FINAL</b>		
(Após remoção dos 20 blocos com população < 1)	1.527	7.269

Por fim, destaca-se que a análise deste capítulo não considerou a classificação etária das pessoas internadas por doenças cardiorrespiratórias, pois diminuiria o número de observações.

### 7.2.3 VARIÁVEIS PREDITORAS

Foram avaliadas 28 variáveis preditoras. Essas variáveis foram agrupadas em seis categorias: 1- transporte (6 variáveis); 2- uso do solo (10 variáveis); 3- inventário de poluição do ar (6 variáveis); 4- terreno e meteorologia (3 variáveis); 5- demografia e economia (2 variáveis); 6- outros (1 variável).

As variáveis da categoria de transporte representam o comprimento das vias (rodovias, ruas e avenidas), o número de veículos (veículos leves, veículos pesados e motocicletas) e o número de terminais de ônibus. A Sedhab (2012) foi a fonte dos dados sobre o comprimento das vias, conforme apresentado pelo Capítulo 2 - Variáveis do estudo. Quanto aos dados sobre o número de veículos, o detalhe do levantamento foi apresentado no Capítulo 3. E em relação ao número de terminais de ônibus, o Capítulo 6 apresenta os detalhes do dado.

A categoria de uso do solo inclui as áreas industriais, comerciais, em processo de urbanização, de solo exposto, em processo de construção civil e naturais (corpos d'água e áreas verdes). Essas áreas foram identificadas pela base geográfica da Sedhab (2012), conforme apresentado pelo Capítulo 2.

O inventário de poluição atmosférica representa a quantidade de emissões veiculares ao longo de 233 vias de tráfego (aproximadamente 615 km) do DF. O cálculo e a análise desse inventário foram apresentados pelo Capítulo 3. Neste capítulo foi utilizada uma superfície de poluição identificada pelo inventário. Para isso, usou-se o método de interpolação conhecido como IDW. Essa mesma superfície de poluição do inventário foi usada no Capítulo 4.

A categoria dos dados de terreno e meteorológicos inclui temperatura, humidade e altimetria. A fonte e a descrição desses dados foram apresentadas no Capítulo 2. Destaca-se, que para temperatura e humidade também foi usado o método IDW para criação de uma superfície de distribuição espacial. A categoria demografia e economia se referem aos dados de população e renda, respectivamente. Ambos os dados foram obtidos do censo demográfico do IBGE (2010). E a categoria “outros” inclui os pontos de incêndios florestais. Os detalhes do levantamento desses três últimos dados também estão apresentados no Capítulo 2. O Quadro 7 apresenta o sumário das 28 variáveis preditoras utilizadas na análise do presente capítulo.

Quadro 7 - Descrição das variáveis preditoras.

Categoria	Variáveis	Unidade	Definição da variável
Transporte	Rodovias	m	Vias de tráfego definidas como rodovias (conforme o DER)
	Ruas e avenidas	m	Demais vias de tráfego. A maior parte, no contexto intraurbano
	Veículos leves	Número	Veículos de passageiro
	Veículos pesados	Número	Ônibus e caminhões
	Motocicletas	Número	Veículos com duas rodas em linha
	Terminais de ônibus	Coordenadas	Terminais de ônibus locais e rodoviárias interestaduais
Uso do solo	Áreas industriais	m <sup>2</sup>	Área com presença de atividades industriais
	Áreas comerciais	m <sup>2</sup>	Área com presença de atividades comerciais
	Áreas em urbanização	m <sup>2</sup>	Áreas em processo de urbanização
	Solo exposto	m <sup>2</sup>	Áreas degradadas (sem vegetação, sem estruturas urbanas)
	Áreas de construção civil	m <sup>2</sup>	Áreas privadas ou públicas em processo de construção civil
	Área verde intraurbana	m <sup>2</sup>	Áreas verdes intraurbana (no contexto urbano)
	Parques	m <sup>2</sup>	Parques urbanos. Muitos possuem estrutura para prática de esportes, como quadras etc.
	Florestas	m <sup>2</sup>	Grandes áreas verdes. Unidades de Conservação
	Lagos	m <sup>2</sup>	Presença de lagos na área
Inventário de poluição atmosférica	Rios	m	Presença de rios na área
	MP	Toneladas	Toneladas de MP emitidas na área
	CO	Toneladas	Toneladas de CO emitidas na área
	CH <sub>4</sub>	Toneladas	Toneladas de CH <sub>4</sub> emitidas na área
	NO <sub>x</sub>	Toneladas	Toneladas de NO <sub>x</sub> emitidas na área
	NMHC	Toneladas	Toneladas de NMHC emitidas na área
Terreno e meteorológicos	CO <sub>2</sub>	Toneladas	Toneladas de CO <sub>2</sub> emitidas na área
	Temperatura	°C	Temperatura
	Umidade relativa	%	Umidade relativa do ar
Demografia e economia	Altimetria	Unidade	Altimetria: muito baixa (1), baixa (2), média (3), alta (4), e muito alta (5)
	População	Número	População na área
Outros	Renda	R\$	Total de renda por mês, por população e por setor censitário
	Incêndios florestais	Coordenadas	Localização dos focos de queimadas

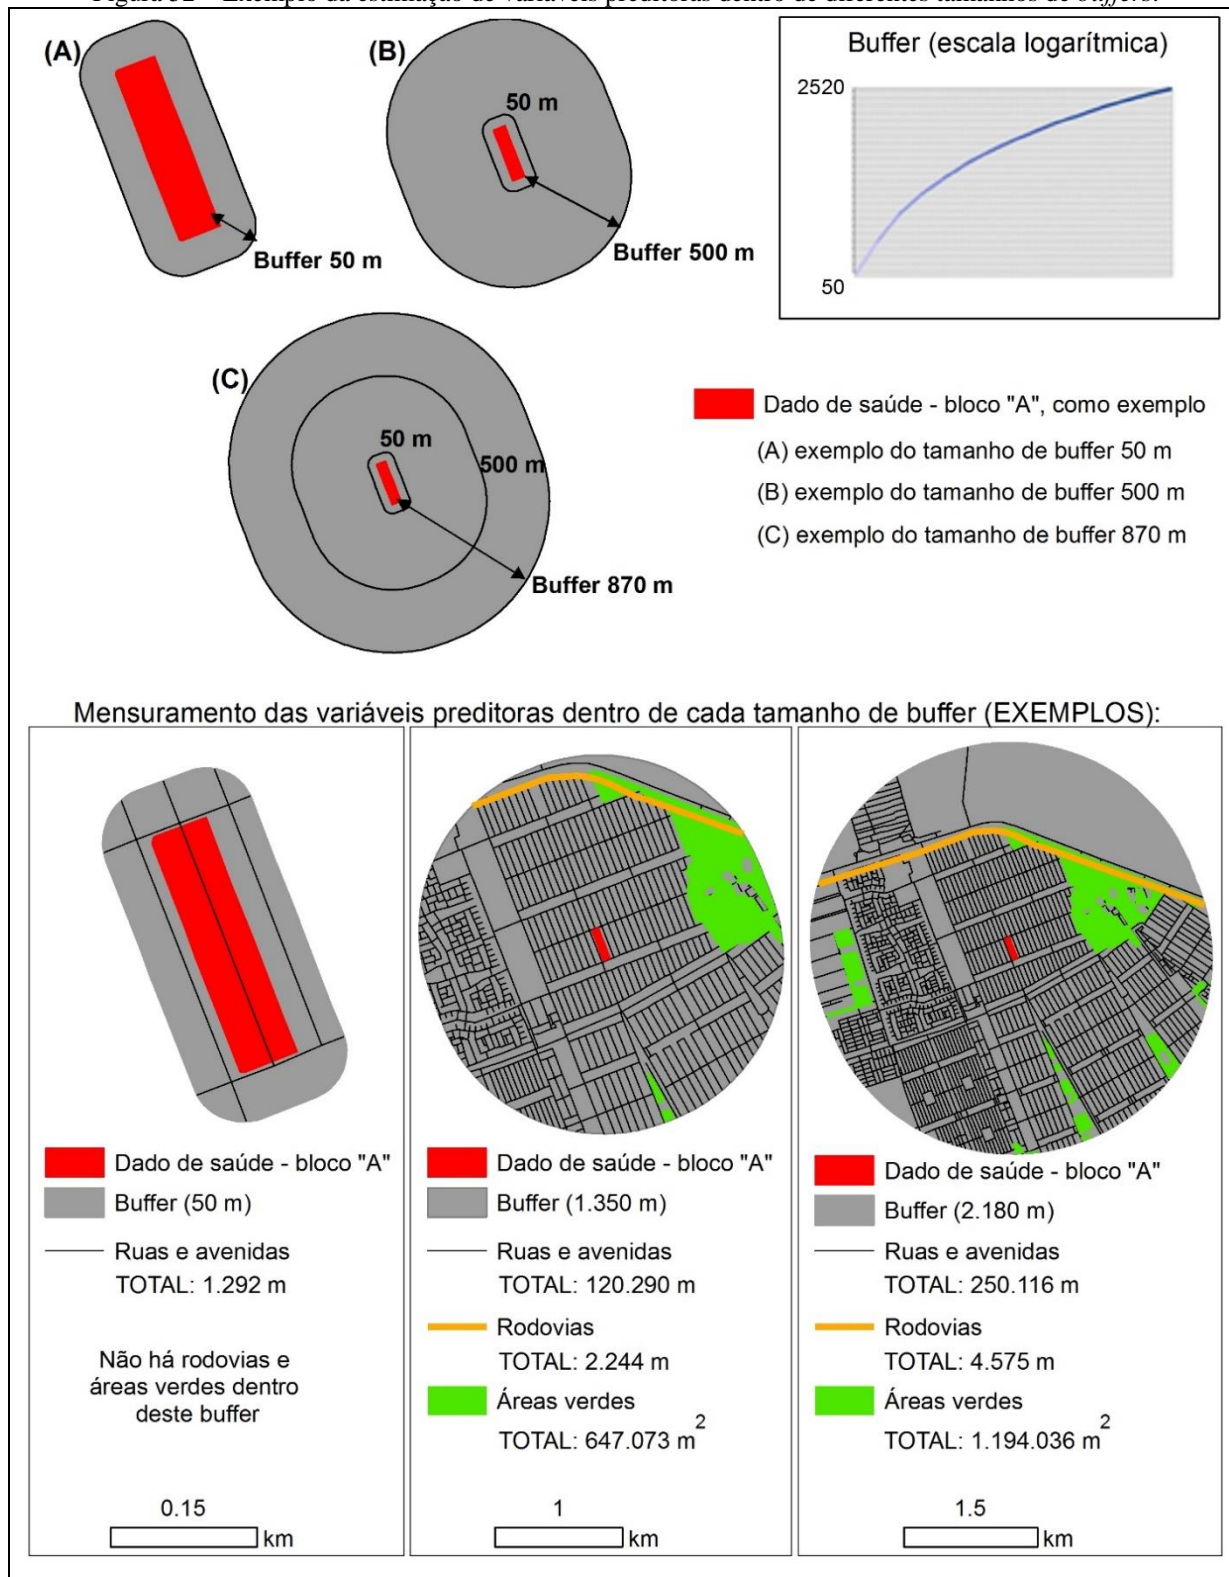
#### 7.2.4 TÉCNICAS EM SIG PARA MENSURAMENTO DAS VARIÁVEIS PREDITORAS

Primeiramente, foram definidos 15 *buffers* ao redor de cada um dos 1.527 blocos de endereços. Os *buffers* foram definidos usando uma escala logarítmica (Figura 52). O tamanho dos *buffers* foram 50 m, 500 m, 870 m, 1.140 m, 1.350 m, 1.540 m, 1.700 m, 1.840 m, 1.960 m, 2.080 m, 2.180 m, 2.280 m, 2.370 m, 2.450 m e 2.520 m. Após a definição dos *buffers*, foram usadas técnicas em SIG para estimação de cada variável preditora dentro de cada buffer. Esse processo foi realizado para todos os 1.527 blocos. Por exemplo, no hipotético bloco “A” tem 1.292 e 120.290 m de ruas e avenidas dentro dos *buffers* de 50 e 1.350 m, respectivamente. A Figura 52 apresenta o processo de estimação das variáveis preditoras.

Por fim, destaca-se que as seguintes ferramentas operacionais foram aplicadas por meio do programa ArcGis: *calculate geometry* - cálculo de área (m<sup>2</sup>) e comprimentos (m); *spatial join* – junção dos dados entre duas feições geográficas, usando como parâmetro as coordenadas geográficas; e, *intersect* - identificação da geometria que intercepta duas feições geográficas.



Figura 52 – Exemplo da estimaco de variveis predictoras dentro de diferentes tamanhos de *buffers*.



Fonte: Produo do prprio autor.

## 7.2.5 ANÁLISE ESTATÍSTICA

### 7.2.5.1 Quantile regression

O método quantile regression foi utilizado na análise estatística para a estimação do risco. Quantile regression é um método que objetiva mensurar como os quantis da variável resposta muda com as variações nas variáveis preditoras. Diferente do método de regressão mais popular, método dos mínimos quadrados (*Ordinary Least Squares* – OLS), no qual avalia como a média da variável resposta muda com as variáveis preditoras. Dessa forma, o método quantile regression é conhecido por sua robustez com avaliação dos *outliers* da variável resposta. Estudos que têm divulgado resultados baseado na média da variável resposta podem estar perdendo informações importantes em relação aos efeitos das variáveis preditoras na variável resposta (KOENKER; HALLOCK, 2001; REICH et al., 2011; BIND et al., 2015).

Na língua portuguesa o método quantile regression é traduzido como regressão quantílica. No entanto, como grande parte dos estudos em epidemiologia espacial que utilizou esse método estão publicados na literatura internacional, nesta tese será adotado o termo internacional - quantile regression. De acordo com Koenker (2005), o modelo em quantile regression é descrito pela Equação 21.

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + e_i$$

Equação 21

Onde  $y_i$  é a variável resposta para os quantis ( $q$ )  $i^{th}$ ;  $\beta_0 + \beta_1, \dots + \beta_k$  referem-se aos coeficientes, ou parâmetros de regressão associados com os quantis  $i^{th}$ ;  $x_{1i}, x_{2i}, \dots, x_{ki}$  representam as variáveis preditoras  $k$  para os quantis  $i^{th}$ ;  $e_i$  é o erro residual.

O modelo quantile regression minimiza  $\sum_i q |e_i| + \sum_i (1 - q) |e_i|$ , a uma soma que dá as penalidades assimétricas  $q |e_i|$  para predições abaixo; e  $(1 - q) |e_i|$  para predições acima. Portanto, a função objetiva que o modelo quantile regression usa para minimizar os coeficientes é dada pela Equação 22, onde  $0 < q < 1$ .

$$Q(\beta_q) = \sum_{i:y_i \geq x'_i \beta} q |y_i - x'_i \beta_q| + \sum_{i:y_i < x'_i \beta} (1 - q) |y_i - x'_i \beta_q|$$

Equação 22

A estrutura da matemática do quantile regression é baseada em programação linear. Como apresentado anteriormente, tem-se  $\beta_q$  ao invés de  $\beta$ . Assim, para garantir que diferentes escolhas de quantis ( $q$ )  $i^{th}$  estima diferentes valores de  $\beta$ , é utilizado o fator de efeitos marginais. Nesse sentido, a condicional padrão dos quantis é especificada para ser linear, conforme apresentado pela Equação 23.

$$Q_q(y_i | x_i) = x'_i \beta_q$$

Equação 23

Para os regressores  $k^{th}$ , o efeito marginal é o coeficiente para os quantis ( $q$ )  $i^{th}$ , conforme apresentado pela Equação 24.


$$\frac{\partial Q_q(y|x)}{\partial x_k} = \beta_{qk}$$

Equação 24

Por fim, destaca-se que o fator de efeitos marginais são para mudanças infinitesimal no regressor, assumindo que a variável dependente permanece no mesmo quantil. Além disso, um parâmetro  $\beta_{qk}$  estima a mudança em um específico quantil ( $q$ )  $i^{th}$  da variável dependente  $y$  produzida pela mudança de 1 unidade na variável independente  $x_k$ .

A Figura 53 apresenta um exemplo da variação de uma hipotética variável dependente em função de uma variável preditora. A Figura 53 mostra essa variação com base no modelo quantile regression (quantis 0,05; 0,10; 0,25; 0,75; 0,90 e 0,95) e com base no modelo de regressão OLS.

Figura 53 - Gráfico scatterplot (modelo de regressão OLS e quantile regression).

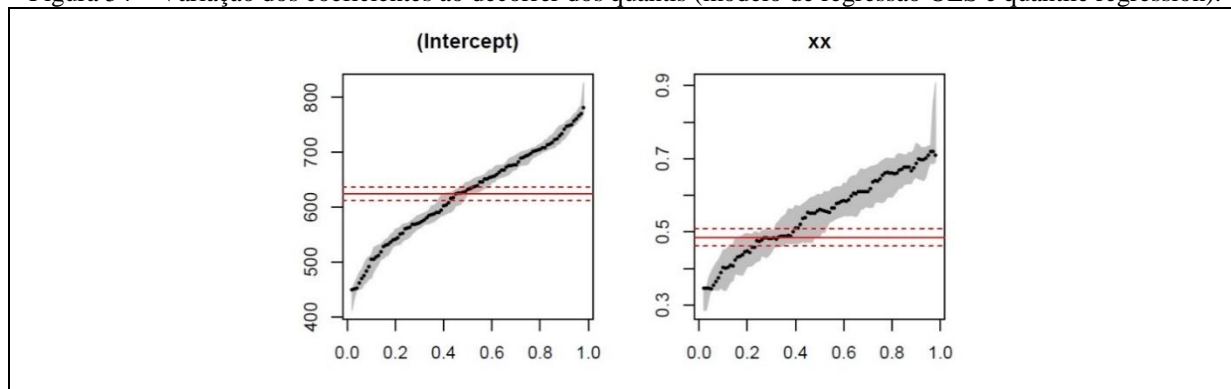


Fonte: KOENKER (2011), com edição.

Nota: quantil 0.05 (H), quantil 0.10 (G), quantil 0.25 (F), quantil 0.50 (D), quantil 0.75 (C), quantil 0.90 (B), quantil 0.95 (A) e coeficientes estimados pela regressão OLS (E).

A Figura 54 apresenta um outro exemplo hipotético sobre o resultado da regressão OLS e do modelo quantile regression. O destaque apresentado pela Figura 54 é a variação dos coeficientes ao decorrer dos quantis considerados no modelo.

Figura 54 – Variação dos coeficientes ao decorrer dos quantis (modelo de regressão OLS e quantile regression).



Fonte: KOENKER (2011).

Nota: valor do quantil (eixo X), valor do coeficiente (eixo Y), intercepto (intercept), variável preditora (xx), linha vermelha sólida (coeficiente com base no modelo de regressão OLS), linha vermelha pontilhada (intervalo de confiança do coeficiente com base no modelo de regressão OLS), linha preta sólida (coeficiente com base no modelo quantile regression), marca sólida cinza (intervalo de confiança do coeficiente com base no modelo quantile regression).

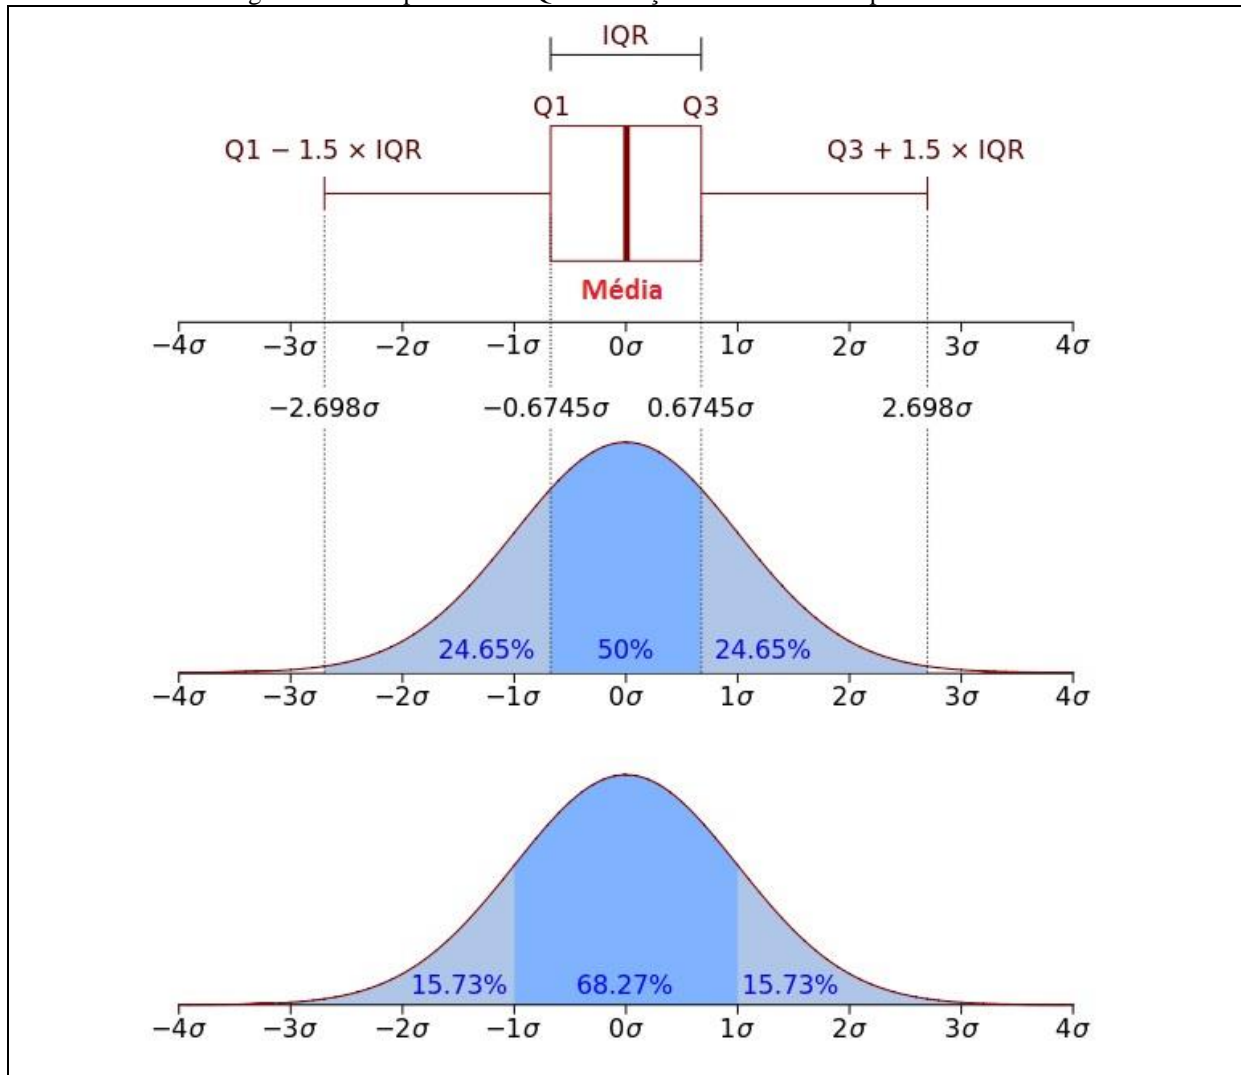
Portanto, com base nos exemplos apresentados pelas Figura 53 e Figura 54, é possível perceber que a medida de posição estatística utilizada para caracterizar a variável dependente (posição do quantil) causa uma diferença significativa do efeito da variável preditora na variável dependente. Observando Figura 54– gráfico xx, por exemplo, estima-se que entre os quantis 0,20 e 0,50 não há diferença significativa do uso entre o modelo OLS e o modelo quantile regression. No entanto, valores altos da variável dependente (quantis  $> 0,50$ ) sofrem significativamente mais efeitos da variável preditora que os valores baixos (quantis  $< 0,20$ ).

### 7.2.5.2 Interquartile range

Além do quantile regression, foi utilizado na análise estatística deste capítulo o conceito da variação do interquartil – o termo em inglês é *Interquartile Range (IQR)*. Será adotado nesta tese o termo da literatura internacional (IQR).

O IQR é uma medida da estatística descritiva com objetivo de extrair as observações contidas na diferença entre o primeiro quantil e o terceiro quantil (UPTON; COOK, 1996; KOKOSKA; ZWILLINGER, 2000). A adoção do IQR como método de extração das observações a serem analisadas tem sido considerada uma abordagem robusta para mensuração da distribuição dos dados em termos de escala. Um grande número de estudos em epidemiologia têm utilizado o IQR como meio de extração dos dados (LADEN et al., 2000; ZANOBETTI; SCHWARTZ, 2009; KLOOG et al., 2012; VALDÉS et al., 2012; AUSTIN, E. et al., 2013). A Figura 55 apresenta a posição do IQR dentro de uma função de densidade de probabilidade.

Figura 55 - Bloxplot com o IQR e a função de densidade de probabilidade.



Fonte: KOKOSKA e ZWILLINGER (2000), com edição.

### 7.2.5.3 Risco

O risco calculado no estudo neste capítulo considerou como variável resposta a taxa de internações, ou seja, o número de pacientes internados por população (taxa de incidência) em cada um dos 1.527 blocos de endereços.

No cálculo do risco foi considerado o coeficiente ( $\beta$ ) do quantile regression para cada tamanho de *buffer*. Além disso, o risco foi estimado para o efeito singular de cada variável preditora (total de 28 variáveis preditoras). Destaca-se que tentou-se incluir mais de uma variável preditora no modelo, mas não gerou significância. A Equação 25 descreve o risco estimado.

$$\text{Risco}_{kij} = \beta_{kij} \times \text{IQR}_{kj}$$

Equação 25

Onde  $K$  é a variável preditora;  $i$  representa o quantil  $i^{\text{th}}$ , no qual foi utilizado 0,05; 0,10; 0,25; 0,75; 0,90 e 0,95;  $j$  é o tamanho do *buffer*; e *IQR* é a variação do interquartil, conforme apresentado pela Equação 26.

$$\text{IQR}_{kj} = 75^{\text{th}}\text{Percentile}_{k,j} - 25^{\text{th}}\text{Percentile}_{k,j}$$

Equação 26

Os resultados foram expressos pelo valor do coeficiente ( $\beta$ ) do modelo e os respectivos intervalos de 95% de confiança (95% IC), por conta do interquartil (IQR) de cada variável preditora. Considerou-se os resultados como significantes com o  $p\text{-value} \leq 0,05$ .

A análise estatística foi realizada no programa R. O Apêndice E.1 apresenta o modelo do script utilizado na análise. Por fim, destaca-se que o Apêndice C exibe a representação espacial de todos os dados utilizados na análise deste capítulo.

## 7.2.6 MODELAGEM EM SIG PARA CONSTRUÇÃO DOS MAPAS DE RISCO

Neste estágio foram utilizadas técnicas de modelagem em SIG para criação dos mapas de risco para DF. Os mapas de risco foram estimados com base em dois dados de entrada: os resultados da análise estatística (item 7.2.5.3) e os dados de endereçamento do DF, no qual foi fornecido pela Sedhab (2012).

Em relação aos dados de endereçamento, foi utilizado o nível das quadras com objetivo de criar um mapa de risco com um maior número de observações (número de polígonos). Pois os dados de saúde utilizados para a análise estatística se referem a 1.527 polígonos, enquanto que toda a base de quadras do DF possui um número total de 6.158 polígonos. Além disso, o nível de quadras foi escolhido pois apresenta o maior número de internações hospitalares, 3.090, conforme apresentado na Tabela 15.

Os mapas de risco foram construídos somente para as variáveis preditoras que apresentaram significância na análise do quantile regression. As variáveis que apresentaram significância

foram mensuradas em todas as 6.158 quadras, e para cada um dos 15 *buffers* (50 a 2.520 m). A técnica utilizada para o mensuramento foi a mesma apresentada pelo item 7.2.4.

Considerando que a análise do quantile regression avaliou somente uma variável preditora por vez, foi criado um mapa de risco para cada variável preditora. O risco total foi calculado para cada uma das 6.158 quadras, baseado na soma dos riscos de todos os *buffers*. A Equação 27 apresenta a operação algébrica realizada.

$$RM_{z,k,i} = \frac{Q_{z,k,j=1} \times Risk_{k,i,j=1}}{IQR_{k,j=1}} + \frac{Q_{z,k,j=2} \times Risk_{k,i,j=2}}{IQR_{k,j=2}} + \dots + \frac{Q_{z,k,j=n} \times Risk_{k,i,j=n}}{IQR_{k,j=n}}$$

Equação 27

Onde  $RM$  é o valor do risco para cada um dos 6.158 polígonos que representam as quadras;  $Z$  é o polígono;  $k$  é a variável preditora;  $i$  representa o quantil  $i^{th}$ ;  $Q$  é a quantidade da variável preditora  $k$  dentro do polígono  $Z$ , para cada tamanho de *buffer*  $j$  ( $j=1$  para *buffer* de 50m,  $j=2$  para *buffer* de 500 m,  $j=3$  para *buffer* de 870 m, ...,  $j=15$  para *buffer* de 2.520 m);  $Risk$  é o risco estimado pela Equação 25; e  $IQR$  é resultado da Equação 26.

Os mapas de risco foram determinados somente para o valor significativo de  $Risk$  ( $p\text{-value} \leq 0,05$  e 95% IC sem o valor zero) no *buffer*  $n$ .

## 7.3 RESULTADOS

### 7.3.1 ANÁLISE DESCRITIVA

Foram analisadas 7.269 internações de 1.527 blocos de endereços. O número médio de internações hospitalares por blocos de endereços é de 4,76 (0,017 considerando a taxa), com um desvio padrão igual a 21,71 (0,928 considerando a taxa). Há somente uma internação hospitalar em cada um dos percentis baixos, 5<sup>th</sup>, 10<sup>th</sup>, and 25<sup>th</sup>. Nos percentis altos, 75<sup>th</sup>, 90<sup>th</sup>, e 95<sup>th</sup>, há duas, quatro e nove internações, respectivamente (Tabela 18).




Tabela 16 - Resumo de estatística descritiva dos dados de saúde.

Parâmetros estatísticos	Número absoluto das internações	Taxa (Internação por população)
Mínimo	1	0,00007
Percentil 5 <sup>th</sup>	1	0,0013
Percentil 10 <sup>th</sup>	1	0,033
Percentil 25 <sup>th</sup>	1	0,071
Média	4,72	0,017
Desvio padrão	21,58	0,928
Percentil 75 <sup>th</sup>	2	0,042
Percentil 90 <sup>th</sup>	4	0,131
Percentil 95 <sup>th</sup>	9	0,274
Máximo	357	20,68

### 7.3.2 DECAIMENTO DO RISCO DE DOENÇAS CARDIORRESPIRATÓRIAS

Na análise do quantile regression não foi encontrada significância para os quantiles 0,05; 0,10; 0,25 e 0,75. Todos resultados significantes foram associados com os maiores quantiles; 0,90 e 0,95. Esse resultado é associado com a distribuição dos dados de saúde cujo no DF o maior número de internações está nos percentis 90<sup>th</sup> e 95<sup>th</sup>. Como exemplo dos diferentes efeitos com base nos quantiles, a Figura 56 apresenta o risco considerando as rodovias dentro do *buffer* de 500 m. Portanto, todos os resultados que apresentados por este capítulo são baseados nos quantiles 0,90 e 0,95.

Figura 56 - Variação do risco entre os quantiles (considerando as rodovias dentro do *buffer* de 500 m).

Fonte: Produção do próprio autor.

Nota: highways (rodovias); admissions (internações); significância foi encontrada somente para os quantiles 0,90 e 0,95.

Entre as 28 variáveis preditoras, 13 variáveis apresentaram valor zero no intervalo de confiança para todos os *buffers*, o que significa que essas variáveis não causam efeito significativo na mudança da variável resposta (taxas de internações). Essas 13 variáveis foram: terminais de ônibus, áreas de urbanização, áreas de construção, parques, florestas, lagos, PM, CH<sub>4</sub>, NMHC, CO<sub>2</sub>, temperatura, humidade e população (Tabela 17).

Especificamente para as variáveis do inventário de poluição, variáveis meteorológicas (temperatura e humidade) e população, a falta de significância está possivelmente relacionada à fonte e formato da variável. Por exemplo, talvez a técnica de SIG (interpolação do tipo IDW) utilizada para o mensuramento das variáveis do inventário de poluição e as variáveis meteorológicas não é acurada. Quanto à variável população, provavelmente há uma diferença insignificante do número de pessoas no decorrer dos *buffers*.

A Tabela 17 mostra que a área comercial foi a única variável preditora com coeficientes significantes em todos os 15 *buffers* (quantile 0,90). Resultados similares foram encontrados para as rodovias, na qual só não apresentaram significância para o primeiro *buffer*, de 50 m.

Entre as categorias de variáveis, o inventário de poluição do ar foi a categoria que apresentou os menores efeitos na variável resposta, em que somente CO e NO<sub>x</sub> tiveram efeitos significantes, e apenas para os menores *buffers* 50 – 500 m, respectivamente (Tabela 17).

Algumas variáveis apresentaram valores de IQR igual a zero para os primeiros *buffers*, por exemplo, rodovias, *buffer* = 50 m; indústrias, *buffer* = 50 a 1.700 m; solo exposto, *buffer* = 50 a 1.140 m. Sugere-se, portanto, que essas variáveis não estão associadas com a ocorrência de internações nas distâncias de *buffers* avaliadas. A Tabela 17 mostra essas variáveis que apresentaram IQR igual a zero.




Categoria	Variáveis	Q	Buffer														
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
	NMHC	0,90															
		0,95															
	CO <sub>2</sub>	0,90															
		0,95															
Meteorologia e terreno	Temperatura	0,90															
		0,95															
	Humidade	0,90															
		0,95															
	Altimetria	0,90															
		0,95															
Demografia e economia	População	0,90															
		0,95															
	Renda	0,90															
		0,95															
Outros	Incêndios florestais	0,90	*														
		0,95	*														

Notas: Quantiles (Q); quantile 0,90 com IC  $\neq 0$  e  $p\text{-value} \leq 0,05$  (cor cinza claro); quantile 0,95 com IC  $\neq 0$  e  $p\text{-value} \leq 0,05$  (cor cinza escuro); IC contém zero (branco); Buffer 50 m (1); Buffer 500 m (2); Buffer 87 m (3); Buffer 1.140 m (4); Buffer 1.350 m (5); Buffer 1.540 m (6); Buffer 1.700 m (7); Buffer 1.840 m (8); Buffer 1.960 m (9); Buffer 2.080 m (10); Buffer 2.180 m (11); Buffer 2.280 m (12); Buffer 2.370 m (13); Buffer 2.450 m (14); Buffer 2.520 m (15); IQR igual a zero (\*).

A Figura 57 apresenta o risco calculado para cada *buffer*, em relação ao IQR, aos quantiles e específico para as variáveis da categoria transporte (rodovias, ruas e avenidas). Considerando as rodovias não há risco no *buffer* < 50 m, pois o IQR é igual a zero. Além disso, o risco para o quantile 0,95 é maior que o risco para o quantile 0,90. O maior risco no quantile 0,95 foi encontrado para os blocos de endereços localizados a 1.140 m das rodovias. Em um bloco de endereço com 3.400 m de rodovias (*buffer* 1.140 m) foi encontrado um aumento de 15 interações.

As ruas e avenidas também apresentaram riscos elevados. Há risco desde o primeiro *buffer*, 50 m (quantile 0,95; risco = 3 interações; 95% IC: 0,6; 24,1), com IQR igual a 550 m. O maior risco está no *buffer* 500 m (quantile 0,95; risco = 6 interações; 95% IC: 1,4; 7,6), com IQR igual a 6.550 m. O risco se torna zero no *buffer*  $\geq 1.140$  m, enquanto o IQR continua aumentando (Figura 57).

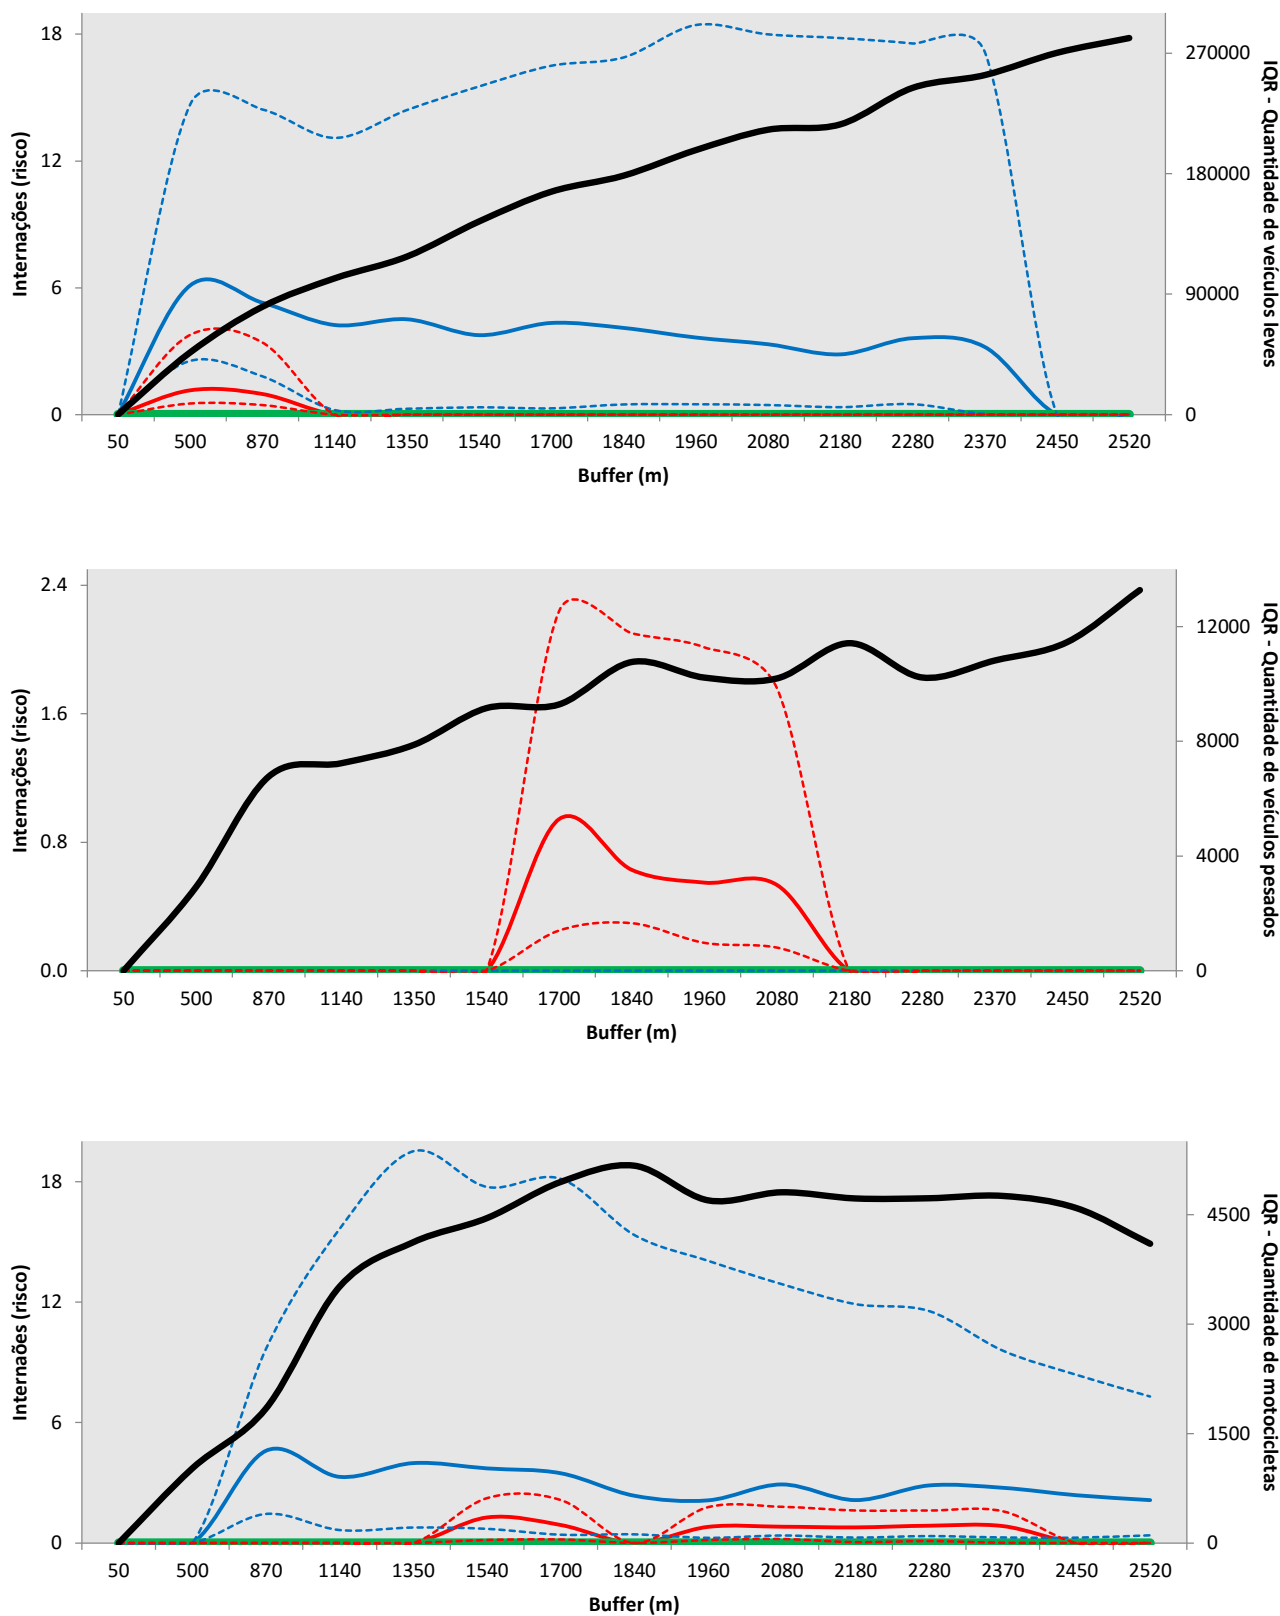
Figura 57 – Variação do risco no decorrer dos *buffers* – rodovias, ruas e avenidas.

Fonte: Produção do próprio autor.

Nota: linha azul sólida (internações – risco – coeficientes para o quantile 0,95); linha vermelha sólida (internações – risco – coeficientes para o quantile 0,90); linha verde sólida (internações – risco – coeficientes para o quantile 0,05; 0,10; 0,25; 0,75); linha azul pontilhada (internações – risco – 95% IC para o quantile 0,95); linha vermelha pontilhada (internações – risco – 95% IC para o quantile 0,90); linha preta sólida (IQR – quantidade da variável preditora).

Os veículos leves, os veículos pesados e as motocicletas não apresentaram risco no *buffer* <50m (IQR = 0). Especificamente para os veículos leves, o maior risco foi para distância  $\leq 500$  m (quantile 0,95; risco = 6 internações; 95% IC: 2,6; 14,6), com IQR igual a 46.480 veículos. O risco diminuiu entre 870 e 2.370 m (quantile 0,95; risco = 4 internações; 95% IC: 1,8; 14,4). E para distâncias > 2.370 m o risco é zero. Para os veículos pesados, em geral, o risco foi menor comparado com os veículos leves. Para os *buffers* entre 1.700 m e 2.080 m, o risco decorrente dos veículos pesados é igual a 1 (quantile 0,90; 95% IC: 0,2; 2,2). E para as motocicletas o maior risco foi para o *buffer* 870 m (quantile 0,95; risco = 4; 95% IC: 1,4; 9,7) - Figura 58.

Figura 58 - Variação do risco no decorrer dos *buffers* – veículos leves, pesados e motocicletas.




Fonte: Produção do próprio autor.

Nota: linha azul sólida (internações – risco – coeficientes para o quantile 0,95); linha vermelha sólida (internações – risco – coeficientes para o quantile 0,05; 0,10; 0,25; 0,75); linha azul pontilhada (internações – risco – 95% IC para o quantile 0,95); linha vermelha pontilhada (internações – risco – 95% IC para o quantile 0,90); linha preta sólida (QTR – quantidade da variável preditora).

Não há risco relacionado com as áreas industriais em distâncias  $\leq 2,080$  m. Entre 50 e 1.700 m o IQR para áreas industriais é igual a zero. E entre 1.840 e 2.080 m, mesmo com IQR igual a aproximadamente 6 mil  $m^2$ , o risco é zero. Há um risco baixo somente para *buffer* > 2.080 m, e o maior risco está no *buffer* de 2.520 m (quantile 0,90; risco = 0,18 interações; 95% IC: 0,07; 0,55) - Figura 59.

Considerando as áreas comerciais, foi encontrado risco para todos os *buffers*. O risco aumento até o *buffer* de 1.700 m, no qual nessa distância ocorre o maior risco (quantile 0,95; risco = 12 interações; 95% IC: 2,2; 20,8), IQR igual a 74.000  $m^2$ . Em seguida o risco diminui para em torno de 7 interações; quantile 0,95; enquanto o IQR continua aumentando (Figura 59).

Figura 59 - Variação do risco no decorrer dos *buffers* – áreas industriais e comerciais.

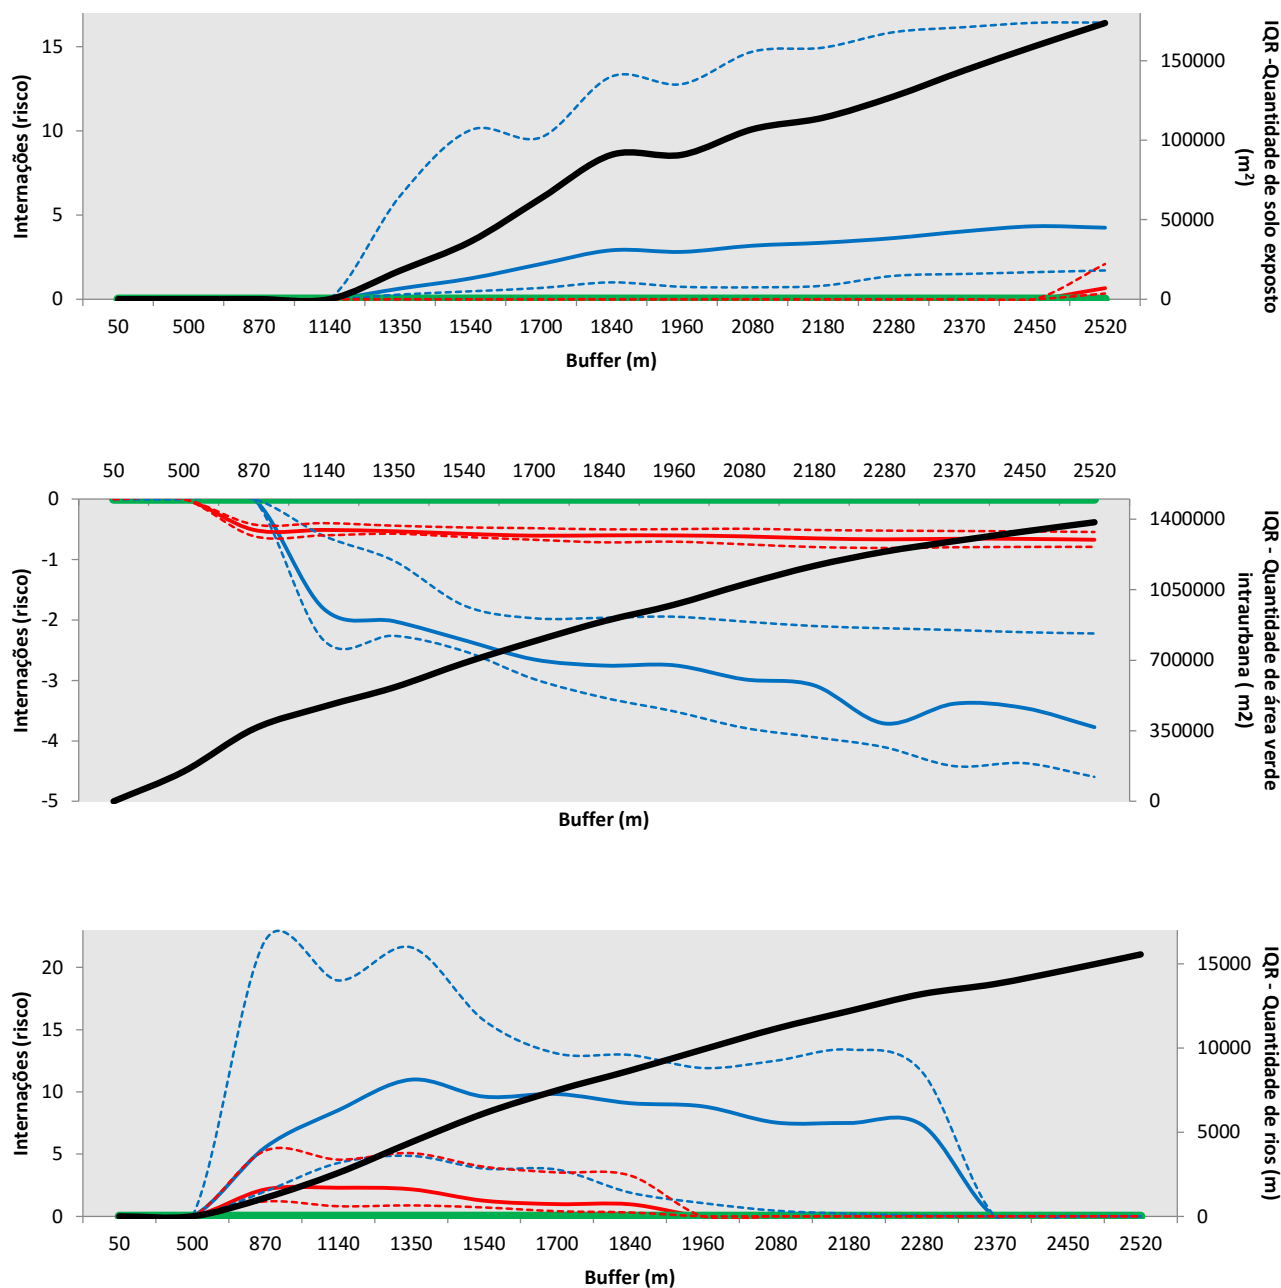


Fonte: Produção do próprio autor.

Nota: linha azul sólida (interações – risco – coeficientes para o quantile 0,95); linha vermelha sólida (interações – risco – coeficientes para o quantile 0,90); linha verde sólida (interações – risco – coeficientes para o quantile 0,05; 0,10; 0,25; 0,75); linha azul pontilhada (interações – risco – 95% IC para o quantile 0,95); linha vermelha pontilhada (interações – risco – 95% IC para o quantile 0,90); linha preta sólida (IQR – quantidade da variável preditora).

Em relação às áreas de solo exposto, observou-se um aumento do efeito do IQR afetando o risco de ocorrência de interações entre 1.350 a 2.520 m. O maior risco é no *buffer* de 2.450 m (quantile 0,95; 4 interações; 95% IC: 1,6; 16,4). O efeito foi o oposto quando foi analisada às áreas verdes intraurbana. Observou-se um decréscimo do risco entre todos os *buffers*, enquanto que o IQR aumentava em cada *buffer*. Quanto aos rios, há risco significativo somente entre 870 e 2.280 m no quantile 0,95; e entre 870 e 1.700 m no quantile 0,90 (Figura 60).

Figura 60 - Variação do risco no decorrer dos *buffers* – áreas de solo exposto, verde intraurbana e rios.




Fonte: Produção do próprio autor.

Nota: linha azul sólida (interações – risco – coeficientes para o quantile 0,95); linha vermelha sólida (interações – risco – coeficientes para o quantile 0,90); linha verde sólida (interações – risco – coeficientes para o quantile 0,05; 0,10; 0,25; 0,75); linha azul pontilhada (interações – risco – 95% IC para o quantile 0,95); linha vermelha pontilhada (interações – risco – 95% IC para o quantile 0,90); linha preta sólida (IQR – quantidade da variável preditora).



As variáveis relacionadas à categoria do inventário de poluição (CO e NO<sub>x</sub>) apresentaram risco somente em distâncias curtas, < 500 m e < 50 m, respectivamente (Figura 61). As demais variáveis (PM, CH<sub>4</sub>, NMHC e CO<sub>2</sub>) não apresentaram risco.


Figura 61 - Variação do risco no decorrer dos *buffers* – CO e NO<sub>x</sub>.



Fonte: Produção do próprio autor.

Nota: linha azul sólida (internações – risco – coeficientes para o quantile 0,95); linha vermelha sólida (internações – risco – coeficientes para o quantile 0,90); linha verde sólida (internações – risco – coeficientes para o quantile 0,05; 0,10; 0,25; 0,75); linha azul pontilhada (internações – risco – 95% IC para o quantile 0,95); linha vermelha pontilhada (internações – risco – 95% IC para o quantile 0,90); linha preta sólida (IQR – quantidade da variável preditora).


Em relação à variável renda, foi observado resultado que não era esperado. Espera-se encontrar elevado risco de doenças cardiorrespiratórias em áreas com baixa renda (LIM et al., 2012; BRANIS; LINHARTOVA, 2012). No entanto, observou-se um aumento do risco entre 870 e 1.140 m, no qual nesse intervalo de distância o IQR para a renda aumentou (Figura 62). Possivelmente, a variável renda não apresenta variação entre os tamanhos de *buffers*. Esse mesmo problema aconteceu com a variável população, conforme mencionado anteriormente.

Figura 62 - Variação do risco no decorrer dos *buffers* – renda.

Fonte: Produção do próprio autor.

Nota: linha azul sólida (internações – risco – coeficientes para o quantile 0,95); linha vermelha sólida (internações – risco – coeficientes para o quantile 0,90); linha verde sólida (internações – risco – coeficientes para o quantile 0,05; 0,10; 0,25; 0,75); linha azul pontilhada (internações – risco – 95% IC para o quantile 0,95); linha vermelha pontilhada (internações – risco – 95% IC para o quantile 0,90); linha preta sólida (IQR – quantidade da variável preditora).

Considerando a variável altimetria, os resultados mostraram uma alta variação de risco enquanto o IQR se manteve praticamente constante no decorrer de todos os *buffers* (Figura 63). Sugere-se que a variável altimetria não é uma boa preditora para a avaliação do risco de internações por doenças cardiorrespiratórias no DF. Provavelmente é porque a maior parte da área urbana no DF possui um terreno do tipo plano.


Figura 63 - Variação do risco no decorrer dos *buffers* – altimetria.

Fonte: Produção do próprio autor.

Nota: linha azul sólida (internações – risco – coeficientes para o quantile 0,95); linha vermelha sólida (internações – risco – coeficientes para o quantile 0,90); linha verde sólida (internações – risco – coeficientes para o quantile 0,05; 0,10; 0,25; 0,75); linha azul pontilhada (internações – risco – 95% IC para o quantile 0,95); linha vermelha pontilhada (internações – risco – 95% IC para o quantile 0,90); linha preta sólida (IQR – quantidade da variável preditora).

E em relação a variável incêndios florestais, o risco é presente entre 500 e 1.540 m. O maior risco está no *buffer* de 500 m (quantile 0,95; risco = 4 interações; 95% IC: 3,0; 15,2). Acima de 500 m o risco diminui até o *buffer* de 1.700 m, se tornando zero (Figura 64).

Figura 64 - Variação do risco no decorrer dos *buffers* – incêndios florestais.



Fonte: Produção do próprio autor.

Nota: linha azul sólida (interações – risco – coeficientes para o quantile 0,95); linha vermelha sólida (interações – risco – coeficientes para o quantile 0,90); linha verde sólida (interações – risco – coeficientes para o quantile 0,05; 0,10; 0,25; 0,75); linha azul pontilhada (interações – risco – 95% IC para o quantile 0,95); linha vermelha pontilhada (interações – risco – 95% IC para o quantile 0,90); linha preta sólida (IQR – quantidade da variável preditora).

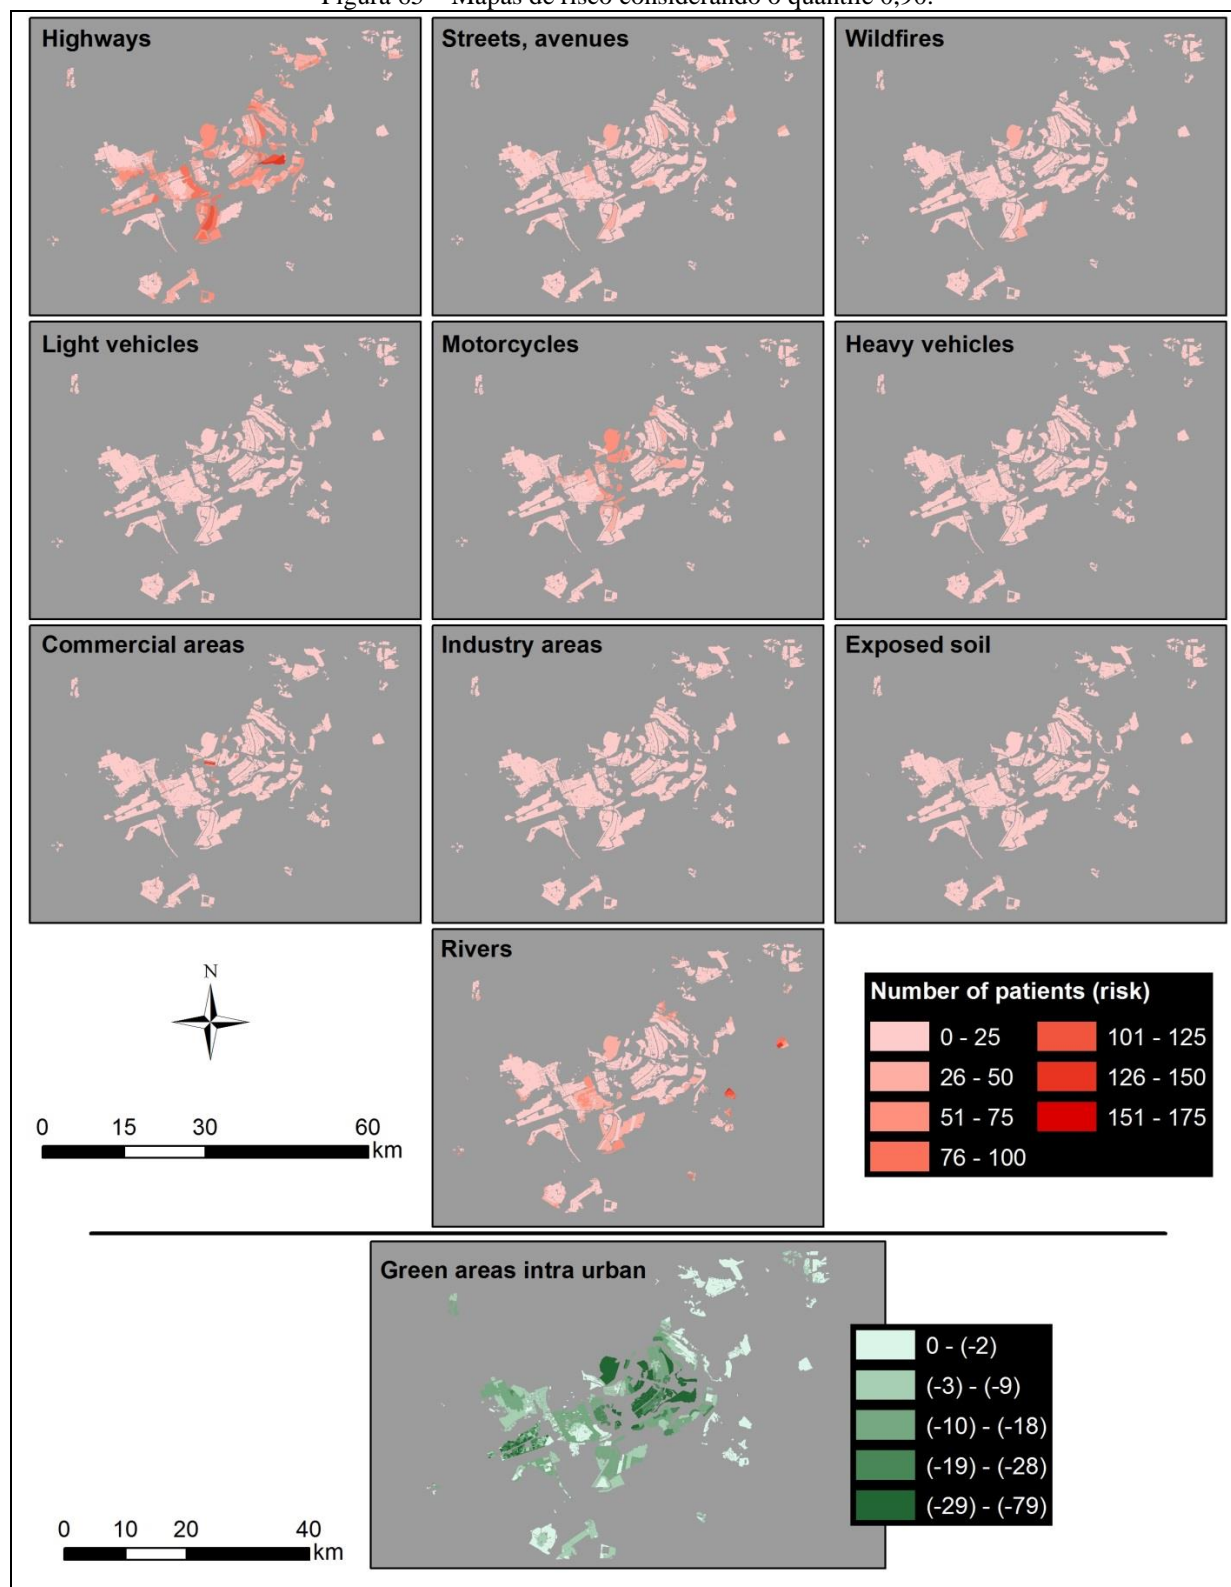
### 7.3.3 MAPAS DE RISCO

Os resultados obtidos do processo de modelagem em SIG para criação dos mapas de riscos são apresentados nas Figura 65 e Figura 66, com base nos quantiles que apresentaram os resultados com significância, 0,90 e 0,95; respectivamente.

Devido aos resultados inesperados e/ou sem representação para a área do DF, as variáveis renda, altimetria, CO e NOx não foram incluídas para a elaboração do mapa de risco.

Por fim, destaca-se que os mapas de risco são apresentados separadamente pela variável que causa um decréscimo do risco (áreas verdes intraurbana) e pelas variáveis que causam um aumento no risco (restante das variáveis).

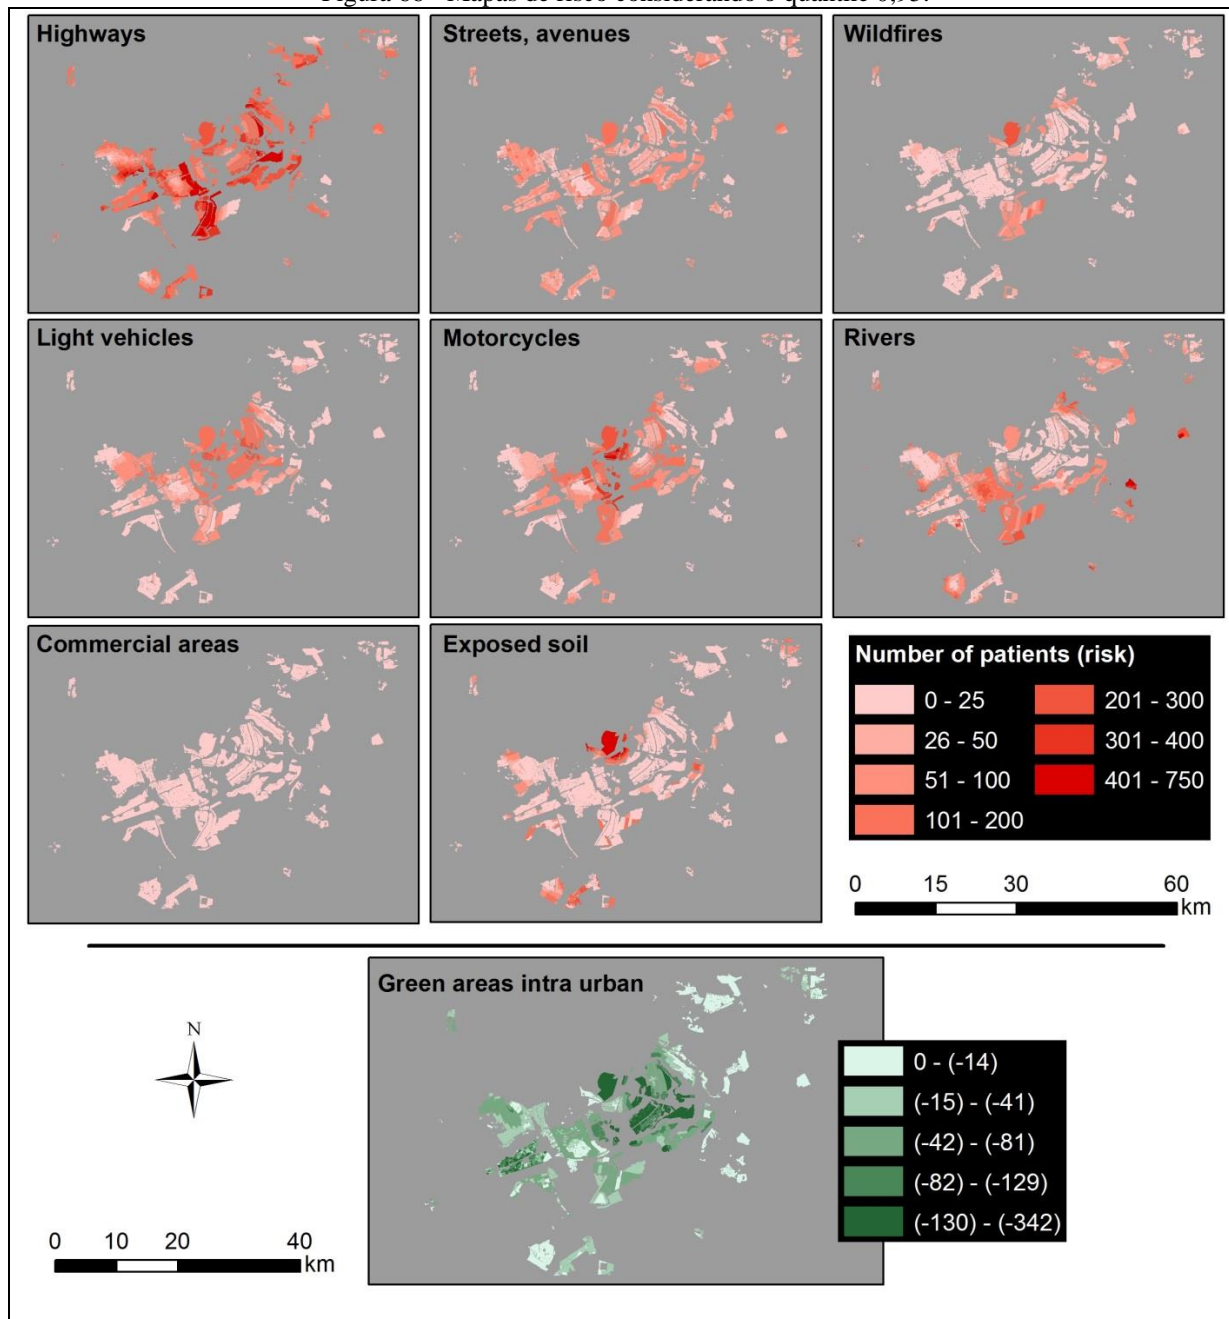
Figura 65 – Mapas de risco considerando o quantile 0,90.



Fonte: Produção do próprio autor.

Nota: Highways (rodovias); Streets, avenues (ruas e avenidas); Wildfires (incêndios florestais); Light vehicles (veículos leves); Motorcycles (motocicletas); Heavy vehicles (veículos pesados); Commercial areas (áreas comerciais); Industry areas (áreas industriais); Exposed soil (solo exposto); Rivers (rios); Green áreas intra urban (áreas verdes intraurbana); Number of patients – risk (número de pacientes – risco).

Figura 66 - Mapas de risco considerando o quantile 0,95.



Fonte: Produção do próprio autor.

Nota: Highways (rodovias); Streets, avenues (ruas e avenidas); Wildfires (incêndios florestais); Light vehicles (veículos leves); Motorcycles (motocicletas); Commercial areas (áreas comerciais); Exposed soil (solo exposto); Rivers (rios); Green áreas intra urban (áreas verdes intraurbana); Number of patients – risk (número de pacientes – risco).

## 7.4 DISCUSSÃO

Entre as 15 variáveis que apresentaram risco significativo (Tabela 17), 9 variáveis não mostraram efeitos no risco em distâncias curtas (em geral,  $\leq 500$  m). Isso pode significar que, para explicar melhor o risco de doenças cardiorrespiratórias é necessário que considere variáveis preditoras localizadas mais de 500 m das residências. Os mesmos resultados foram encontrados por Power et al. (2015) nos Estados Unidos com avaliação dos níveis de ansiedade na população que vive próximo às rodovias.

Observou-se também que 7 variáveis (rodovias, motocicletas, áreas industriais, áreas comerciais, áreas de solo exposto, áreas verdes intraurbana e renda) tiveram risco significativo até o último *buffer* 2.520 m (Tabela 17). Ou seja, o risco dessas variáveis no *buffer* de 2.520 m não é zero. Provavelmente ainda há risco acima de 2.520 m. Não foi possível comparar esse resultado com outros estudos pois em geral a maior distância avaliada em pesquisas anteriores foi de 1.500 m.

As rodovias foram as que apresentaram o maior risco. Observou-se que um aumento de 2.500m de rodovias (*buffer* entre 500 a 1.140 m) foi associado com um aumento de 46% no risco de doenças cardiorrespiratórias (quantile 0,95). Pesquisas anteriores mostram que a proximidade às rodovias está associada com o risco de doenças cardiovasculares. Brugge et al. (2013) mostram que há um aumento de risco para as pessoas que vivem a 50 m das rodovias; o risco aumenta em 49% (95% IC: 6%, 110%). Para aqueles que vivem entre 50 e 100 m o risco é de 41% (95% IC: 6%, 86%).

Considerando as ruas e avenidas, os resultados sugerem que o risco é significativo em distâncias curtas (máximo 870 m). O maior risco é no *buffer* de 500 m (quantile 0,95). Observou-se que um aumento de 6.000 m de ruas e avenidas (*buffer* 50 a 500 m) esteve associado com um aumento de 51% do risco de doenças cardiorrespiratórias (quantile 0,95).

Comparando o risco entre os veículos (leves, pesados e motocicletas), observou-se um decréscimo do risco com o aumento do tamanho de *buffer* para os veículos leves e motocicletas. Por outro lado, o risco dos veículos pesados é presente somente entre os *buffers* de 1.540 e 2.180 m. Sugere-se que a maior concentração de veículos pesados no DF está localizada distante das áreas residenciais. Williams et al. (2009) também encontraram que os veículos pesados estão distantes das residências, o que não representa efeitos adversos à saúde humana.

Outros estudos mostraram que o tráfego de veículos é associado com o aumento de doenças. Por exemplo, Williams et al. (2009) conduziram um estudo em Seattle, Washington – EUA, e mostraram que as pessoas que vivem a 150 m das vias arteriais têm 21% (95% IC: 15,6%; 23,5%) menos *NK cytotoxicity* (função de imunização do organismo) do que as pessoas que vivem mais de 150 m das vias arteriais.

Os resultados também indicaram que as residências estão localizadas distantes das áreas industriais no DF. Há risco somente para o *buffer* > 2.080 m. O risco acima desse *buffer* é muito baixo, tendo o maior risco igual a 0,18 (95% IC: 0,07; 0,55). Esse resultado não é uma surpresa, pois o DF é uma área com baixa concentração de indústrias.

Por outro lado, há uma alta concentração de área comercial no DF. Os resultados mostraram riscos significantes para todos os *buffers*. O maior risco foi para o *buffer* de 1.700 m (quantile 0,95; risco = 12 internações; 95% IC: 2,2; 20,8). Estimou-se que o risco de internações no *buffer* de 1.700 m (quantile 0,95) é 197% maior, que para o *buffer* de 500 m. Comparando o *buffer* de 1.700 m com o *buffer* de 2.520 m (último *buffer*), o risco diminuiu 49%. O decréscimo do risco para *buffers* maiores considerando áreas comerciais foi também encontrado em outros estudos. Por exemplo, James et al. (2014) estudaram a associação de ambientes construídos com o índice de massa corporal. Os autores encontraram que o efeito decorrente das áreas comerciais diminuiu conforme o *buffer* aumentava.

Observando as áreas de solo exposto, os resultados mostraram um aumento do risco iniciando no *buffer* de 1.140 m (quantile 0,95). Abaixo de 1.140 m o risco é zero para todos os quantiles. Observou-se que no último *buffer* (2.520 m) o risco aumentou em 572% (quantile 0,95). Provavelmente o risco ainda existe para distâncias acima do último *buffer*. Sugere-se que a dispersão das partículas atmosféricas decorrentes do solo exposto no DF a longas distâncias está sendo influenciadas por condições meteorológicas, por exemplo, o vento. Estudos anteriores (WALLACE et al., 2009; RODRIGUEZ et al., 2013) mostram que a velocidade do vento podem contribuir significativamente para a existência do risco decorrentes de material particulado vindo do solo em distâncias maiores que 2.520 m.

Os resultados mostraram que as áreas de vegetação intraurbana são importantes para minimizar o risco de internações por motivo do sistema cardiorrespiratório. Observou-se que um aumento de 1 km<sup>2</sup> de áreas verdes intraurbana (entre os *buffers* de 1.140 e 2.520 m) esteve associado com menos 2 internações (quantile 0,95). Outros estudos também mostraram um efeito positivo das áreas verdes para a saúde humana (ZANDBERGEN; GREEN, 2007; NARDO et al., 2010). Nielsen and Hansen (2007), por exemplo, mostraram que quem vive em distâncias curtas de

áreas verdes possui menos chance de ter stress e obesidade. Berg et al. (2010) mostram também que há menos ocorrência de doenças mentais para quem vive menos de 1 km de áreas com vegetação.

Quanto aos corpos d'água (rios e lagos), não foi observado associações que demonstrassem benefício para a saúde humana. Os resultados mostraram que há um aumento de risco entre 870 e 1.350 m (quantile 0,95) quando considera os rios como variável preditora. Observou-se que um aumento de 3.200 m de rio (entre os *buffers* 870 e 1.350 m) foi associado com um aumento de 98% no risco (quantile 0,95). Sugere-se que as áreas aos redores dos rios no DF apresentam uma alta densidade populacional. Quanto aos lagos, não foram encontrados resultados significantes. Não foi possível comparar esses resultados com outros estudos, pois ainda não há pesquisas que verificaram a associação de saúde com a presença de corpos d'água (considerada como um tipo de característica ambiental).

Em relação aos incêndios florestais, os resultados mostraram um decréscimo no risco entre 500 e 1.540 m. As pessoas que vivem  $\leq 500$  m dos pontos mais próximos de incêndios florestais possuem mais chances de terem doenças do sistema cardiorrespiratório que as pessoas que vivem  $> 500$  m. O principal ponto é que os incêndios florestais são relacionados com a emissão de poluentes atmosféricos, por exemplo, MP, CO e Black Carbon (BC). Pesquisas anteriores mostram os efeitos desses incêndios à saúde humana (WILLIAMS et al., 2012; O'NEILL et al., 2013; YOUSOUF et al., 2014). Johnston et al. (2014) mostram que os eventos de incêndios florestais em Sidnei, Austrália, foram associados com um aumento de atendimentos hospitalares por doenças respiratórias.

A análise apresentada por este capítulo tem algumas limitações. Primeiro, as variáveis que representam a circulação de veículos (veículos leves, pesados e motocicletas) são de 233 vias do DF (a maioria rodovias e grandes avenidas). Provavelmente se os dados fossem de todas as vias do DF, os resultados poderiam apresentar uma elevada associação da quantidade de veículos com o número de internações. A segunda limitação é quanto aos dados de saúde (a mesma limitação apresentada nos Capítulos 4 e 5). Os dados de saúde são somente uma amostra dos dados que estão disponíveis no site do Datasus (DATASUS, 2015). Os dados utilizados neste capítulo são referentes a 7.269 internações (possui o endereço residencial), enquanto que os dados do site do Datasus são de 399.564 internações (não possui o endereço residencial). E a terceira limitação é quanto ao processo adotado para a normalização dos dados (dados de saúde por população). Não é uma regra de que em todos os casos haverá uma relação linear entre a população residente e a respectiva área ocupada.



Por fim, destaca-se que os resultados da análise deste capítulo sugerem que as variáveis relacionadas às características ambientais dos bairros explicam os casos de internações por doenças cardiorrespiratórias. Os mapas de risco apresentados mostram a distribuição espacial do risco de internações, até mesmo para as áreas que não apresentavam dados de saúde. Essas contribuições podem contribuir para o processo de gestão urbana do DF com objetivo de melhorar a qualidade de vida da população.

## Capítulo 8 - Uma nova abordagem do uso do solo para avaliação da saúde humana: a relação entre tipos de estruturas urbanas e risco de doenças cardiorrespiratórias

---

### 8.1 APRESENTAÇÃO

Estudos têm mostrado que além do estilo de vida, aspectos ambientais são um importante fator de risco para a saúde humana (BHATNAGAR, 2006; O'TOOLE et al., 2008; BUONANNO, GIORGIO et al., 2013; LIN, H. et al., 2013; CHUM; O'CAMPO, 2015).

Dentre os aspectos ambientais, o uso do solo é um exemplo de variável que pode explicar a qualidade de vida das pessoas. Pesquisas mostram que o tipo de uso do solo tem ligação com a ocorrência de doenças mentais (VILLANUEVA et al., 2013), obesidade (FRASER et al., 2012; WALL et al., 2012), índice de massa corporal (JAMES et al., 2014) e doenças cardiorrespiratórias (CHUM; O'CAMPO, 2015). Esses estudos assumem que o uso do solo são *proxy* que identificam as variáveis diretamente relacionada com a qualidade de vida. Por exemplo, o uso do solo pode ser uma *proxy* das fontes de emissões de poluentes atmosféricos, nas quais essas fontes têm relação direta com a ocorrência de doenças cardiorrespiratórias. Esse exemplo já foi provado por Corburn (2007), Rosenlund et al. (2008), Su et al. (2009).

Apesar de que vários estudos já exploraram as variáveis relacionadas ao uso do solo para avaliar a saúde humana, ainda nenhuma pesquisa utilizou o conceito de morfologia urbana, identificado pelos tipos de estruturas urbanas, como *proxy* indicadora. Na literatura internacional esse conceito é conhecido como UST – *Urban Structure Types*. Como o termo ainda é pouco conhecido no Brasil, nesta tese será adotado a sigla UST.

De acordo com Heiden et al. (2012), USTs são indicadores espaciais, nos quais descrevem o sistema urbano por meio das propriedades físicas (ex.: tamanho, superfície dos materiais), das características ambientais (ex.: clima, hidrologia) e as funções (ex.: uso do solo). A abordagem UST é mais específica que o método convencional para classificação do uso do solo. Por meio da UST é possível identificar diferentes tipos de morfologia das áreas residenciais, industriais, comerciais, áreas públicas, áreas verdes etc. A identificação dos tipos de morfologia é feita com

base no critério de quantidade, agregação, taxa de vegetação, área impermeável e conectividade (HEIDEN et al., 2012; WEBER et al., 2014b).

O método UST já foi aplicado em estudos para avaliação do consumo de água (HOFER, 2013), do risco de mudanças climáticas (MOON et al., 2009), das ilhas urbanas de calor (WEBER et al., 2014a) e do ruído decorrente do tráfego de veículos (WEBER et al., 2014b). Mas ainda não houve estudos com objetivo de estudar as USTs como preditoras da exposição humana.

Portanto, este capítulo apresentará a avaliação entre USTs e risco de ocorrência das doenças cardiorrespiratórias. A avaliação apresentada por este capítulo é referente ao sétimo objetivo específico desta tese.

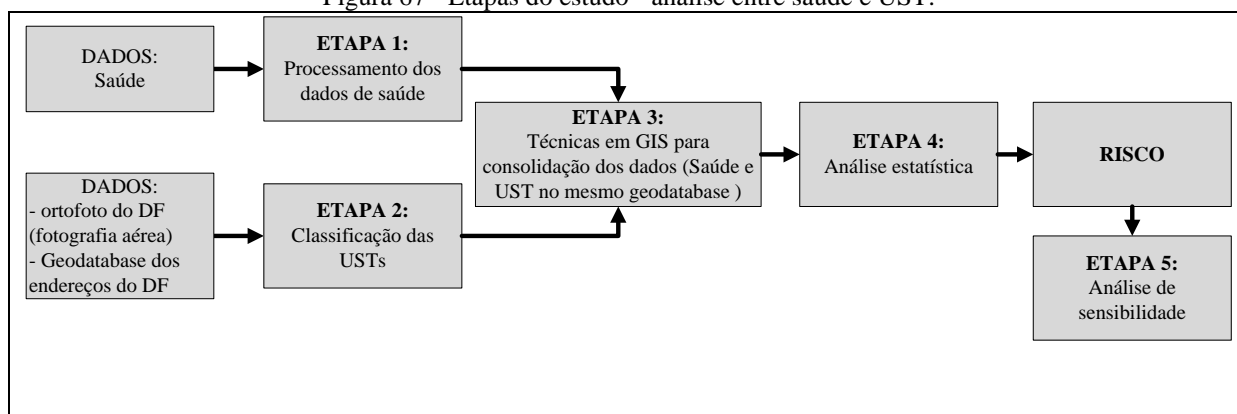
Destaca-se que os resultados que serão descritos neste capítulo foram publicados no *Journal Environment International* (Apêndice B.5).

## 8.2 MÉTODO

### 8.2.1 DESIGN DO ESTUDO

O estudo deste capítulo foi do tipo ecológico com uma análise cross-sectional da associação entre UST e internações por doenças cardiorrespiratórias. Cinco etapas representaram o estudo: 1) processamento dos dados de saúde; 2) classificação das USTs; 3) consolidação dos dados de saúde e USTs em um único geodatabase; 4) aplicação das análises estatísticas, e; 5) análise de sensibilidade (Figura 67).

Figura 67 - Etapas do estudo - análise entre saúde e UST.



Fonte: Produção do próprio autor.

### 8.2.2 PROCESSAMENTO DOS DADOS DE SAÚDE

O dado de saúde utilizado foi decorrente do resultado do processamento dos dados do Datasus (2013). O formato e a descrição do dado são os mesmos que foram utilizados no Capítulo 7 - Análise do decaimento do risco de doenças cardiorrespiratórias.



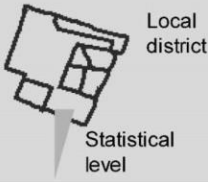


Portanto, foi utilizado na análise do presente capítulo um total de 1.527 polígonos que representam a agregação dos pacientes internados por doenças cardiorrespiratórias. Quanto ao número de pacientes, foram estudados um total de 7.269.

### 8.2.3 CLASSIFICAÇÃO DAS UST

O conceito de UST foi desenvolvido nos anos de 1960 para os estudos de planejamento urbano nas cidades da Alemanha. Desde então, a metodologia UST tem sido utilizada para o entendimento da dinâmica dos sistemas urbanos e para promover o desenvolvimento sustentável (RAITH, 2000).

As USTs são indicadores espaciais nos quais descrevem o sistema urbano por meio das propriedades físicas, características ambientais e propriedades funcionais (HEIDEN et al., 2012). De acordo com Banzhaf and Höfer (2008), é considerada na abordagem UST a ideia da escala espacial (no qual varia do nível municipal para o nível do edifício ou residência) e a quantidade da generalização. Por exemplo, a Figura 68 mostra que as USTs são definidas por certas características, tais como: densidade das características (densidade dos prédios, estruturas urbanas); quantidade de área verde, e; conectividade entre as características.

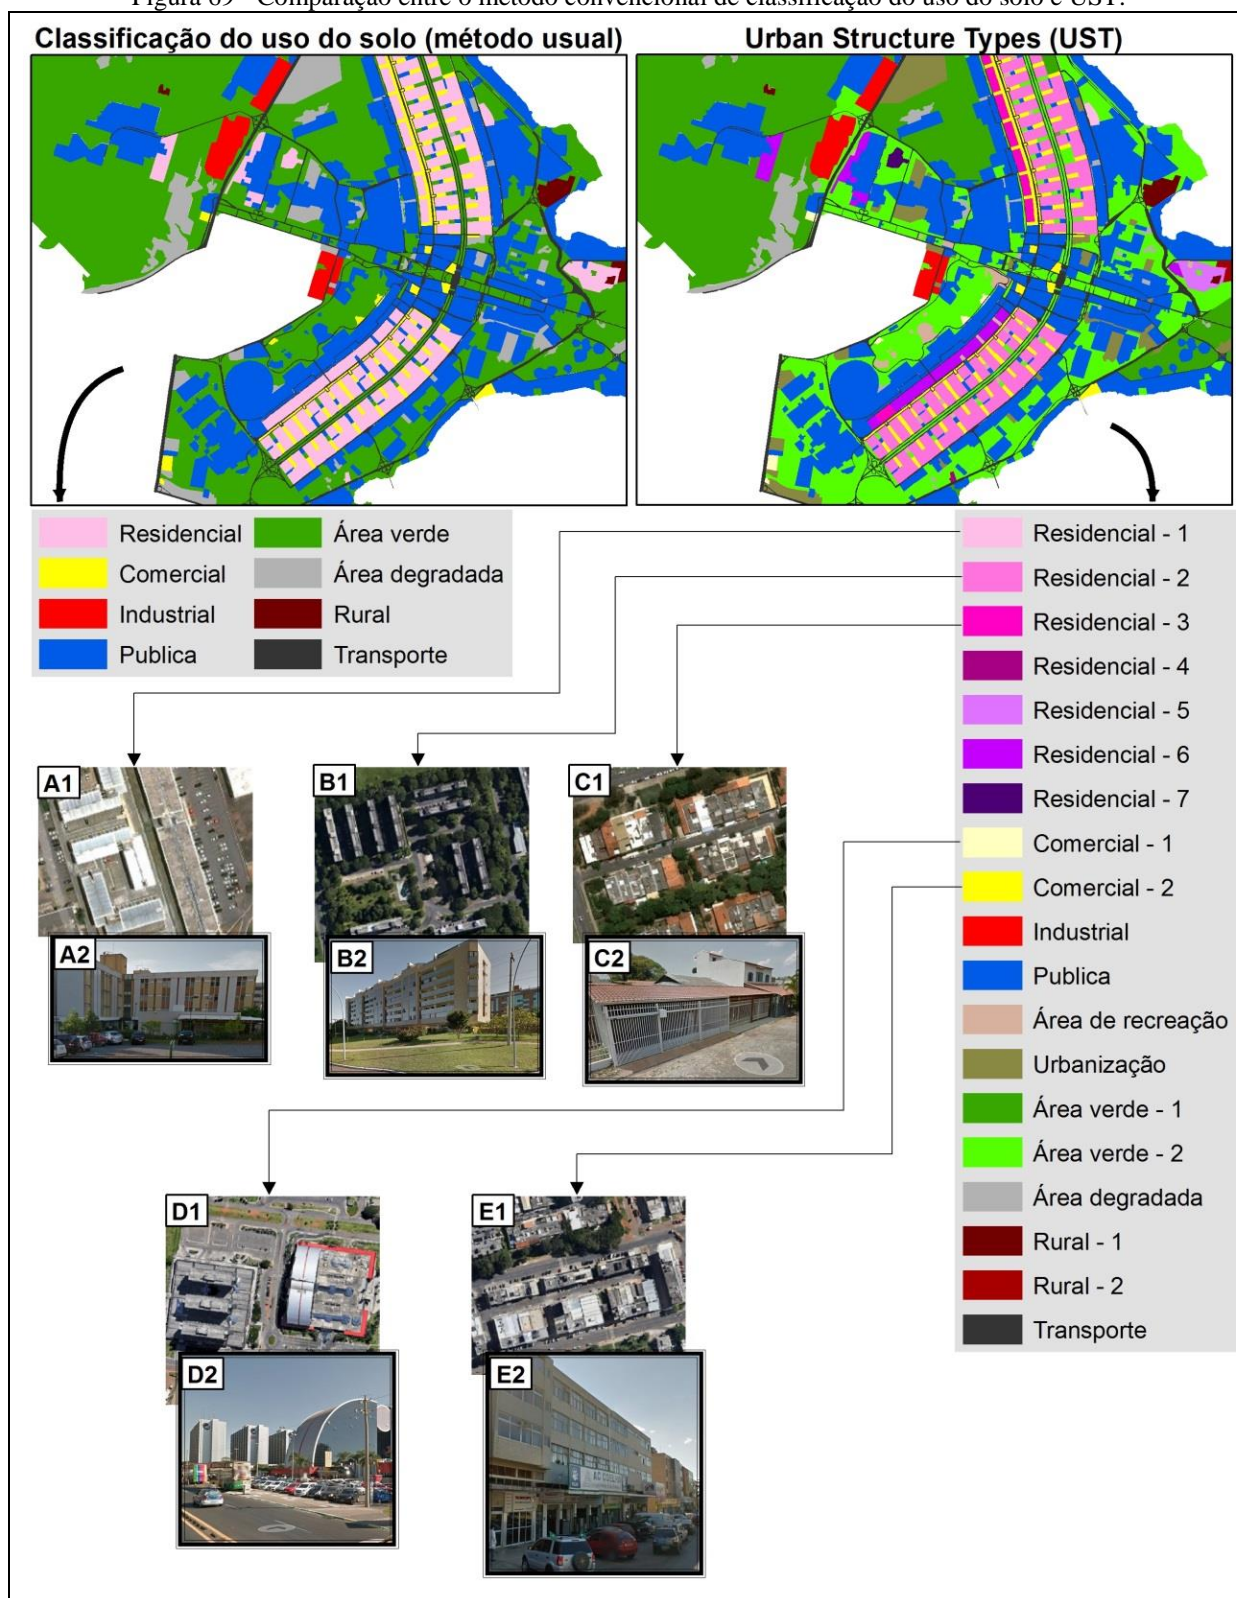
Figura 68 - Análise das USTs com base na escala.

	Scale	Amount of generalisation	Evaluation
administrative	 <p>City Municipality</p> <p>Urban land use / land cover</p>		<p>Urban dynamics: land use processes, e.g. suburbanisation</p> <p>Natural impacts: climate / health e.g. urban heat island</p> <p>Natural hazards: e.g. flooding; earthquakes; landslides</p>
	 <p>Local district Statistical level</p> <p>Urban morphology</p>		<p>Biotope structure</p> <p>Settlement structure</p>
	 <p>Local neighborhood</p> <p>Urban structure type</p>		<p>Degree of imperviousness</p> <p>Degree of mixed or homogeneous structure</p> <p>Potentials in local land use structure</p> <p>Environmental quality</p>
physiological	 <p>Building</p> <p>Structure element</p>		<p><b>Site specifics</b></p>

Fonte: Banzhaf and Höfer (2008).

Diferente do método convencional de classificação do uso do solo, no qual tem sido utilizado nos estudos em saúde ambiental, o método UST é mais específico em termos de escala espacial e quantidade da generalização. A Figura 69 mostra a comparação entre o método convencional e UST na região do DF. Destaca-se que a Figura 69 apresenta somente o exemplo geral, pois os tipos de UST podem ser mais específicos (ter mais classes de UST).

Figura 69 - Comparação entre o método convencional de classificação do uso do solo e UST.



Fonte: Produção do próprio autor.

Nota: A1 – exemplo da classe Residencial 1 (imagem de satélite); A2 – exemplo da classe Residencial 1 (detalhes do local); B1 – exemplo da classe Residencial 2 (imagem de satélite); B2 – exemplo da classe Residencial 2 (detalhes do local); C1 – exemplo da classe Residencial 3 (imagem de satélite); C2 – exemplo da classe Residencial 3 (detalhes do local); D1 – exemplo da classe Comercial 1 (imagem de satélite); D2 – exemplo da classe Comercial 1 (detalhes do local); E1 – exemplo da classe Comercial 2 (imagem de satélite); E2 – exemplo da classe Comercial 2 (detalhes do local).

A classificação das USTs pode ser feita de duas formas, por meio automático ou manual. O método automático é baseado nas técnicas de sensoriamento remoto (processamento de imagem – interpretação automática pelo computador), enquanto que o método manual é baseado na interpretação visual de uma fotografia aérea ou imagem de satélite (BANZHAF; HÖFER, 2008; HEIDEN et al., 2012; HOFER, 2013). Apesar de que a interpretação visual consome um maior tempo, ainda continua sendo o método que oferece os resultados mais acurados. A interpretação visual gera como resultado uma acurácia maior que 90%, enquanto que a interpretação automática oferece uma acurácia entre 50% e 80% (WANG, Q. et al., 2008; HECHT et al., 2011).

Conseqüentemente, para a classificação das USTs neste estudo foi escolhido o método de interpretação visual. Para guiar o processo de classificação, foi utilizado a fotografia aérea do DF (ortofotos com 1 m de resolução) - (GDF, 2009) e o geodatabase do sistema de endereçamento do DF (SEDHAB, 2012). A base de endereçamento da Sedhab (2012) minimizou o tempo de classificação (minimizou o tempo para vetorização), pois já está delimitado na base o polígono referente a cada lote, quadra, conjunto, setor e região administrativa do DF. Além disso, a base de endereçamento apresenta informações gerais sobre o uso do solo, no qual está dividido entre as seguintes categorias: áreas residenciais, áreas públicas, áreas comerciais e áreas industriais. Essas informações facilitou o processo de classificação das USTs.

A chave de classificação das USTs definida nesta tese é diferenciada no primeiro nível como: áreas verdes, áreas residenciais, áreas públicas, áreas comerciais e industriais e áreas mistas. No seguinte nível, cada uma das classes do primeiro nível foi dividida com base na taxa de área verde, renda e tamanho do lote (Figura 70). Como complemento da descrição de cada classe de UST, o Apêndice F apresenta a imagem de satélite, a descrição e a imagem do local como exemplo de cada UST.

Figura 70 - Chave de classificação das USTs no DF.

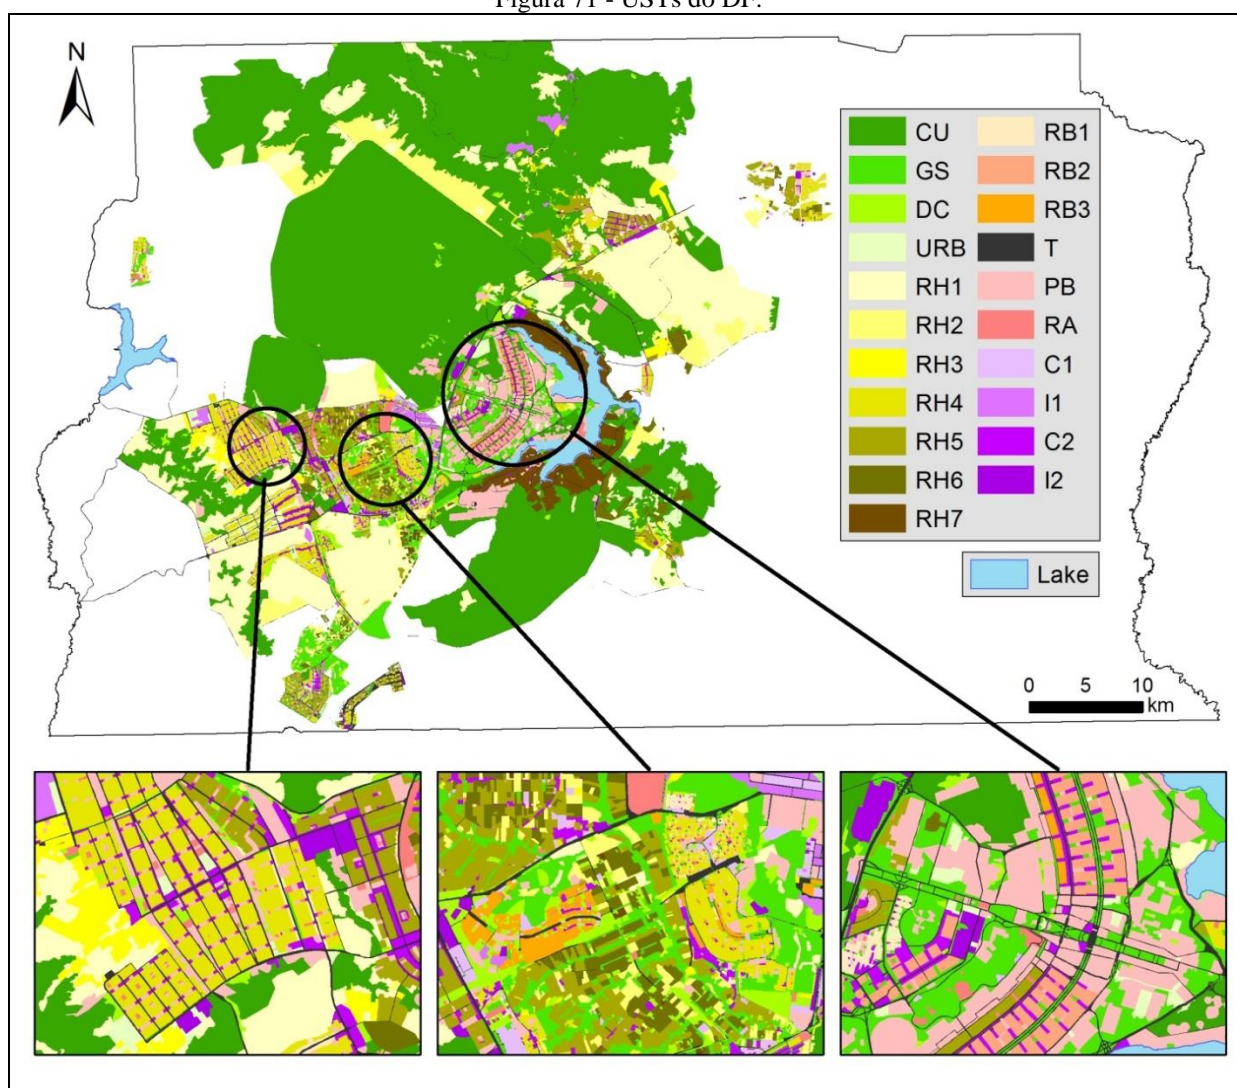
				Índice de área verde	Renda	Tamanho do lote	Descrição	
Área verde	Natural	Unidades de conservação (CU)		Alto – Muito alto	NA	NA	Áreas onde a ocupação urbana é limitada.	
		Espaços verdes (GS)		Médio	NA	NA	Área verde intra urbana.	
	Artificial	Área degradada (DC)		baixo–muito baixo	NA	NA	Área de solo exposto.	
		Urbanização (URB)		Baixo-Médio	NA	NA	Áreas designadas para novas áreas urbanas.	
Área residencial	Rural	Densidade muito baixa – RH 1		Médio-Alto	MB - B	> 2000 m <sup>2</sup>	Áreas rurais em inicial processo de legalização.	
		Densidade baixa – RH 2		Baixo-Médio	Média	> 2000 m <sup>2</sup>	Área rural em processo avançado de legalização.	
	Urbana	Casas	Marginal -RH 3		Muito baixo	Muito baixo	< 150 m <sup>2</sup>	Materiais simples de construção. Área muito pobre.
			Densidade alta – RH 4		Muito baixo	Baixo	150 – 250 m <sup>2</sup>	Área homogênea com alta densidade de urbanização.
			Densidade média -RH 5		Baixo	B - M	250 – 500 m <sup>2</sup>	Casas heterogêneas (algumas piscinas e jardins)
			Padrão alto -RH 6		Médio	M - A	500 – 1000 m <sup>2</sup>	Casas de padrão elevado, unifamiliar.
		Padrão muito alto -RH 7		Médio	A - MA	1000–2000 m <sup>2</sup>	Casa com padrão muito elevado. Manssões.	
		Apartamentos	Prédios baixos – RB 1		Baixo	Média	NA	Prédios de até 6 andares em áreas.
			Prédios baixos, nobre – RB 2		Alto-Muito Alto	M - A	NA	Prédios de até 6 andares em áreas. Área nobre.
	Prédios altos – RB 3		Baixo	Média	NA	Prédios de até 35 andares.		
Área pública	Transporte - T		Muito baixo	NA	NA	Vias de tráfego de veículos.		
	Prédios públicos - PB		Baixo	NA	Variável	Prédios públicos e centros de serviços.		
	Recreação - RA		Média	NA	NA	Infraestrutura de esporte.		
Área comercial e industrial	Comercial – C 1		Muito baixo	NA	Variável	Prédios comerciais com padrão médio a alto.		
	Industrial – I 1		Muito baixo	NA	> 2000m <sup>2</sup>	Área designada para indústria. Pouco comércio.		
Mista	Comercial / Residencial – C 2		Muito baixo	Variable	Variable	Área comercial com área residencial.		
	Industrial / Comercial / Residencial – I 2		Muito baixo	Variable	Variable	Áreas industriais com áreas comerciais e residencias.		

Fonte: Produção do próprio autor. Nota: Não se aplica (NA), Muito baixo – baixo (MB – B), Baixo – médio (B – M), Médio – Alto (M – A), Alto – Muito alto (A – MA).



A Figura 71 mostra as USTs do DF. Como complemento, é apresentado um zoom das três principais regiões do DF, em termos de densidade demográfica e presença de atividades. Neste estudo, as USTs foram classificadas somente para a área urbana do DF e algumas áreas de entorno da região urbanizada (por exemplo, o Parque Nacional de Brasília). As áreas brancas representadas na Figura 71 são consideradas em geral áreas verdes, áreas degradadas ou áreas rurais afastadas.

Figura 71 - USTs do DF.



Fonte: Produção do próprio autor. Nota: Lago (Lake).

Por fim, destaca-se que o autor de presente tese classificou as USTs referentes às seguintes regiões administrativas do DF: Brasília, Ceilândia, Lago Norte, Lago Sul, Recanto das Emas, Samambaia, São Sebastião, Sobradinho, Cruzeiro e Taguatinga. As demais regiões foram classificadas por outros alunos, nos quais integram o mesmo grupo de pesquisa do orientador da presente tese.

#### 8.2.4 TÉCNICAS EM SIG PARA CONSOLIDAÇÃO DOS DADOS

O procedimento adotado para a consolidação dos dados de saúde e UST foi o mesmo aplicado na análise do Capítulo 7 - Análise do decaimento do risco de doenças cardiorrespiratórias.

Portanto, primeiramente foram definidos 15 *buffers* ao redor de cada polígono que representa os dados de saúde (1.527 polígonos). Os tamanhos dos *buffers* variaram na escala logarítmica entre 50 m a 2.520 m. Em seguida, foram usadas técnicas em SIG para estimar a quantidade de cada UST (m<sup>2</sup>) dentro de cada *buffer*. A seguinte ordem de técnica/procedimento foi aplicada por meio do programa ArcGis: 1) *intersect*: identificação da geometria que intercepta duas feições geográficas (nesse caso, *buffers* e USTs); 2) *calculate geometry*: cálculo da área (m<sup>2</sup>) para cada polígono identificado por cada intersecção (nesse caso, área de cada USTs); e, 3) *summary statistics*: soma da área de todos os polígonos identificados pelo *intersect* (esse processo foi feito usando o tamanho do *buffer* como filtro).

#### 8.2.5 ANÁLISE ESTATÍSTICA

O método quantile regression foi utilizado na análise estatística. Os principais conceitos do método quantile regression foi apresentado no Capítulo 7 - Análise do decaimento do risco de doenças cardiorrespiratórias.

Na análise deste capítulo a variável resposta foi a taxa de internação hospitalar por doenças cardiorrespiratórias (número de internações por população) em cada um dos 1.527 polígonos de endereço. O risco de doenças cardiorrespiratórias foi calculado considerando o efeito individual de cada UST, usando a renda como uma co-variável.

O cálculo do risco foi realizado em duas etapas. Na primeira, foi calculado o risco de cada *buffer* (Equação 28 e Equação 29). Em seguida, foi considerada a média do risco entre os *buffers*.

$$\text{Risco}_{kij} = \beta_{kij} \times \text{IQR}_{kj}$$

Onde  $K$  é a variável preditora (cada UST);  $i$  representa o quantil  $i^{th}$ , no qual foi utilizado 0,05; 0,10; 0,25; 0,75; 0,90 e 0,95;  $j$  é o tamanho do buffer; e  $IQR$  é a variação do interquartil, conforme apresentado pela Equação 29.

$$IQR_{kj} = 75^{th}Percentile_{k,j} - 25^{th}Percentile_{k,j}$$

Equação 29

Destaca-se que o cálculo da média do risco entre os *buffers* foi feito somente para os *buffers* que apresentaram risco significativo decorrente da Equação 28 ( $p\text{-value} \leq 0.05$  e 95% do intervalo de confiança sem o valor zero).

Por fim, destaca-se que os resultados foram expressos pelo coeficiente do modelo, no qual mostra o risco de internações e os respectivos intervalos de 95% de confiança (95% IC), por conta do interquartil nas quantidades de cada UST.

A análise estatística foi realizada no programa R. O Apêndice E.2 apresenta o modelo do script utilizado na análise.

### 8.2.6 ANÁLISE DE SENSIBILIDADE

Análise de sensibilidade foi realizada para verificação da robustez dos resultados primários. Considera-se aqui como resultados primários os decorrentes da análise estatística apresentada pelo item 8.2.5. Portanto, os polígonos de endereços, nos quais contém as informações sobre o número de pacientes, foram divididos com base na variação da quantidade de pessoas e da renda (valores altos e baixos) dentro dos respectivos polígonos.

Para os valores baixos foram consideradas as observações abaixo do quantil 0,25; enquanto que para os valores altos foram consideradas as observações maiores que o quantil 0,75. Como resultado, foram gerados quatro subgrupos: população alta, população baixa, renda alta e renda baixa. Para cada subgrupo foi encontrado um total de 382 blocos de endereços (polígonos).

Por fim, foi aplicado o método estatístico descrito no item 8.2.5 para cada um dos quatro subgrupos. A análise de sensibilidade foi realizada somente para as USTs que apresentaram risco significativo nos resultados primários.

## 8.3 RESULTADOS

### 8.3.1 ANÁLISE DESCRITIVA


Foram analisadas 7.269 internações de 1.527 blocos de endereços. O resultado dos parâmetros estatísticos descritivos são os mesmos apresentados no Capítulo 7 - item 7.3.1. Mas para facilitar a leitura do presente capítulo, será apresentado novamente pela Tabela 18 o resumo descritivo dos dados de saúde.

Tabela 18 - Resumo de estatística descritiva dos dados de saúde - Análise entre saúde e UST.

Parâmetros estatísticos	Número absoluto das internações	Taxa (Internação por população)
Mínimo	1	0,00007
Percentil 5 <sup>th</sup>	1	0,0013
Percentil 10 <sup>th</sup>	1	0,033
Percentil 25 <sup>th</sup>	1	0,071
Média	4,72	0,017
Desvio padrão	21,58	0,928
Percentil 75 <sup>th</sup>	2	0,042
Percentil 90 <sup>th</sup>	4	0,131
Percentil 95 <sup>th</sup>	9	0,274
Máximo	357	20,68


Analisando a quantidade de cada UST (em termos de IQR) em cada tamanho de buffer, observou-se que para o primeiro *buffer* (50 m) somente área residencial de densidade alta (RH4), transporte (T), prédios públicos (PB) e comercial/residencial área (C2) estão presentes. Isso significa que 78% dos blocos de endereços estão localizados (baseado no *buffer* de 50 m) em áreas que contém RH4, 48% em áreas que contém T, 33% em áreas que contém PB, e 37% em áreas que contém C2. A maior parte das USTs estão localizadas entre os *buffers* de 500 m e 1.350 m. Por outro lado, área residencial de padrão muito alto (RH7) e área residencial nobre de prédios baixos (RB2) não estão presente em nenhum dos *buffers*. A Figura 72 e a Figura 73 mostram a quantidade de cada UST em termos de IQR entre os *buffers*. Como complemento, o Quadro 8 mostra as USTs que apresentam IQR igual a zero.

Figura 72 – Quantidade de USTs em termos de IQR (m<sup>2</sup>) ao longo dos *buffers* – áreas residenciais e áreas verdes.



Fonte: Produção do próprio autor.

Figura 73 - Quantidade de USTs em termos de IQR (m<sup>2</sup>) ao longo dos *buffers* – áreas públicas e áreas comerciais, industriais e mistas.



Fonte: Produção do próprio autor.

### 8.3.2 UST E RISCO DE DOENÇAS CARDIORRESPIRATÓRIAS

As variáveis unidades de conservação (CU), espaços verdes (GS), áreas degradadas (DC), área residencial de densidade baixa (RH2), área residencial de densidade média (RH5), transporte (T), área comercial (C1), área industrial (I1) e área mista entre indústrias, comércio e residências (I2) apresentaram valor zero no intervalo de confiança para todos os *buffers*, indicando que não há associação significativa com a ocorrência de internações. Entre as USTs que indicaram efeitos na ocorrência de internações, urbanização (URB), área residencial de densidade muito baixa (RH1), área residencial marginal (RH3), área residencial de densidade alta (RH4), área residencial de prédios altos (RB3) e área de recreação (RA) mostraram efeito negativo, o que significa que essas USTs reduzem o risco de internações hospitalares. Por outro lado, as variáveis área residencial de padrão alto (RH6), área residencial de prédios baixos (RB1), prédios públicos (PB) e área mista – comércio/residências (C2) apresentaram efeito positivo no risco de ocorrência de internações (Quadro 8).

Quadro 8 - Risco significativo diferente de zero em cada *buffer* (95% IC não contém o valor zero).

Categoria	Variáveis	Buffer														
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Áreas verdes	CU															
	GS															
	DC															
	URB		-	-	-	-	-	-	-	-	-	-	-	-	-	-
Áreas residenciais	RH1															
	RH2															
	RH3															
	RH4															
	RH5															
	RH6															
	RH7															
	RB1															
	RB2															
RB3																
Áreas públicas	T															
	PB															
	RA															
Área comercial e industrial	C1															
	I1															
Mista	C2															
	I2															

Nota: IQR igual a zero (cor laranja); 95% IC não contém valor zero (cor verde); 95% IC contém valor zero (cor vermelha); risco negativo (-); risco positivo (+); *Buffer* 50 m (1); *Buffer* 500 m (2); *Buffer* 870 m (3); *Buffer* 1.140 m (4); *Buffer* 1.350 m (5); *Buffer* 1.540 m (6); *Buffer* 1.700 m (7); *Buffer* 1.840 m (8); *Buffer* 1.960 m (9); *Buffer* 2.080 m (10); *Buffer* 2.180 m (11); *Buffer* 2.280 m (12); *Buffer* 2.370 m (13); *Buffer* 2.450 m (14); *Buffer* 2.520 m (15).

A Figura 74 mostra que há risco decorrente de 10 USTs (RB1, RB3, RH1, RH3, RH4, RH6, URB, PB, RA e C2), pois apresentaram 95% IC diferente de zero na análise primária. Além disso, a Figura 74 mostra que há presença de risco para a análise de sensibilidade (população e renda alta/baixa).

Na análise primária foi encontrado efeito significativo somente para o quantil 0,90 e 0,95. A diferença dos resultados entre esses quantis é mínima. Portanto, os resultados apresentados neste capítulo para a análise primária serão somente para o quantil 0,95. Para a análise de sensibilidade, encontrou-se risco para os quantis 0,25; 0,75; 0,90 ou 0,95. A Figura 74 apresenta os quantis para cada UST e para o tipo da análise de sensibilidade.


Os resultados mostraram que áreas residências com prédios baixos (RB1) provocam o maior risco positivo (risco = 0,07; 95% IC: 0,12; 0,03), seguido de prédios públicos - PB (risco = 0,05; 95% IC: 0,11; 0,02) e comércio/residências - C2 (risco = 0,05; 95% IC: 0,08; 0,02). As áreas residenciais de densidade alta (RH4) apresentaram o menor risco negativo (risco = -0,17; 95% IC: -0,14; -0,2), (Figura 74).

Na análise de sensibilidade foi encontrado variações elevadas no risco decorrente da presença de área residencial de densidade muito baixa (RH1), área residencial de densidade alta (RH4), prédios públicos (PB), áreas de recreação (RA) e área mista entre comércio e residência (C2). Para o grupo de população alta – RH1, o risco se tornou positivo (risco = 0,03; 95% IC: 0,06; 0,005), enquanto que para população baixa – RH1, o risco decresceu 700%, em comparação com a análise primária. Resultados similares (alto decréscimo do risco negativo) foram encontrados para população baixa – RH4 (risco = -1,02; 95% IC: -0,78; -1,14), no qual teve um decréscimo de 500% em comparação com a análise primária (Figura 74).

Na análise de sensibilidade foi encontrado um aumento significativo no risco para renda baixa – PB, RA e C2. Considerando PB, a análise primária estimou um risco de 0,05 (95% IC: 0,11; 0,014), e para renda baixa o risco foi de 0,50 (95% IC: 0,71; 0,06). Para RA, o risco se tornou positivo para a análise de sensibilidade com renda baixa (risco = 0,31; 95% IC: 1,26; 0,03). E para renda baixa – C2, foi encontrado um risco de 0,11 (95% IC: 1,42; 0,02), enquanto que para a análise primária o risco foi de 0,05 (95% IC: 0,08; 0,023), (Figura 74).



Figura 74 - Risco (taxa de internações hospitalares).



Fonte: Produção do próprio autor. Notas: risco da análise primária (a); risco da análise de sensibilidade – renda alta (b); risco da análise de sensibilidade – renda baixa (c); risco da análise de sensibilidade – população alta (d); risco da análise de sensibilidade – população baixa (e); 95% IC contém valor zero (losango amarelo); IQR igual a zero (losango verde); quantil 0,25 (quadrado verde); quantil 0,75 (quadrado alaranjado); quantil 0,90 (quadrado azul); quantil 0,95 (quadrado roxo).

## 8.4 DISCUSSÃO

Com base no *buffer* de 50 m, 78% dos blocos de endereços estão localizados em áreas residenciais de densidade alta (RH4). No entanto, não foi encontrado efeito danoso de RH4 na saúde humana. Os resultados mostraram que RH4 está associado com um risco negativo de internações (Figura 74). Uma possível explicação desse risco negativo é que a UST RH4 está localizada distante dos principais centros de atividades. É assumido que os centros de atividades concentram uma circulação alta de veículos, e conseqüentemente, uma maior emissão de poluentes atmosféricos (importante causa de doenças cardiorrespiratórias).

Conforme apresentado no Apêndice F, RH4 é também caracterizada por uma elevada densidade de urbanização, o que é esperado uma quantidade alta de ocorrência de doenças. Portanto, na análise de sensibilidade para RH4 encontrou-se uma diferença significativa entre a análise para população alta e população baixa. Para população baixa, o risco negativo aumentou mais de 500% (Figura 74). Pesquisas anteriores sugerem que há uma ligação entre poluição do ar e número de pessoas vivendo em uma cidade (COOPER et al., 2012; HIXSON et al., 2012; LAMSAL et al., 2013). Por exemplo, Cooper et al. (2012) mostraram que a maior parte da concentração de NO<sub>2</sub> nos EUA, Europa, China e Índia é explicada pela densidade populacional. Na análise do presente capítulo, a RH4 se apresentou como sensível à densidade populacional.

Era esperado encontrar um risco positivo de internações decorrentes da presença da UST diretamente ligada ao transporte (T) e um risco negativo da UST diretamente ligada às áreas verdes (unidades de conservação - CU e espaços verdes - GS). No entanto, os resultados dessas USTs não foram significantes. Possivelmente, o tráfego de veículos e as áreas verdes estão sendo explicados por outras USTs. Lembrando-se que a taxa de área verde, a conectividade e a densidade são parâmetros de classificação de todas as USTs.

Foi esperado também encontrar um elevado risco decorrente da presença de indústrias (I1) e áreas mistas entre indústrias, comércio e residências (I2). No entanto, é importante destacar que no DF não há alta concentração de indústrias. A maior parte das áreas I1 e I2 no DF apresentam uma baixa densidade de indústrias, quando comparado com outras cidades que são polos industriais, como São Paulo.

As áreas residenciais com prédios baixos (RB1) e as áreas residenciais com padrão alto (RH6) estão associadas com um aumento significativo na ocorrência de internações (Figura 74). RB1 inclui prédios antigos próximos às avenidas com tráfego intenso de veículos. Outros estudos têm mostrado que a idade das estruturas dos prédios é um importante fator que determina a

qualidade do ar interno (*indoor air quality*). Nos prédios antigos a penetração da poluição externa é geralmente maior devido à estrutura das janelas, portas e sistemas de ventilação (JUNG et al., 2011; MACNEILL et al., 2012; MOLLE et al., 2013; LEE et al., 2014). Quanto à UST RH6, é considerada uma área com alta renda e tráfego de veículos. Dargay et al. (2007) relatam que há uma relação positiva entre renda e densidade de veículos. Além disso, o Departamento de Planejamento Urbano do DF (CODEPLAN, 2013) mostra que as regiões com alta renda no DF possuem mais veículos. Por exemplo, 97,4% dos domicílios da região administrativa do Lago Norte possuem automóveis. O Lago Norte é a região administrativa do DF com o maior número, seguido do Lago Sul (97% dos domicílios com automóveis), Sudoeste (91,9%), Brasília (82,9%), Park Way (82,5%). O Lago Norte também é a região administrativa que possui o maior número de automóveis por domicílio. A estimativa é de 46,5% dos domicílios no Lago Norte possuem três ou mais automóveis (CODEPLAN, 2013). Por fim, destaca-se que o Lago Norte foi a região administrativa do DF que concentrou a maior parte das RH6.

Por outro lado, as áreas residenciais marginais (RH3) são regiões no DF com renda baixa. A maior parte das casas são construídas com material de baixa qualidade. Além disso, em geral as regiões não apresentam sistema de esgotamento sanitário, água tratada e coleta de lixo (Apêndice F). Considera-se como a principal fonte de poluição do ar para RH3 a poeira, que é decorrente do solo exposto. A poeira está diretamente ligada com a ocorrência de doenças cardiorrespiratórias (CHAN; YAO, 2008; LEE, H. et al., 2013). No entanto, a presença de RH3 apresentou risco negativo (Figura 74). Uma possível explicação é baseada em uma hipótese na área de higiene ambiental. A hipótese é que pessoas que vivem em ambientes sujos (baixa renda) possuem um sistema imunológico melhor. Portanto, especificamente para a análise do presente capítulo, provavelmente as pessoas de RH3 possuem um melhor sistema imunológico, apresentando menos doenças cardiorrespiratórias (OKADA et al., 2010; OLSZAK et al., 2012). Vale destacar também, que há a possibilidade de o resultado da UST RH3 estar associado com o acesso aos sistemas de saúde.

As áreas residenciais com prédios altos (RB3) foram associadas com decréscimo no risco de internações (Figura 74). Sugere-se que a altura dos prédios tem uma forte associação com o risco de internações hospitalares. Destaca-se que a principal característica de RB3 são os prédios altos (a maioria até 35 andares). Estudos anteriores mostram que o nível de poluição *indoor* e *outdoor* varia conforme o andar do prédio. Por exemplo, em Nova Iorque a concentração *indoor* e *outdoor* de hidrocarbonetos policíclicos aromáticos e Black Carbon (BC)

diminuem com o aumento dos andares no edifício. A concentração desses poluentes entre o segundo e o sexto andar foi 1,5 – 2 vezes menor que o primeiro andar. Além disso, a concentração entre o sexto e o trigésimo segundo é significativamente menor que em andares inferiores (JUNG et al., 2011). Estudos em outras cidades também tem mostrado a variação da distribuição vertical da exposição humana, tais como Tianjin, China (XIAO et al., 2012); Beijing, China (MA et al., 2012), e; as áreas suburbanas de Taiwan (CHEN et al., 2002).

Os resultados mostraram um risco negativo das interações decorrente da presença de área residencial com densidade muito baixa (RH1). Além disso, o risco decorrente da presença de RH1 é mais sensível à densidade populacional. Foi observado que para o grupo de população alta o risco se tornou positivo, enquanto que para o grupo de população baixa o risco foi negativo (Figura 74). RH1 é caracterizada por áreas rurais com baixa densidade populacional. Outros estudos mostraram que as áreas rurais apresentam um nível menor de exposição humana em comparação com as áreas urbanas. Um nível elevado de urbanização corresponde a uma concentração elevada de poluição atmosférica (GARCIA et al., 2010; CHENG et al., 2013; CHOWDHURY et al., 2013; WEBER et al., 2014b). Especificamente para a relação entre densidade populacional e áreas rurais, Xia et al. (2014) mostraram que em Shanghai, China, as concentrações de SO<sub>2</sub>, NO<sub>x</sub> e PTS foram menores nas áreas rurais, quando comparado com as áreas urbanas. Os autores ainda observaram que quanto mais as áreas rurais se tornavam mais povoadas, a qualidade do ar diminuía.

As áreas de recreação (RA) foram associadas com decréscimo no risco de interações em todas as análises, com exceção para a análise de sensibilidade de renda baixa (Figura 74). Estudos anteriores divulgaram que espaços de recreação são associados com os benefícios à saúde humana (BERRIGAN; MCKINNON, 2008; NOWAK; HEISLER, 2010; VILLANUEVA et al., 2013; AMERICAN HEART ASSOCIATION, 2014). Além disso, estudos nos EUA têm mostrado que as condições socioeconômicas estão relacionadas com as atividades físicas na comunidade. As regiões com menores rendas são associadas com o decréscimo no número de espaços de recreação (POWELL et al., 2004; MENDOZA et al., 2010).

Foi encontrado aumento no risco decorrente das áreas de urbanização (URB), de prédios públicos (PB) e das áreas mistas entre comércios e residências (C2) - (Figura 74). Conforme apresentado no Apêndice F, URB é uma área que está em processo de construção, na qual pode resultar na suspensão de partículas (poeira) e emissões de caminhões e equipamentos de construção. Outros estudos mostraram resultados similares nas cidades dos EUA (LADEN et al., 2000; ZANOBETTI; SCHWARTZ, 2009), em que materiais em suspensão decorrente de

áreas em urbanização foram associados com efeito na saúde humana. Quanto às áreas PB e C2, destaca-se que são áreas onde concentram atividades do tipo, compras, negócios, etc., na qual resultam em elevado tráfego de veículos e conseqüentemente uma alta concentração de poluentes do ar. Pesquisas anteriores mostram que áreas que concentram esses tipos de atividades têm associação com efeitos adversos à saúde humana (JAMES et al., 2014).

O estudo apresentado por este capítulo tem as mesmas limitações das análises descritas pelos Capítulos 4, 5 e 7. Ou seja, os dados de saúde são somente uma amostra dos dados que estão disponíveis no site do Datasus (DATASUS, 2015). Os dados utilizados neste capítulo são referentes a 7.269 internações, enquanto que os dados do site do Datasus são de 399.564 internações. E a outra limitação é quanto ao processo adotado para a normalização dos dados (dados de saúde por população). Não é uma regra de que em todos os casos haverá uma relação linear entre a população residente e a respectiva área ocupada.

Diante do exposto, os resultados apresentados por este capítulo sugerem que o uso do método convencional de classificação do uso do solo como forma de investigar a relação entre ocupação do solo e saúde humana pode omitir importantes informações sobre a exposição humana. O método UST pode ser uma abordagem complementar aos estudos epidemiológicos, contribuindo assim para o desenvolvimento de políticas em planejamento urbano, meio ambiente e saúde.

## Conclusão

---

A hipótese testada nesta tese é válida, ou seja, a exposição da população do DF às fontes de emissões de poluentes do ar pode ser estimada por meio de classificação e mensuração do uso e ocupação do solo.

Os resultados deste trabalho acrescentam com ineditismo e inovação às pesquisas que já investigaram o emprego de modelos de uso e ocupação do solo para mensuração da exposição humana às fontes de poluição. A principal contribuição é quanto à forma de classificar e mensurar o uso e ocupação do solo. Esta tese mostrou que a exposição humana varia em função da distância às fontes de poluição (Capítulos 4, 6, 7 e 8), dos tipos de ambientes construídos (Capítulo 7) e dos tipos de estruturas urbanas (Capítulo 8).

O Quadro 9 apresenta uma matriz com os principais pontos de comparação dos resultados entre cada um dos sete objetivos específicos (nos quais foram separados entre os capítulos 3 a 8).

Este trabalho também contribui de forma prática e aplicada como ferramenta de apoio para a implantação de políticas que visam o planejamento e gestão da ocupação urbana. Conforme a hipótese corroborada nesta tese, o principal benefício das políticas orientadas pelos resultados deste estudo seria o controle das fontes de emissão, e conseqüentemente a melhoria da qualidade de vida da população. Especificamente no DF, esta pesquisa pode contribuir diretamente para minimizar os desafios enfrentados pela região, que são, por exemplo: as estações de monitoramento da qualidade do ar no DF ainda estão no processo inicial de consolidação, o que a torna precária e de pouca representatividade; o DF apresentou um crescimento da área urbana em torno de 30% nos últimos 15 anos; o DF tem uma relação de praticamente 0,6 veículos automotores terrestres por habitante; e um total de 400 mil pessoas foram internadas por doenças cardiorrespiratórias nos últimos cinco anos e 15 mil vieram a óbito.

Em especial quanto à rede de monitoramento da qualidade do ar no DF, destaca-se que o presente trabalho não utilizou os dados decorrentes dessa rede devido aos problemas de qualidade dos dados. Conforme detalhado no Capítulo 3 e 4, a rede do DF possui limitações quanto à operação e quanto à representatividade espacial e temporal dos dados.

Dessa forma, as ocorrências de internações por doenças cardiorrespiratórias foram consideradas como proxies indicadoras da qualidade do ar. Portanto, deve-se considerar como principal limitação deste estudo a possibilidade de ocorrência do falso positivo ou do falso negativo em relação aos casos de internações por doenças do sistema cardiorrespiratório. Essa é uma limitação recorrente em muitos estudos de epidemiologia ambiental (BHATNAGAR, 2006; JOHNSTON et al., 2014; ZOU et al., 2014; BIND et al., 2015; CBHA, 2015; CHUM; O'CAMPO, 2015; NORDIO et al., 2015). E também, destaca-se que há limitação relacionada ao viés espacial da distribuição dos dados de saúde, pois os dados utilizados são exclusivamente dos hospitais públicos do DF.

A técnica adotada para a estimação da população (usada para a taxa de incidência) e a amostra reduzida dos dados de saúde (quando se compara com os dados disponibilizados no site do Datasus) são outras importantes limitações deste trabalho. Quanto à estimação da população, sugere-se para os próximos estudos o uso do método dasimétrico. E em relação à amostra reduzida dos dados de saúde, sugere-se para as próximas pesquisas a atualização (acréscimo de mais observações na amostra) do banco de dados de saúde construído nesta pesquisa. Essa atualização poderia permitir uma análise temporal, na qual não foi possível nesta tese devido ao tamanho da amostra dos dados de saúde.

Os principais desafios operacionais para a realização deste trabalho foram quanto à aquisição dos dados de veículos e saúde. A descrição da aquisição e operação desses dados foram apresentadas nos Capítulos 3 e 4, respectivamente. O desafio consiste na ausência de um sistema que possibilita a consulta de informações espaciais sobre a circulação de veículos e a ocorrência de doenças na população. Nesse sentido, a presente tese propôs um sistema de consolidação dos dados de saúde e transporte (Capítulos 3 e 4) que podem apoiar futuros estudos acadêmicos e até mesmo a gestão realizada pelas agências governamentais do DF. Vale destacar que o sistema proposto por esta tese é inédito e inovador para a realidade dos órgãos governamentais do DF.

Com intuito de facilitar o acesso aos resultados desta tese pela comunidade científica; pelas agências governamentais; e pela população em geral, foi utilizada a ferramenta Worldmap. Assim, os resultados com formatos espaciais do presente trabalho está de livre acesso no seguinte endereço eletrônico: <https://worldmap.harvard.edu/maps/distritofederal>.

Por fim, o Quadro 10 apresenta uma síntese dos principais resultados (no contexto do ineditismo e da inovação); limitações; e sugestões de novos estudos, conforme cada objetivo específico traçado (separados por capítulos).

Quadro 9 - Matriz com os principais pontos de comparação dos resultados entre cada um dos sete objetivos específicos (separados entre os Capítulos 3 e 8).

	Capítulo 3: Emissões das vias	Capítulo 4: Saúde e emissões das vias	Capítulo 5: Padrões de distribuição	Capítulo 6: Áreas prioritárias	Capítulo 7: Saúde e uso do solo	Capítulo 8: Saúde e UST
Capítulo 3: Emissões das vias	-	A	B	C	D	E
Capítulo 4: Saúde e emissões das vias	*	-	F	G	H	E
Capítulo 5: Padrões de distribuição	*	*	-	I	J	K
Capítulo 6: Áreas prioritárias	*	*	*	-	L	M
Capítulo 7: Saúde e uso do solo	*	*	*	*	-	N
Capítulo 8: Saúde e UST	*	*	*	*	*	-

Notas:

(-) Comparação entre os mesmos elementos na matriz;

(\*) Inverso da matriz;

(A) A estimação das emissões das vias de tráfego é associada com a ocorrência de internações. No entanto, o método para criação da superfície de emissões deve ser aprimorado;

(B) As emissões das vias de tráfego pode ser o principal fator responsável pela a identificação de *cluster* dos pacientes de até 5 anos e dos pacientes de todas as idades;

(C) As vias de tráfego apresentaram um peso significativo no modelo para estimação das áreas prioritárias. Em média, as vias com as maiores taxas de emissões foram consideradas como prioridade alta;

(D) O número de veículos foi associado significativamente com a avaliação do decaimento do risco. Por outro lado, as emissões estimadas pelo inventário não apresentaram associações significativas. Provavelmente, o método de interpolação utilizado para criação da superfície de emissões não foi eficiente;

(E) Era esperada uma associação entre a UST de transporte e a ocorrência de internações, mas a análise do Capítulo 8 não encontrou associação significativa. Sugere-se uma revisão do tipo de mensuramento/identificação da UST transporte, pois possivelmente, o método utilizado para classificar as UST transporte não foi preciso e acurado;

(F) Os pacientes de até 5 anos e os acima de 59 anos se destacaram por apresentarem associações com as emissões das vias e por apresentarem uma distribuição espacial diferente (o número de internações não é totalmente homogêneo no DF); Diferente dos pacientes entre 6 e 17 anos, nos quais não apresentaram associações significantes com as emissões das vias e apresentam distribuição espacial homogênea;

(G) As vias de tráfego e a localização do endereço dos pacientes apresentam associação entre si e também um peso significativo no modelo para estimação das áreas prioritárias;



**(H)** O Capítulo 7 não avaliou a relação com base na faixa etária, pois diminuiria o tamanho da amostra, o que é inviável para o método *quantile regression*. Portanto, a comparação entre os Capítulos 4 e 7 será somente com base no grupo etário de todas as idades. A associação entre as emissões inventariadas e as internações foi significativa com o modelo estatístico de regressão linear dos mínimos quadrados (Capítulo 4). Já no modelo *quantile regression* (Capítulo 7) não foi encontrada significância em todos os *buffers* e para todos os poluentes. Provavelmente, a diferença da consolidação dos dados de saúde influenciou na significância dos resultados. Lembra-se que para a análise do Capítulo 7 a consolidação dos dados de saúde foi diferente, pois não foi considerada a agregação do endereçamento;

**(I)** O grupo etário de até 5 anos e o grupo acima de 59 anos destacaram por apresentarem padrões espaciais diferentes (*cluster*, heterogeneidade conforme a distância – Capítulo 5) e por terem apresentados os maiores pesos no modelo de determinação das áreas prioritárias para o monitoramento (Capítulo 6);

**(J)** O Capítulo 7 não avaliou a relação com base na faixa etária, pois diminuiria o tamanho da amostra, o que é inviável para o método *quantile regression*. Portanto, a comparação entre os Capítulos 5 e 7 será somente com base no grupo etário de todas as idades. Até 2.500 m houve presença de *cluster* significativa, o que sugere a existência de um fator comum responsável pela ocorrência do número de pacientes até essa distância (Capítulo 5). O maior *buffer* utilizado para as análises do Capítulo 7 foi de 2.520 m, no qual seis variáveis apresentaram associação com o número de pacientes nessa distância. As variáveis foram: rodovias, motocicletas, áreas comerciais, solo exposto, áreas verdes intraurbana e renda. Provavelmente essas variáveis estão associadas com a ocorrência de *cluster* identificadas pelo Capítulo 5;

**(K)** O Capítulo 8 não avaliou a relação com base na faixa etária, pois diminuiria o tamanho da amostra, o que é inviável para o método *quantile regression*. Portanto, a comparação entre os Capítulos 5 e 8 será somente com base no grupo etário de todas as idades. Até 2.500 m houve presença de *cluster* significativa, o que sugere a existência de um fator comum responsável pela ocorrência do número de pacientes até essa distância (Capítulo 5). O maior *buffer* utilizado para as análises do Capítulo 8 foi de 2.520 m, no qual nove USTs (URB, RH1, RH3, RH4, RH6, RB1, RB3, PB, RA e C2) apresentaram associação com o número de pacientes nessa distância. Provavelmente essas USTs estão associadas com a ocorrência de *cluster* identificadas pelo Capítulo 5;

**(L)** As áreas identificadas no DF com prioridade alta e altíssima para o monitoramento da exposição (Capítulo 6) são semelhantes as áreas identificadas com elevado risco de ocorrência de pacientes, sobretudo quando foi considerada a variável rodovia (Capítulo 7);

**(M)** As áreas com densidade elevada de ambientes construídos e com densidade populacional alta foram determinantes para estabelecerem um nível de prioridade alto a muito alto para o monitoramento da exposição (Capítulo 6). As análises do Capítulo 8 também identificaram que a densidade das estruturas urbanas e a densidade da população estão associadas com a ocorrência de doenças cardiorrespiratórias;

**(N)** As análises dos Capítulos 7 e 8 identificaram que a variação do risco está associada à variação do *buffer*. Era esperada uma associação entre as USTs de transporte e áreas verdes com a ocorrência de internações, mas a análise do Capítulo 8 não encontrou associação significativa. Sugere-se uma revisão do tipo de mensuramento/identificação dessas USTs, pois possivelmente, o método utilizado para classificar não foi preciso e acurado. Já a análise do Capítulo 7 apresentou associação significativa entre internações com as áreas verdes intraurbana (associação negativa) e com as áreas relacionadas ao transporte (sobretudo, rodovias). Por fim, destaca-se que as áreas de atividades, como as áreas comerciais e públicas, apresentaram associações significativas em ambas as análises (Capítulos 7 e 8).

Quadro 10 – Síntese dos resultados de todas as análises realizadas, considerando o ineditismo/ inovação, limitações e sugestões de novos estudos.

(Continua)

Capítulo	Destaques para o ineditismo / inovação	Principais limitações	Principais sugestões de novos estudos
Capítulo 3 – Predição das emissões das vias de tráfego	<ul style="list-style-type: none"> <li>- Banco de dados geográficos sobre a circulação de veículos no DF;</li> <li>- Alternativa barata e simples para regiões que não monitoram a exposição humana, ou que possuem um monitoramento deficiente.</li> </ul>	<ul style="list-style-type: none"> <li>- Diferença entre os veículos novos e os velhos;</li> <li>- Emissões durante o período do dia;</li> <li>- Emissões de partida dos motores;</li> <li>- Validação dos resultados com as estações de monitoramento.</li> </ul>	<ul style="list-style-type: none"> <li>- Incluir mais vias no modelo;</li> <li>- Incluir uma análise temporal.</li> </ul>
Capítulo 4 – Construção de um banco de dados geográficos para os dados de saúde e avaliação da relação entre saúde e emissões decorrentes das vias de tráfego	<ul style="list-style-type: none"> <li>- Banco de dados geográficos de saúde para o DF;</li> <li>- Alternativa barata e simples para regiões que não monitoram a exposição humana, ou que possuem um monitoramento deficiente.</li> </ul>	<ul style="list-style-type: none"> <li>- Técnica adotada para a estimação da população;</li> <li>- Amostra reduzida dos dados de saúde quando se compara com os dados disponibilizados no site do Datasus.</li> </ul>	<ul style="list-style-type: none"> <li>- Uso da técnica de modelos dasimétricos para estimação da população;</li> <li>- Uso de outros métodos para estimar uma superfície de poluição a partir dos dados de inventário;</li> <li>- Incluir uma análise temporal.</li> </ul>
Capítulo 5 - Avaliação dos padrões de distribuição espacial da ocorrência de doenças cardiorrespiratórias	<ul style="list-style-type: none"> <li>- Aplicação de discussão de quatro técnicas em geoestatística para avaliação de dados de saúde.</li> </ul>	<ul style="list-style-type: none"> <li>- Técnica adotada para a estimação da população;</li> <li>- O uso dos centroides para cada polígono pode influenciar na identificação de alguns padrões.</li> </ul>	<ul style="list-style-type: none"> <li>- Uso da técnica de modelos dasimétricos para estimação da população;</li> <li>- Incluir uma análise temporal.</li> </ul>

Capítulo	Destaques para o ineditismo / inovação	Principais limitações	Principais sugestões de novos estudos
Capítulo 6 - Identificação das áreas prioritárias para mensuração da exposição humana às fontes de poluição atmosférica	<ul style="list-style-type: none"> <li>- Determinação dos locais prioritários para monitoramento da exposição humana com base em critérios modelados de forma hierárquica, com considerações da consistência matemática e conforme as características específicas da área de estudo (DF).</li> </ul>	<ul style="list-style-type: none"> <li>- Acurácia e precisão para representação de alguns critérios, tais como: presença humana, sobretudo no período diurno;</li> <li>- As áreas comerciais, industriais e de serviços públicos não foram consideradas no critério estrutura das edificações.</li> </ul>	<ul style="list-style-type: none"> <li>- Uso de critérios mais precisos e acurados que representam a presença humana no período diurno com base na faixa etária (principalmente para as pessoas entre 18 e 59 anos).</li> </ul>
Capítulo 7 - Estimação do risco da ocorrência de doenças cardiorrespiratórias com base no uso e ocupação do solo	<ul style="list-style-type: none"> <li>- Análise do risco por <i>buffer</i>;</li> <li>- Análise do risco considerando um número maior de variáveis relacionadas aos ambientes construídos (<i>built Environment</i>).</li> </ul>	<ul style="list-style-type: none"> <li>- Técnica adotada para a estimação da população;</li> <li>- Amostra reduzida dos dados de saúde quando se compara com os dados disponibilizados no site do Datasus.</li> </ul>	<ul style="list-style-type: none"> <li>- Uso da técnica de modelos dasimétricos para estimação da população;</li> <li>- Incluir uma análise temporal.</li> </ul>
Capítulo 8 - Avaliação da relação entre os tipos de estruturas urbanas e o risco de doenças cardiorrespiratórias	<ul style="list-style-type: none"> <li>- O uso de um novo conceito sobre uso do solo (tipos de estruturas urbanas) como forma de avaliar a saúde humana.</li> </ul>	<ul style="list-style-type: none"> <li>- Técnica adotada para a estimação da população;</li> <li>- Amostra reduzida dos dados de saúde quando se compara com os dados disponibilizados no site do Datasus.</li> </ul>	<ul style="list-style-type: none"> <li>- Uso da técnica de modelos dasimétricos para estimação da população;</li> <li>- Incluir uma análise temporal;</li> <li>- Revisar o tipo de mensuramento e identificação da UST relacionada diretamente ao transporte (T).</li> </ul>

(Conclusão)

## Referências Bibliográficas

---

- ABREU, L. M.; GRANEMANN, S. R.; GARTNER, I. R.; BERNARDES, R. S. Escolha de um programa de controle da qualidade da água para consumo humano: aplicação do método AHP. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 4, n. 2, p. 257–262, 2000.
- ACADEMIC ONEFILE. Poeira que faz chover: areia do Saara aumenta precipitação na Amazônia. Disponível em: <<http://migre.me/f7Ovn>>. Acesso em: 10/2/2013.
- ACHOTEGUI-CASTELLS, A.; SARDANS, J.; RIBAS, A.; PEÑUELAS, J. Identifying the origin of atmospheric inputs of trace elements in the Prades Mountains (Catalonia) with bryophytes, lichens, and soil monitoring. **Environmental monitoring and assessment**, v. 185, n. 1, p. 615–29, 2013.
- ADEME. **Classification and criteria for setting up air-quality monitoring station**. 1st ed. Paris, 2002.
- AGUIAR, A. O.; TAKAYANAGUI, A. M. M.; ROCHA, A. A.; et al. **Saneamento, Saúde e Ambiente: fundamentos para um desenvolvimento sustentável**. 1º ed. Barueri, São Paulo: Manole, 2005.
- AGUILERA, I.; GUXENS, M.; GARCIA-ESTEBAN, R.; et al. Association between GIS-based exposure to urban air pollution during pregnancy and birth weight in the INMA Sabadell Cohort. **Environmental health perspectives**, v. 117, n. 8, p. 1322–7, 2009.
- ALIGNER. Programa de computador. **Expert Choice (versão 3.01)**, 2004. Estados Unidos.
- ALMEIDA, S. L. DE. **Análise espacial das doenças respiratórias e a poluição relacionada ao tráfego no município de São Paulo**, 2013. Dissertação (Mestrado em Saúde Pública): Universidade de São Paulo, São Paulo.
- ALMEIDA-SILVA, M.; CANHA, N.; FREITAS, M. C.; DUNG, H. M.; DIONÍSIO, I. Air pollution at an urban traffic tunnel in Lisbon, Portugal: an INAA study. **Applied radiation and isotopes**, v. 69, n. 11, p. 1586–1591, 2011.
- ALVES, E. M. P.; COSTA, R. R.; BRAGA, A. A.; et al. **Monitoramento da qualidade do ar no Brasil**. São Paulo: Instituto Saúde e Sustentabilidade, 2014.
- AMERICAN HEART ASSOCIATION. **Creating Spaces: changing the built environment to promote active living**. 2014.
- ANASTASOPOULOS, A. T.; WHEELER, A. J.; KARMAN, D.; KULKA, R. H. Intraurban concentrations, spatial variability and correlation of ambient polycyclic aromatic hydrocarbons (PAH) and PM<sub>2.5</sub>. **Atmospheric Environment**, v. 59, p. 272–283, 2012.

- ANDREAE, M. O. The aerosol nucleation puzzle. **Science**, v. 339, n. 6122, p. 911–2, 2013.
- ANSELIN, L. Local indicators of spatial association - LISA. **Geographical analysis**, v. 27, n. 2, p. 93–115, 1995.
- ANTT. **1º Inventário nacional de emissões atmosféricas do transporte ferroviário de cargas**. 1st ed. Brasília: Agência Nacional de Transporte Terrestre, 2010.
- AQICN. Air pollution: real-time air quality index. Disponível em: <<http://aqicn.org/city/beijing/>>. Acesso em: 1/4/2013.
- ARBEX, M. A.; SANTOS, U. D. P.; MARTINS, L. C.; et al. Air pollution and the respiratory system. **Journal Brazilian Pneumologic**, v. 38, n. 5, p. 643–655, 2012.
- ASHWORTH, D. C.; FULLER, G. W.; TOLEDANO, M. B.; et al. Comparative assessment of particulate air pollution exposure from municipal solid waste incinerator emissions. **Journal of Environmental and Public Health**, v. 2013, p. 13, 2013.
- ASSUNÇÃO, J. V. Controle de poluição do ar. In: A. Philippi; M. de A. Roméro; G. C. Bruna (Eds.); **Curso de Gestão Ambiental**. 1º ed., p.101–154, 2004. Barueri, São Paulo: Manole.
- AUSTIN, A. T.; BUSTAMANTE, M. M. C.; NARDOTO, G. B.; et al. Latin america's nitrogen challenge. **Science**, v. 340, p. 149, 2013.
- AUSTIN, E.; COULL, B. A.; ZANOBETTI, A.; KOUTRAKIS, P. A framework to spatially cluster air pollution monitoring sites in US based on the PM2.5 composition. **Environment international**, v. 59, p. 244–254, 2013.
- BAHADORI, T.; SUH, H.; KOUTRAKIS, P. PM2.5 and PM10 concentrations in four metropolitan cities in eastern United States. **Journal Air Waste Management**, v. 2, n. 3, 2000.
- BAIRD, C.; CANN, M. **Química ambiental**. 4th ed. Porto Alegre: Bookman, 2011.
- BAKONYI, S. M. C.; MORESCO, I. D.-O.; MARTINS, L. C.; BRAGA, A. L. F. Poluição atmosférica e doenças respiratórias em crianças na cidade de Curitiba , PR. **Revista Saúde Pública**, v. 38, n. 5, p. 695–700, 2004.
- BALDAUF, R. W.; HEIST, D.; ISAKOV, V.; et al. Air quality variability near a highway in a complex urban environment. **Atmospheric Environment**, v. 64, p. 169–178, 2013.
- BANDO, D. H.; MOREIRA, R. S.; PEREIRA, J. C.; BARROZO, L. V. Spatial clusters of suicide in the municipality of São Paulo 1996-2005: an ecological study. **BMC Psychiatry**, v. 12, n. 1, p. 124, 2012. BMC Psychiatry. Disponível em: <BMC Psychiatry>. .
- BANZHAF, E.; HÖFER, R. Monitoring urban structure types as spatial indicators with CIR Aerial Photographs for a more effective urban environmental management. **Journal of Selected topics in applied earth observations and remote sensing**, v. 1, n. 2, p. 129–138, 2008.

- BAPTISTA, G. M. M. Mapeamento do sequestro de carbono e de domos urbanos de CO<sub>2</sub> em ambientes tropicais, por meio de sensoriamento remoto hiperespectral. **Geografia**, v. 29, n. 2, p. 189–202, 2004.
- BARRETT, S. R. H.; BRITTER, R. E.; WAITZ, I. A. Global mortality attributable to aircraft cruise emissions. **Environmental science & technology**, v. 44, n. 19, p. 7736–42, 2010.
- BARROS, M. A.; MOREIRA, M. A.; RUDORFF, B. F. T. Processo analítico hierárquico na identificação de áreas favoráveis ao agroecossistema cafeeiro em escala municipal. **Pesquisa Agropecuária Brasileira**, v. 42, n. 12, p. 1769–1777, 2007.
- BARROZO, L. V. Contribuições da cartografia aos estudos de geografia da saúde: investigando associações entre padrões espaciais. **Cartogeo**, v. Especial, n. 2, p. 413–425, 2014.
- BATEMAN, I. J.; HARWOOD, A. R.; MACE, G. M.; et al. Bringing Ecosystem Services into Economic Decision-Making: Land Use in the United Kingdom. **Science**, v. 341, n. 6141, p. 45–50, 2013.
- BECHLE, M. J.; MILLET, D. B.; MARSHALL, J. D. Remote sensing of exposure to NO<sub>2</sub>: Satellite versus ground-based measurement in a large urban area. **Atmospheric Environment**, v. 69, n. 2, p. 345–353, 2013.
- BEELEN, R.; HOEK, G.; VIENNEAU, D.; et al. Development of NO<sub>2</sub> and NO<sub>x</sub> land use regression models for estimating air pollution exposure in 36 study areas in Europe - The ESCAPE project. **Atmospheric Environment**, v. 72, p. 10–23, 2013.
- BEEVERS, S. D.; KITWIROON, N.; WILLIAMS, M. L.; et al. Air pollution dispersion models for human exposure predictions in London. **Journal of exposure science & environmental epidemiology**, p. 1–7, 2013.
- BELLASIO, R.; BIANCONI, R.; CORDA, G.; CUCCA, P. Emission inventory for the road transport sector in Sardinia (Italy). **Atmospheric Environment**, v. 41, n. 4, p. 677–691, 2007. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1352231006009435>>. Acesso em: 25/7/2014.
- BERG, A. E. VAN DEN; MAAS, J.; VERHEIJ, R. A.; GROENEWEGEN, P. P. Green space as a buffer between stressful life events and health. **Social Science & Medicine**, v. 70, n. 8, p. 1203–1210, 2010.
- BERRIGAN, D.; MCKINNON, R. Built environment and health. **Preventive Medicine**, v. 47, n. 3, p. 239–240, 2008.
- BHANGAR, S.; SINGER, B. C.; NAZAROFF, W. W. Calibration of the Ogawa passive ozone sampler for aircraft cabins. **Atmospheric Environment**, v. 65, p. 21–24, 2013.
- BHATNAGAR, A. Environmental cardiology: Studying mechanistic links between pollution and heart disease. **Circulation Research**, v. 99, n. 7, p. 692–705, 2006.

- BIND, M.-A.; COULL, B.; PETERS, A.; et al. Beyond the mean: quantile regression to explore the association of air pollution with gene-specific methylation in the normative aging study. **Environmental health perspectives**, v. 2, n. 3, 2015.
- BLACK, W. R. **Sustainable transportation: problems and solutions**. 1st ed. Nova York: Guilford Press, 2010.
- BORGINI, A.; TITTARELLI, A.; RICCI, C.; et al. Personal exposure to PM2.5 among high-school students in Milan and background measurements: The EuroLifeNet study. **Atmospheric Environment**, v. 45, n. 25, p. 4147–4151, 2011.
- BRAGA, B.; HESPANHOL, I.; CONEJO, J. L.; et al. **Introdução à Engenharia Ambiental**. 2º ed. São Paulo: Pearson Prentice Hall, 2005.
- BRAJER, V.; HALL, J.; RAHMATIAN, M. Air Pollution , Its Mortality Risk , and Economic Impacts in Tehran , Iran. **Iranian Journal Publising Health**, v. 41, n. 5, p. 31–38, 2012.
- BRANCO, G. M.; WALSH, M. **Controle da poluição dos veículos a diesel: uma estratégia para o progresso do Brasil**. 1º ed. Rio de Janeiro: Ipsis, 2005.
- BRANIS, M.; LINHARTOVA, M. Association between unemployment, income, education level, population size and air pollution in Czech cities: Evidence for environmental inequality? A pilot national scale analysis. **Health & place**, 2012.
- BRENDER, J.; ZHAN, B.; LANGLOIS, P.; SUAREZ, L.; SCHEUERLE, A. Residential proximity to waste sites and industrial facilities and chromosomal anomalies in offspring. **International Journal of hygiene and environmental health**, v. 211, p. 50–58, 2008.
- BRIAN, S.; JAMES, S.; LAWRENCE, F.; et al. Neighborhood environment and psychosocial correlates of adults' physical activity. **Medicine & Science in Sports & Exercise**, v. 44, n. 4, p. 637–646, 2012.
- BRINGFELT, B.; HJORTH, T.; RING, S. A numerical air pollution dispersion. **Atmospheric Environment (1967)**, v. 8, p. 131–148, 1974.
- BRUGGE, D.; LANE, K.; PADRÓ-MARTÍNEZ, L. T.; et al. Highway proximity associated with cardiovascular disease risk: the influence of individual-level confounders and exposure misclassification. **Environmental health**, v. 12, n. x, p. 84, 2013. Disponível em: <<http://www.ehjournal.net/content/12/1/84>>. .
- BUONANNO, G.; BERNABEI, M.; AVINO, P.; STABILE, L. Occupational exposure to airborne particles and other pollutants in an aviation base. **Environmental pollution**, v. 170, p. 78–87, 2012.
- BUONANNO, G.; FUOCO, F. C.; MORAWSKA, L.; STABILE, L. Airborne particle concentrations at schools measured at different spatial scales. **Atmospheric Environment**, v. 67, p. 38–45, 2013.

- BUONANNO, G.; MARKS, G.; MORAWSKA, L. Health effects of daily airborne particle dose in children: Direct association between personal dose and respiratory health effects. **Environmental pollution**, v. 180, p. 246–250, 2013.
- BUSTAMANTE, E. N.; MONGE-NÁJERA, J.; MÉNDEZ-ESTRADA, V. H. Use of a Geographic Information System and lichens to map air pollution in a tropical city : San José , Costa Rica. **Revista Biológica Tropical**, v. 61, n. 2, p. 557–563, 2013.
- CABALLERO, S.; ESCLAPEZ, R.; GALINDO, N.; MANTILLA, E.; CRESPO, J. Use of a passive sampling network for the determination of urban NO<sub>2</sub> spatiotemporal variations. **Atmospheric Environment**, v. 63, n. 2, p. 148–155, 2012.
- CABRAL, S. D.; OLIVEIRA, L. B.; MATTOS, L. B.; SAMPAIO, M. R.; RIBEIRO, S. K. **Transporte sustentável: alternativas para ônibus urbanos**. 1st ed. Rio de Janeiro: Coppe - UFRJ, 2001.
- CAESB. Base dados: **localização e classificação dos hidrômetros do Distrito Federal**, 2011. Brasília.
- CAI, M.; YIN, Y.; XIE, M. Prediction of hourly air pollutant concentrations near urban arterials using artificial neural network approach. **Transportation Research Part D: Transport and Environment**, v. 14, n. 1, p. 32–41, 2009.
- CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. **Introdução à ciência da geoinformação**. 1<sup>o</sup> ed. Rio de Janeiro, 2001.
- CAMARGO, N. V. A.; COSTA, N. R.; MIRAGLIA, S. G. E. K. Poluição atmosférica – Análise sobre as medidas de controle da poluição atmosférica e o sistema de informação do Parque do Ibirapuera. **Gepros - Gestão da Produção, Operações e Sistemas**, , n. 2, p. 87–100, 2011.
- CAMPOS, F. G. DE; BARROZO, L. V.; RUIZ, T.; et al. Distribuição espacial dos idosos de um município de médio porte do interior paulista segundo algumas características sócio-demográficas e de morbidade. **Cadernos de saúde pública**, v. 25, n. 1, p. 77–86, 2008.
- CBHA. Where we live matters for our health: neighborhoods and health. Disponível em: <[www.commissionhealth.org](http://www.commissionhealth.org)>. Acesso em: 17/5/2015.
- CERVERO, R.; KOCKELMAN, K. Travel demand and the 3 Ds: density, diversity and design. **Transportation Research Part D**, v. 3, p. 199–219, 1997.
- CETESB. **1<sup>o</sup> Inventário de emissões antrópicas de gases de efeito estufa diretos e indiretos do estado de São Paulo**. 1<sup>o</sup> ed. São Paulo: CETESB, 2011.
- CETESB. **Inventário de emissões das fontes estacionárias do estado de São Paulo**. São Paulo, 2012.
- CETESB. Qualidade do ar. Disponível em: <<http://www.cetesb.sp.gov.br/>>. Acesso em: 4/6/2013.



- CHAN, C. K.; YAO, X. Air pollution in mega cities in China. **Atmospheric Environment**, v. 42, n. 1, p. 1–42, 2008.
- CHEN, C.-L.; TSUANG, B.-J.; TU, C.-Y.; CHENG, W.-L.; LIN, M.-D. Wintertime vertical profiles of air pollutants over a suburban area in central Taiwan. **Atmospheric Environment**, v. 36, n. 12, p. 2049–2059, 2002.
- CHEN, R.; KAN, H.; CHEN, B.; et al. Association of Particulate Air Pollution With Daily Mortality: The China Air Pollution and Health Effects Study. **American Journal of Epidemiology**, , n. 8, 2012.
- CHENG, H.; DENG, Z.; CHAKRABORTY, P.; et al. A comparison study of atmospheric polycyclic aromatic hydrocarbons in three Indian cities using PUF disk passive air samplers. **Atmospheric Environment**, v. 73, p. 16–21, 2013.
- CHIEN, L.-C.; BANGDIWALA, S. I. The implementation of Bayesian structural additive regression models in multi-city time series air pollution and human health studies. **Stochastic Environmental Research and Risk Assessment**, 2012.
- CHINA, S.; JAMES, D. E. Influence of pavement macrotexture on PM10 emissions from paved roads: A controlled study. **Atmospheric Environment**, v. 63, p. 313–326, 2012.
- CHOI, Y. S.; KIM, B. R. PM10 weekly periodicity in Beijing and Tianjin, 2000–2009: Anthropogenic or natural contributions? **Atmospheric Environment**, v. 55, p. 49–55, 2012.
- CHOWDHURY, Z.; CAMPANELLA, L.; GRAY, C.; et al. Measurement and modeling of indoor air pollution in rural households with multiple stove interventions in Yunnan, China. **Atmospheric Environment**, v. 67, p. 161–169, 2013.
- CHRISTOFOLETTI, A. **Modelagem de sistemas ambientais**. 6<sup>o</sup> ed. São Paulo: Edhard Blucher, 1999.
- CHRISTOPHERSON, R. W. **Geossistemas: uma introdução à geografia física**. 7th ed. Porto Alegre: Bookman, 2012.
- CHUANG, Y.-C.; CUBBIN, C.; AHN, D.; WINKLEBY, M. Effects of neighbourhood socioeconomic status and convenience store concentration on individual level smoking. **Journal of Epidemiology & Community Health**, v. 59, p. 568–573, 2005.
- CHUM, A.; O’CAMPO, P. Cross-sectional associations between residential environmental exposures and cardiovascular diseases. **BMC Public Health**, v. 15, n. 1, 2015.
- CHUN, Y.; GRIFFITH, D. **Spatial statistics & geostatistics**. First ed. London: Sage, 2013.
- CODEPLAN. Pesquisa metropolitana por amostra de domicílios. , 2013. Brasília: GDF.
- COHEN, A.; ANDERSON, R.; BRAUER, M.; BURNETT, R. The global burden of disease attributable to outdoor air pollution: estimates from the GBD 2010 project. ISEE Conference. **Anais...** . p.388, 2012. Columbia.

COLETTE, A.; FAVEZ, O.; MELEUX, F.; et al. Assessing in near real time the impact of the April 2010 Eyjafjallajökull ash plume on air quality. **Atmospheric Environment**, v. 45, n. 5, p. 1217–1221, 2011. Elsevier Ltd.

CONAMA. Resolução Conama número 003. (Ministério do Meio Ambiente, Ed.), 1990. Brasília.

CONCEIÇÃO, L. M.; LATORRE, M. DO R. DE O.; REGINA, M. A. C.; et al. Poluição atmosférica e atendimentos por pneumonia e gripe em São Paulo, Brasil. **Revista Saúde Pública**, v. 36, n. 1, p. 88–94, 2002.

CONGALTON, R. G.; GREEN, D. **Assessing the accuracy of remotely sensed data: principles and practices**. 2nd ed. CRC Press, 1999.

COOK, A. J.; GOLD, D. R.; LI, Y. Spatial cluster detection for longitudinal outcomes using administrative regions. **Commun Stat Theory Methods**, v. 42, n. 12, p. 2105–2117, 2013.

COOPER, M. J.; MARTIN, R. V.; DONKELAAR, A. VAN; et al. A satellite-based multi-pollutant index of global air quality. **Environmental Science and Technology**, v. 46, n. 16, p. 8523–8524, 2012.

CORBURN, J. Urban land use, air toxics and public health: Assessing hazardous exposures at the neighborhood scale. **Environmental Impact Assessment Review**, v. 27, n. 2, p. 145–160, 2007.

CRISTALE, J.; SILVA, F. S.; ZOCCOLO, G. J.; MARCHI, M. R. R. Influence of sugarcane burning on indoor/outdoor PAH air pollution in Brazil. **Environmental pollution**, p. 1–7, 2012.

DARGAY, J.; GATELY, D.; SOMMER, M. Vehicle ownership and income growth, worldwide: 1960-2030. **The energy journal**, v. 28, n. 4, p. 143–170, 2007.

DATASUS. Base de dados: **endereço dos pacientes atendidos e internados no Distrito Federal**, 2013. Brasília.

DATASUS. Estatística de saúde. Disponível em: <[www.datasus.gov.br](http://www.datasus.gov.br)>. Acesso em: 30/6/2015.

DAVIS, D. A.; AKOPIAN, G.; WALSH, J. P.; et al. Urban air pollutants reduce synaptic function of CA1 neurons via an NMDA/NO pathway in vitro. **Journal of Neurochemistry**, v. 127, n. 4, p. 509–519, 2013.

DAVIS, M. E. Recessions and Health: The Impact of Economic Trends on Air Pollution in California. **American journal of public health**, p. 1–6, 2012.

DEFRA. Air information resource. Disponível em: <[www.airquality.co.uk](http://www.airquality.co.uk)>. Acesso em: 2/9/2013.

DENATRAN. Estatística de veículos. Disponível em: <[www.denatran.gov.br](http://www.denatran.gov.br)>. Acesso em: 15/4/2015.

- DER. Base de dados: **contagem volumétrica dos pardais eletrônicos**, 2010. Brasília.
- DERAISME, J.; BOBBIA, M.; FOUQUET, C. Contribution of geostatistics to the study of risks related to air pollution. **Advance air pollution**. 1st ed., p.325–340, 2011. Croatia: InTech.
- DERISIO, J. C. **Introdução ao controle de poluição ambiental**. 4th ed. São Paulo: Oficina de textos, 2012.
- DESHMUKH, D. K.; DEB, M. K.; MKOMA, S. L. Size distribution and seasonal variation of size-segregated particulate matter in the ambient air of Raipur city, India. **Air Quality, Atmosphere & Health**, v. 10, 2012.
- DETRAN. Base de dados: **contagem volumétrica dos pardais eletrônicos**, 2009. Brasília.
- DIAS, V. R. D. M.; SANCHES, L.; ALVES, M. D. C.; NOGUEIRA, J. D. S. Spatio-temporal variability of anions in wet precipitation of Cuiabá, Brazil. **Atmospheric Research**, v. 107, p. 9–19, 2012.
- DIEZ-ROUX, A. V. Neighborhoods and health: where are we and where do we go from here? **Epidemiology Sante Publique**, v. 55, n. 1, p. 13–21, 2007.
- DOCKERY, D.; POPE, A.; XU, X.; et al. An association between air pollution and mortality in six U.S. cities. **The New England Journal of Medicine**, v. 329, n. 24, p. 1753–1759, 1993.
- DOMÉNECH, X. **Química atmosférica: origem y efectos de la contaminación**. 4th ed. Madrid: Miraguano Ediciones, 2008.
- DONKELAAR, A. VAN; MARTIN, R. V.; BRAUER, M.; et al. Global estimates of ambient fine particulate matter concentrations from satellite-based aerosol optical depth: development and application. **Environmental health perspectives**, v. 118, n. 6, p. 847–55, 2010.
- DRIVAS, P.; BOWERS, T.; YAMARTINO, R. Soil mixing depth after atmospheric deposition. I. Model development and validation. **Atmospheric Environment**, v. 45, n. 25, p. 4133–4140, 2011.
- DUARTE, C.; SOUZA, R. DE; SILVA, S. D.; et al. Inventory of conventional air pollutants emissions from road transportation for the state of Rio de Janeiro. **Energy Policy**, v. 25, n. 20, 2013.
- EEA. **Air quality in Europe - 2012 report**. 1st ed. Copenhagen: EEA, 2012.
- ENVIRONMENTAL PROTECTION AGENCY. **Air quality criteria for particulate matter**. 1st ed. Estados Unidos: Environmental Protection Agency, 2004.
- EPA. Exposure Research air: methods, models, tools and databases. Disponível em: <<http://www.epa.gov/nerl/topics/air.html>>. Acesso em: 9/4/2013a.
- EPA. Air Science Resources. Disponível em: <<http://www2.epa.gov/science-and-technology/air-science-resources#monitoring>>. Acesso em: 9/4/2013b.

- ESRI. Programa de computador. **ArcGis (versão 10.2)**, 2013a. Estados Unidos.
- ESRI. Programa de computador. **ArcCatalog (versão 10.2)**, 2013b. Estados Unidos.
- FAJERSZTAJN, L.; VERAS, M.; BARROZO, L. V.; SALDIVA, P. Air pollution: a potentially modifiable risk factor for lung cancer. **Nature reviews. Cancer**, v. 13, n. 9, p. 674–8, 2013.
- FAN, X.; LAM, K.; YU, Q. Differential exposure of the urban population to vehicular air pollution in Hong Kong. **The Science of the total environment**, 2012.
- FEAM. Monitoramento. Disponível em: <<http://www.feam.br/monitoramento>>. Acesso em: 30/5/2013.
- FENGER, J. Air pollution in the last 50 years - From local to global. **Atmospheric Environment**, v. 43, n. 1, p. 13–22, 2009.
- FEPAM. Qualidade ambiental. Disponível em: <[http://www.fepam.rs.gov.br/qualidade/monitor\\_ar.asp](http://www.fepam.rs.gov.br/qualidade/monitor_ar.asp)>. Acesso em: 30/5/2013.
- FERNANDO, H. J. S.; MAMMARELLA, M. C.; GRANDONI, G.; et al. Forecasting PM10 in metropolitan areas: Efficacy of neural networks. **Environmental pollution**, v. 163, p. 62–67, 2012.
- FIORE, A. M.; NAIK, V.; SPRACKLEN, D. V; et al. Global air quality and climate. **Chemical Society reviews**, v. 41, n. 19, p. 6663–83, 2012.
- FONTANA, V.; RADTKE, A.; BOSSI FEDRIGOTTI, V.; et al. Comparing land-use alternatives: Using the ecosystem services concept to define a multi-criteria decision analysis. **Ecological Economics**, v. 93, p. 128–136, 2013. Elsevier B.V.
- FRASER, L.; CLARKE, G.; CADE, J.; EDWARDS, K. Fast food and obesity: a spatial analysis in a large United Kingdom population of children aged 13-15. **American Journal of Preventive Medicine**, v. 42, n. 5, 2012.
- FREITAS, M. DE B. C.; XAVIER, A. M. DE S.; FRAGOSO, R. M. DE S. Redistributing Agricultural Data by a Dasymetric Mapping Methodology. **Agricultural and Resource Economics Review**, v. 3, n. 41, p. 351–366, 2012.
- FREITAS, S.; LONGO, K. M. Emissões de queimadas em ecossistemas da América do Sul. **Estudos Avançados**, v. 19, n. 53, p. 167–185, 2005.
- FRIEDL, L.; HUSAR, R.; FALKE, S. GEO Task US-09-01a: critical earth observations priorities. **Group on earth observations**, 2010. Disponível em: <[http://sbageotask.larc.nasa.gov/AirQuality\\_US0901a-FINAL.pdf](http://sbageotask.larc.nasa.gov/AirQuality_US0901a-FINAL.pdf)>. .
- FUENTE, D.; VEGA, J. M.; VIEJO, F.; DÍAZ, I.; MORCILLO, M. Mapping air pollution effects on atmospheric degradation of cultural heritage. **Journal of Cultural Heritage**, 2012.
- FUKUSHIMA, H. Air pollution monitoring in East Asia. **Science & Technology Trends**, , n. 18, 2006.

- FULLER, C. H.; BRUGGE, D.; WILLIAMS, P. L.; et al. Estimation of ultrafine particle concentrations at near-highway residences using data from and central monitors. **Atmospheric Environment**, v. 57, p. 257–265, 2012.
- GALLARDO, L.; ESCRIBANO, J.; DAWIDOWSKI, L.; et al. Evaluation of vehicle emission inventories for carbon monoxide and nitrogen oxides for Bogotá, Buenos Aires, Santiago, and São Paulo. **Atmospheric Environment**, v. 47, p. 12–19, 2012.
- GAN, W.; L., T.; HW, D.; et al. Changes in residential proximity to road traffic and the risk of death from coronary heart disease. **Epidemiology**, v. 21, n. 5, p. 642–649, 2010.
- GARCIA, G.; ALLEN, A. G.; CARDOSO, A. A. Development of a sensitive passive sampler using indigotrisulfonate for the determination of tropospheric ozone. **Journal of environmental monitoring**, v. 12, n. 6, p. 1325–1329, 2010.
- GARTNER, I. R. **Avaliação ambiental de projetos em bancos de desenvolvimento nacionais e multilaterais: evidências e propostas**. 1st ed. Brasília: Universa, 2001.
- GARTNER, I. R. Modelagem multiatributos aplicada à avaliação do desempenho econômico-financeiro de empresas. **Pesquisa operacional**, v. 30, n. 3, p. 619–636, 2010.
- GARTNER, I. R.; GAMA, M. L. DA S. Avaliação multicriterial dos impactos ambientais da suinocultura no Distrito Federal: um estudo de caso. **Organismos Rurais e agroindustrias**, v. 7, n. 2, p. 148–161, 2005.
- GASPARRINI, A.; GUO, Y.; HASHIZUME, M.; LAVIGNE, E.; et al. Mortality risk attributable to high and low ambient temperature: a multicountry observational study. **The Lancet**, v. 12, n. 5, 2015.
- GASPARRINI, A.; GUO, Y.; HASHIZUME, M.; KINNEY, P. L.; et al. Temporal Variation in Heat–Mortality Associations: A Multicountry Study. **Environmental Health Perspectives**, v. 38, n. 5, 2015.
- GDF. Plano Diretor de Transporte Urbano do Distrito Federal - PDTU. (GDF, Ed.), 2008. Brasília.
- GDF. Mosaico de ortofotos do Distrito Federal. (GDF, Ed.), 2009. Brasília.
- GEELLEN, L.; HUIJBREGTS, M.; JANS, H.; et al. Comparing the impact of fine particulate matter emissions from industrial facilities and transport on the real age of a local community. **Atmospheric Environment**, v. 73, p. 138–144, 2013.
- GENC, S.; ZADEOGLULARI, Z.; FUSS, S. H.; GENC, K. The adverse effects of air pollution on the nervous system. **Journal of Toxicology**, v. 12, 2012.
- GERHARZ, L. E.; KLEMM, O.; BROICH, A. V.; PEBESMA, E. Spatio-temporal modelling of individual exposure to air pollution and its uncertainty. **Atmospheric Environment**, v. 64, n. 2, p. 56–65, 2013.

- GERON, C.; HAYS, M. Air emissions from organic soil burning on the coastal plain of North Carolina. **Atmospheric Environment**, v. 64, p. 192–199, 2013.
- GETIS, A.; ORD, J. The analysis of spatial association by use of distance statistics. **Geographical Analysis**, v. 24, n. 3, 1992.
- GOLDEN. Programa de computador. **Grapher (versão 8.7.844)**, 2013. Estados Unidos.
- GOMES, J. **Poluição atmosférica: um manual universitário**. 2nd ed. Porto, Portugal: Publindústria, 2010.
- GONZALEZ-BARCALA, F. J.; PERTEGA, S.; GARNELO, L.; et al. Truck traffic related air pollution associated with asthma symptoms in young boys: a cross-sectional study. **Public health**, v. 127, n. 3, 2013. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/23434038>>. Acesso em: 27/3/2013.
- GOOGLE. Programa de computador. **Google Earth (versão 7.1.1.188)**, 2013. Estados Unidos.
- GÓRALCYK, M. Life cycle assessment in the renewable energy sector. **Applied Energy**, v. 75, p. 205–211, 2003.
- GREENING, L. A.; BERNOW, S. Design of coordinated energy and environmental policies: use of multi-criteria decision-making. **Energy Policy**, v. 32, p. 721–735, 2004.
- GRIGAL, D. F. Atmospheric Deposition and Inorganic Nitrogen Flux. **Water, Air, & Soil Pollution**, 2012.
- GRIGG, J. New insights into air pollution and children's health. **Paediatrics and Child Health**, v. 22, n. 5, p. 198–200, 2012.
- GU, B.; DONG, X.; PENG, C.; et al. The long-term impact of urbanization on nitrogen patterns and dynamics in shanghai, China. **Environmental pollution**, v. 171, p. 30–37, 2012.
- GUTTIKUNDA, S. K.; CALORI, G. A GIS based emissions inventory at 1 km × 1 km spatial resolution for air pollution analysis in Delhi, India. **Atmospheric Environment**, v. 67, p. 101–111, 2013.
- HABERMANN, M.; GOUVEIA, N. Aplicação de regressão baseada no uso do solo para prever a concentração de material particulado inalável no município de São Paulo, Brasil. **Engenharia Sanitária e Ambiental**, v. 17, n. 2, p. 155–162, 2012.
- HANSON, S.; GIULIANO, G. **The geography of urban transportation**. 3rd ed. Nova York: Guilford Press, 2004.
- HARISH, M. A study on air pollution by automobiles in Bangalore city. **Management research and practice**, v. 44, n. 3, p. 24–36, 2012.
- HECHT, R.; HEROLD, H.; MEINEL, G.; BUCHROITHNER, M. Automatic derivation of urban structure types from topographic maps by means of image analysis and machine learning. In: 26th International Cartographic Conference. **Anais...**, 2011.

- HEIDEN, U.; HELDENS, W.; ROESSNER, S.; et al. Urban structure type characterization using hyperspectral remote sensing and height information. **Landscape and Urban Planning**, v. 105, n. 4, p. 361–375, 2012.
- HENDRIKS, C.; KRANENBURG, R.; KUENEN, J.; et al. The origin of ambient particulate matter concentrations in the Netherlands. , v. 69, p. 289–303, 2013.
- HENSHER, D. A.; BUTTON, K. J. **Handbook of transport modelling**. Nova York: Pergamon, 2000.
- HENSHER, D. A.; STOPHER, P. R. TRESIS ( Transport and Environmental Strategy Impact Simulator ): application to a case study in NE Sydney. (University of Sidney, Ed.), 2004. Austrália.
- HERTEL, O.; LEEUW, F.; NIELSEN, O.; et al. Human exposure to outdoor air pollution. **Pure and applied chemistry**, v. 73, n. 6, p. 933–958, 2001.
- HIXSON, M.; MAHMUD, A.; HU, J.; KLEEMAN, M. J. Resolving the interactions between population density and air pollution emissions controls in the San Joaquin Valley, USA. **Journal Air Waste Management Association**, v. 62, n. 5, p. 566–575, 2012.
- HOFER, R. **Remote sensing based derivation of urban structure types to assess hydro-meteorological impacts in highly dynamic urban agglomerations in Latin America**, 2013. Albert-Ludwigs University.
- HOFFMAN, K.; KALKBRENNER, A. E.; VIEIRA, V. M.; DANIELS, J. L. The spatial distribution of known predictors of autism spectrum disorders impacts geographic variability in prevalence in central North Carolina. **Environmental health**, v. 11, n. 1, p. 80, 2012.
- HÖNISCH, B.; RIDGWELL, A.; SCHMIDT, D. N.; et al. The geological record of ocean acidification. **Science**, v. 335, n. 6072, p. 1058–63, 2012.
- HSU, H.-H.; ADAMKIEWICZ, G.; HOUSEMAN, E. A.; et al. The relationship between aviation and ultrafine particulate matter concentrations near a mid-sized airport. **Atmospheric Environment**, v. 50, p. 328–337, 2012.
- HU, Z. Spatial analysis of MODIS aerosol optical depth, PM<sub>2.5</sub>, and chronic coronary heart disease. **International journal of health geographics**, v. 8, p. 27, 2009.
- HUANG, C.; CHEN, C. H.; LI, L.; et al. Emission inventory of anthropogenic air pollutants and VOC species in the Yangtze River Delta region, China. **Atmospheric Chemistry and Physics**, v. 11, n. 9, p. 4105–4120, 2011.
- HŮNOVÁ, I.; MAZNOVÁ, J.; KURFÜRST, P. Trends in atmospheric deposition fluxes of sulphur and nitrogen in Czech forests. **Environmental pollution**, v. 3, p. 1–8, 2013.
- IAP. Projeto gestão de qualidade do ar. Disponível em:  
<<http://www.iap.pr.gov.br/modules/conteudo/conteudo.php?conteudo=92>>. Acesso em:  
30/5/2013.

- IBGE. Base de informações geográficas do setor censitário. Disponível em: <<http://www.ibge.gov.br/home/download/estatistica.shtm>>. Acesso em: 1/11/2012a.
- IBGE. Dados estatísticos. Disponível em: <[www.ibge.gov.br](http://www.ibge.gov.br)>. Acesso em: 11/11/2012b.
- IBGE. IBGE Cidades. Disponível em: <[www.cidades.ibge.gov.br](http://www.cidades.ibge.gov.br)>. Acesso em: 21/2/2013.
- IBM. Programa de computador. **SPSS statistics (versão 20)**, 2013. Estados Unidos.
- IBRAM. Banco de dados: qualidade ambiental. , 2013. Disponível em: <<http://www.semarh.df.gov.br/qualiar/index.html>>. Acesso em: 11/3/2013.
- IEMA. Primeiro diagnostico da rede de monitoramento da qualidade do ar no Brasil. , 2014. São Paulo: IEMA.
- IGNOTTI, E.; VALENTE, J. G.; LONGO, K. M.; et al. Impact on human health of particulate matter emitted from burnings in the Brazilian Amazon region. **Revista Saúde Pública**, v. 44, n. 1, p. 121–130, 2010.
- INEA. Qualidade do ar. Disponível em: <<http://www.inea.rj.gov.br/fma/qualidade-ar-rapido.asp?cat=65>>. Acesso em: 30/1/2013.
- INMET. Dados meteorológicos. Disponível em: <[www.inmet.gov.br](http://www.inmet.gov.br)>. Acesso em: 12/2/2012.
- INPE. Focos de queimadas. Disponível em: <<http://www.dpi.inpe.br/proarco/bdqueimadas/>>. Acesso em: 7/4/2013.
- JAMES, P.; BERRIGAN, D.; HART, J. E.; et al. Effects of buffer size and shape on associations between the built environment and energy balance. **Health and Place**, v. 27, p. 162–170, 2014.
- JANSSEN, S.; DUMONT, G.; FIERENS, F.; et al. Land use to characterize spatial representativeness of air quality monitoring stations and its relevance for model validation. **Atmospheric Environment**, v. 59, p. 492–500, 2012.
- JEONG, J. I.; PARK, R. J. Effects of the meteorological variability on regional air quality in East Asia. **Atmospheric Environment**, v. 69, n. 3, p. 46–55, 2013.
- JERRETT, M.; ARAIN, A.; KANAROGLOU, P.; et al. A review and evaluation of intraurban air pollution exposure models. **Journal of exposure analysis and environmental epidemiology**, v. 15, n. 2, p. 185–204, 2005.
- JOHNSTON, F. H.; PURDIE, S.; JALALUDIN, B.; et al. Air pollution events from forest fires and emergency department attendances in Sydney, Australia 1996-2007: a case-crossover analysis. **Environmental Health**, v. 13, n. 1, p. 105, 2014. Disponível em: <<http://www.ehjournal.net/content/13/1/105>>. .
- JOLY, M.; PEUCH, V.-H. Objective classification of air quality monitoring sites over Europe. **Atmospheric Environment**, v. 47, p. 111–123, 2012.



- JUNG, K. H.; BERNABÉ, K.; MOORS, K.; et al. Effects of Floor Level and Building Type on Residential Levels of Outdoor and Indoor Polycyclic Aromatic Hydrocarbons, Black Carbon, and Particulate Matter in New York City. **Atmosphere**, v. 2, n. 2, p. 96–109, 2011.
- KÄFFER, M. I.; LEMOS, A. T.; APEL, M. A.; et al. Use of bioindicators to evaluate air quality and genotoxic compounds in an urban environment in Southern Brazil. **Environmental pollution**, v. 163, p. 24–31, 2012.
- KAM, W.; LIACOS, J. W.; SCHAUER, J. J.; DELFINO, R. J.; SIOUTAS, C. Size-segregated composition of particulate matter (PM) in major roadways and surface streets. **Atmospheric Environment**, v. 55, p. 90–97, 2012.
- KANAROGLOU, P. S.; JERRETT, M.; MORRISON, J.; et al. Establishing an air pollution monitoring network for intra-urban population exposure assessment: A location-allocation approach. **Atmospheric Environment**, v. 39, n. 13, p. 2399–2409, 2005.
- KANG, J.; KIM, J. Y. Portable RF-Sensor System for the Monitoring of Air Pollution and Water Contamination. **Journal of Analytical Methods in Chemistry**, v. 2012, p. 1–5, 2012.
- KATSOYIANNIS, A.; BIRGUL, A.; RATOLA, N.; et al. Can car air filters be useful as a sampling medium for air pollution monitoring purposes? **Environment international**, v. 48, p. 65–70, 2012. Elsevier Ltd.
- KHAVANIN, R.; VEROUSTRAETE, F.; BUYTAERT, J.; DIRCKX, J.; SAMSON, R. Assessing urban habitat quality using spectral characteristics of Tilia leaves. **Environmental pollution**, v. 178, p. 7–14, 2013.
- KHILLARE, P. S.; SARKAR, S. Airborne inhalable metals in residential areas of Delhi, India: distribution, source apportionment and health risks. **Atmospheric Pollution Research**, v. 3, p. 46–54, 2012.
- KIM, H.-M.; KWAN, M.-P. Space-time accessibility measures: a geocomputational algorithm with a focus on the feasible opportunity set and possible activity duration. **Journal of Geographical Systems**, v. 5, p. 71–91, 2003.
- KIMBROUGH, S.; BALDAUF, R. W.; HAGLER, G. S. W.; et al. Long-term continuous measurement of near-road air pollution in Las Vegas: seasonal variability in traffic emissions impact on local air quality. **Air Quality, Atmosphere & Health**, 2012.
- KLOOG, I.; MELLY, S. J.; RIDGWAY, W. L.; COULL, B. A.; SCHWARTZ, J. Using new satellite based exposure methods to study the association between pregnancy PM<sub>2.5</sub> exposure, premature birth and birth weight in Massachusetts. **Environmental Health**, v. 111, n. 40, 2012.
- KOENKER, R. **Quantile Regression**. 1st ed. Londres: Cambridge U. Press, 2005.

- KOENKER, R. Quantile regression in r: a vignette. **Guide to use quantile regression in R**, 2011. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.161.133&rep=rep1&type=pdf>>. Acesso em: 2/7/2015.
- KOENKER, R.; HALLOCK, K. F. Quantile Regression. **Journal of Economic Perspectives**, v. 15, n. 4, p. 143–156, 2001.
- KOKOSKA, S.; ZWILLINGER, D. **CRC standard probability and statistics tables and formulae**. 2nd ed. New York: CRC Press, 2000.
- KOLENDOWICZ, L.; BEDNORZ, E.; WALNA, B.; KURZYCA, I. Episodes of extreme rainwater pollution and its relationship with synoptic situation. **Journal Atmospheric Chemistry**, 2011.
- KOO, B.; JUNG, J.; POLLACK, A. K.; et al. Impact of meteorology and anthropogenic emissions on the local and regional ozone weekend effect in Midwestern US. **Atmospheric Environment**, v. 57, p. 13–21, 2012.
- KOOP, T. The seeds of ice in clouds. **Nature**, v. 498, n. 20, p. 303–303, 2013.
- KOUSOULIDOU, M.; FONTARAS, G.; NTZIACHRISTOS, L.; et al. Use of portable emissions measurement system (PEMS) for the development and validation of passenger car emission factors. **Atmospheric Environment**, v. 64, n. x, p. 329–338, 2013.
- KUMAR, M.; LIPI, K.; SURESHBADU, S.; MAHANTI, N. C. Aerosol Properties over Ranchi Measured from Aethalometer. **Atmospheric and Climate Sciences**, v. 01, n. 03, p. 91–94, 2011.
- KURLAND, K.; GORR, W. **Gis tutorial fo health**. 4th ed. Nova York: Esri press, 2012.
- KWASNY, F.; MADL, P.; HOFMANN, W. Correlation of Air Quality Data to Ultrafine Particles (UFP) Concentration and Size Distribution in Ambient Air. **Atmosphere**, v. 1, n. 1, p. 3–14, 2010.
- LADEN, F.; NEAS, L. M.; DOCKERY, D. W.; SCHWARTZ, J. Association of fine particulate matter from different sources with daily mortality in six U.S. cities. **Environmental Health Perspectives**, v. 108, n. 10, p. 941–947, 2000.
- LADEN, F.; SCHWARTZ, J.; SPEIZER, F. E.; DOCKERY, D. W. Reduction in fine particulate air pollution and mortality: Extended follow-up of the Harvard Six Cities Study. **American Journal of Respiratory and Critical Care Medicine**, v. 173, n. 6, p. 667–672, 2006.
- LAMSAL, L. N.; MARTIN, R. V; PARRISH, D. D.; KROTKOV, N. A. Scaling relationship for NO<sub>2</sub> pollution and urban population size: a satellite perspective. **Environmental science & technology**, v. 47, n. 14, p. 7855–61, 2013.

- LEE, H. J.; COULL, B. A.; BELL, M. L.; KOUTRAKIS, P. Use of satellite-based aerosol optical depth and spatial clustering to predict ambient PM<sub>2.5</sub> concentrations. **Environmental research**, v. 118, p. 8–15, 2012.
- LEE, H.; KIM, H.; HONDA, Y.; LIM, Y.-H.; YI, S. Effect of Asian dust storms on daily mortality in seven metropolitan cities of Korea. **Atmospheric Environment**, v. 79, p. 510–517, 2013.
- LEE, J. S.; DEMOKRITOU, P.; KOUTRAKIS, P.; SABORIT, D. Development and evaluation of personal respirable particulate sampler (PRPS). **Atmospheric Environment**, v. 40, p. 212–224, 2006.
- LEE, K.; PARKHURST, W. J.; XUE, J.; et al. Outdoor/Indoor/Personal ozone exposures of children in Nashville, Tennessee. **Journal of the Air & Waste Management Association**, v. 54, n. 3, p. 352–359, 2004.
- LEE, K.; YEOM, J.; YOON, C.; et al. Seasonal and geographic effects on predicting personal exposure to nitrogen dioxide by time-weighted microenvironmental model. **Atmospheric Environment**, v. 67, n. 2, p. 143–148, 2013. Elsevier Ltd.
- LEE, R.; CUBBIN, C.; WINKLEBY, M. Contribution of neighbourhood socioeconomic status and physical activity resources to physical activity among women. **Journal of Epidemiology and Community Health**, v. 61, n. 10, 2007.
- LEE, W.; WOLFSON, J. M.; CATALANO, P. J.; RUDNICK, S. N.; KOUTRAKIS, P. Size-resolved deposition rates for ultra fine and submicrometer particles in a residential housing unit. **Environmental Science & Technology**, v. 48, p. 10282–10290, 2014.
- LEGRO, R. S.; SAUER, M. V.; MOTTLA, G. L.; et al. Effect of air quality on assisted human reproduction. **Human Reproduction**, v. 25, n. 5, p. 1317–1324, 2010.
- LEIVA, M. A.; SANTIBAÑEZ, D. A.; IBARRA E, S.; MATUS C, P.; SEGUEL, R. A five-year study of particulate matter (PM<sub>2.5</sub>) and cerebrovascular diseases. **Environmental pollution**, v. 181, p. 1–6, 2013.
- LENZI, E.; FAVERO, L. O. B. **Química da atmosfera**. Rio de Janeiro: LTC, 2011.
- LEPEULE, J.; LADEN, F.; DOCKERY, D.; SCHWARTZ, J. Chronic exposure to fine particles and mortality: An extended follow-up of the Harvard six cities study from 1974 to 2009. **Environmental Health Perspectives**, v. 120, n. 7, p. 965–970, 2012.
- LI, L.; WU, J.; WILHELM, M.; RITZ, B. Use of generalized additive models and cokriging of spatial residuals to improve land-use regression estimates of nitrogen oxides in Southern California. **Atmospheric Environment**, v. 55, p. 220–228, 2012.
- LIM, S. S.; VOS, T.; FLAXMAN, A. D.; et al. A comparative risk assessment of burden of disease and injury attributable to 67 risk factors and risk factor clusters in 21 regions, 1990–2010: A systematic analysis for the Global Burden of Disease Study 2010. **The Lancet**, v. 380, p. 2224–2260, 2012.

- LIMTANAKOOL, N.; DIJST, M.; SCHWANEN, T. The influence of socio-economic characteristics, land use and travel time considerations on mode choice for long-distance trips. In: ANNUAL TRANSPORTATION RESEARCH BOARD MEETING. **Anais...**, 2004. Washington.
- LIN, H.; AN, Q.; LUO, C.; et al. Gaseous air pollution and acute myocardial infarction mortality in Hong Kong: A time-stratified case-crossover study. **Atmospheric Environment**, v. 76, p. 68–73, 2013.
- LIN, L.-Y.; CHUANG, H.-C.; LIU, I.-J.; CHEN, H.-W.; CHUANG, K.-J. Reducing indoor air pollution by air conditioning is associated with improvements in cardiovascular health among the general population. **Science of the total environment**, v. 463-464, p. 176–181, 2013.
- LIPFERT, F. W.; MURRAY, C. J. Air pollution and daily mortality: A new approach to an old problem. **Atmospheric Environment**, v. 55, p. 467–474, 2012. Elsevier Ltd.
- LISKA, G. R.; BEIJO, L. A. Distribuições de probabilidade aplicadas na análise de níveis máximos de MP10 e O3 nas cidades de Cubatão e Paulínia, SP. **Revista de Estudos Ambientais**, v. 14, n. 3, p. 35–47, 2012.
- LIU, X.; ZHANG, Y.; HAN, W.; et al. Enhanced nitrogen deposition over China. **Nature**, v. 494, n. 7438, p. 459–462, 2013. Nature Publishing Group.
- LOBO, P.; HAGEN, D. E.; WHITEFIELD, P. D. Measurement and analysis of aircraft engine PM emissions downwind of an active runway at the Oakland International Airport. **Atmospheric Environment**, v. 61, p. 114–123, 2012.
- LONDON KING'S COLLEGE. London air. Disponível em: <[www.londonair.org.uk/london/asp/home.asp](http://www.londonair.org.uk/london/asp/home.asp)>. Acesso em: 5/5/2013.
- LONGLEY, P.; GOODCHILD, M.; MAGUIRE, D.; RHIND, D. **Sistemas e ciência da informação geográfica**. 3rd ed. Porto Alegre: Bookman, 2013.
- LOZANO, R.; NAGHAVI, M.; FOREMAN, K.; et al. Global and regional mortality from 235 causes of death for 20 age groups in 1990 and 2010. **The Lancet**, v. 380, n. 9859, p. 2095–2128, 2012.
- LUC ANSELIN. Programa de computador. **GeoDa (versão 1.6.7.9)**, 2015. Estados Unidos.
- LUVSAN, M.-E.; SHIE, R.-H.; PUREVDORJ, T.; et al. The influence of emission sources and meteorological conditions on SO2 pollution in Mongolia. **Atmospheric Environment**, v. 61, p. 542–549, 2012.
- MA, Z.; XU, H.; MENG, W.; et al. Vertical ozone characteristics in urban boundary layer in Beijing. **Environmental monitoring and assessment**, v. 22, 2012.

- MAANTAY, J. A.; MAROKO, A. R.; PORTER-MORGAN, H. A New Method for Mapping Population and Understanding the Spatial Dynamics of Disease in Urban Areas: Asthma in the Bronx, New York. **Urban Geography**, v. 29, n. 7, p. 724–738, 2013. Disponível em: <<http://www.tandfonline.com/doi/abs/10.2747/0272-3638.29.7.724>>. Acesso em: 30/11/2014.
- MACNEILL, M.; WALLACE, L.; KEARNEY, J.; et al. Factors influencing variability in the infiltration of PM<sub>2.5</sub> mass and its components. **Atmospheric Environment**, v. 61, p. 518–532, 2012.
- MADSEN, C.; GEHRING, U.; HÅBERG, S. E.; et al. Comparison of land-use regression models for predicting spatial NO<sub>x</sub> contrasts over a three year period in Oslo, Norway. **Atmospheric Environment**, v. 45, n. 21, p. 3576–3583, 2011.
- MAHOWALD, N. Aerosol indirect effect on biogeochemical cycles and climate. **Science**, v. 334, n. 6057, p. 794–6, 2011.
- MAKRI, A.; STILIANAKIS, N. Vulnerability to air pollution health effects. **International journal of hygiene and environmental health**, v. 211, n. 3-4, p. 326–336, 2008.
- MANIGRASSO, M.; AVINO, P. Fast evolution of urban ultrafine particles: Implications for deposition doses in the human respiratory system. **Atmospheric Environment**, v. 51, p. 116–123, 2012.
- MARTELLINI, T.; JONES, K. C.; SWEETMAN, A.; et al. The contribution of waste water treatment plants to PBDEs in ambient air. **Environmental pollution**, v. 169, p. 242–247, 2012.
- MASIOL, M.; SQUIZZATO, S.; CECCATO, D.; RAMPAZZO, G.; PAVONI, B. Determining the influence of different atmospheric circulation patterns on PM<sub>10</sub> chemical composition in a source apportionment study. **Atmospheric Environment**, v. 63, p. 117–124, 2012.
- MATTHIAS, V.; AULINGER, A.; BIESER, J.; et al. The ash dispersion over Europe during the Eyjafjallajökull eruption – Comparison of CMAQ simulations to remote sensing and airborne in-situ observations. **Atmospheric Environment**, v. 48, n. April 2010, p. 184–194, 2012. Elsevier Ltd.
- MCOTA. Inventário de emissões gasosas industriais na Região Centro em 2002. (O. do T. e A. Ministério das Cidades, Ed.), 2003. Coimbra.
- MCT. Inventário de GEE. Disponível em: <[www.mct.gov.br/clima](http://www.mct.gov.br/clima)>. Acesso em: 9/11/2013.
- MENDOZA, J.; WATSON, K.; BARANOWSKI, T.; NICKLAS, T.; USCANGA, D. Ethnic minority children's active commuting to school and association with physical activity and pedestrian safety behaviors. **Journal of applied research on children: informing policy for children at risk**, v. 1, n. 1, 2010.
- MENEZES, P. R.; ALMEIDA, T.; ROSA, A. N. C. S.; et al. **Introdução ao processamento de imagens de sensoriamento remoto**. 1º ed. Brasília: CNPq, 2012.

MENG, Q.; WILLIAMS, R.; PINTO, J. P. Determinants of the associations between ambient concentrations and personal exposures to ambient PM<sub>2.5</sub>, NO<sub>2</sub>, and O<sub>3</sub> during DEARS. **Atmospheric Environment**, v. 63, p. 109–116, 2012.

METCALFE, S.; DERWENT, D. **Atmospheric pollution and environmental change**. 1st ed. London: Hodder Education, 2005.

MICROSOFT. Programa de computador. **Excel (versão 10)**, 2012. Estados Unidos.

MINISTÉRIO DA SAÚDE. **Saúde ambiental**. 1st ed. Brasília: MS, 2011.

MINISTÉRIO DAS CIDADES. **Gestão integrada da mobilidade urbana**. Brasília: Ministério das Cidades, 2006.

MIRAGLIA, S. G. E. K.; VERAS, M. M.; AMATO-LOURENÇO, L. F.; RODRIGUES-SILVA, F.; SALDIVA, P. H. N. Follow-up of the air pollution and the human male-to-female ratio analysis in Sao Paulo, Brazil: a times series study. **BMJ open**, v. 3, n. 7, p. 14–19, 2013.

MIRANDA, M. J. DE; COSTA, C.; SANTANA, P.; BARROZO, L. V. Associação espacial entre variáveis socioeconômicas e risco relativo de nascimentos pré-termo na Região Metropolitana de São Paulo (RMSP) e na Área Metropolitana de Lisboa (AML). **Saúde e Sociedade**, v. 23, n. 4, p. 1142–1153, 2014. Disponível em: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0104-12902014000401142&lng=pt&nrm=iso&tlng=en](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0104-12902014000401142&lng=pt&nrm=iso&tlng=en)>. .

MISHRA, R.; PANDEY, J.; CHAUDHARY, K.; KAHLKHO, A. Estimation of air pollution concentration over Jharia coalfield based on satellite imagery of atmospheric aerosol. **International Journal of Geomatics and Geosciences**, v. 2, n. 3, p. 723–729, 2012.

MISRA, A.; ROORDA, M. J.; MACLEAN, H. L. An integrated modelling approach to estimate urban traffic emissions. **Atmospheric Environment**, v. 73, p. 81–91, 2013. Elsevier Ltd.

MITCHELL, A. **The Esri guide to GIS Analysis: geographic patterns & relationships**. 1st ed. Nova York: Esri press, 1999.

MMA. **1º Inventário nacional de emissões atmosféricas por veículos automotores rodoviários**. 1st ed. Brasília, Brasil: Ministério do Meio Ambiente, 2011.

MOLLE, R.; MAZOUÉ, S.; GÉHIN, É.; IONESCU, A. Indoor-outdoor relationships of airborne particles and nitrogen dioxide inside Parisian buses. **Atmospheric Environment**, v. 69, p. 240–248, 2013.

MÖLTER, A.; LINDLEY, S.; VOCHT, F.; et al. Performance of a microenvironmental model for estimating personal NO<sub>2</sub> exposure in children. **Atmospheric Environment**, v. 51, n. 2, p. 225–233, 2012.

MONDAL, N. K.; SAHA, S. K.; DATTA, J. K.; BANERJEE, A. Indoor Air Pollution : A Household Study in the Village Faridpur and Ranchi Colony , Durgapur , Burdwan District ,

- West Bengal. **World Journal of Environmental Pollution**, v. 1, n. 1, p. 5–7, 2011.
- MONTEIRO, C. A. F.; MENDONÇA, F. **Clima urbano**. 2. ed. São Paulo: Contexto, 2011.
- MOODLEY, K. G.; SINGH, S.; GOVENDER, S. Passive monitoring of nitrogen dioxide in urban air: a case study of Durban metropolis, South Africa. **Journal of environmental management**, v. 92, n. 9, p. 2145–2150, 2011.
- MOON, K.; DOWNES, N.; RUJNER, H.; STORCH, H. Adaptation of the Urban Structure Type Approach for Vulnerability Assessment of Climate Change Risks in Ho Chi Minh City. In: 45 TH ISOCARP CONGRESS 2009. **Anais...** . p.1–7, 2009.
- MORAL, F. J.; REBOLLO, F. J.; VALIENTE, P.; LÓPEZ, F.; MUÑOZ DE LA PEÑA, A. Modelling ambient ozone in an urban area using an objective model and geostatistical algorithms. **Atmospheric Environment**, v. 63, p. 86–93, 2012.
- MOREIRA, D.; TIRABASSI, T. Modelo matemático de dispersão de poluentes na atmosfera: um instrumento técnico para a gestão ambiental. **Ambiente & Sociedade**, v. 7, n. 2, 2004.
- MORTIMER, K.; GORDON, S. B.; JINDAL, S. K.; et al. Household air pollution is a major avoidable risk factor for cardiorespiratory disease. **Chest**, v. 142, n. 5, p. 1308–15, 2012.
- MOTTA, A.; CORRÊA, R. S. Modelo da qualidade do ar em Brasília. **Universa**, v. 6, n. 1, 1998.
- MOTTA, R. S.; ORTIZ, R. A.; FERREIRA, S. DE F. Avaliação econômica dos impactos causados pela poluição atmosférica na saúde humana: um estudo de caso para são paulo. (Cetesb, Ed.), 20AD.
- MOURA, X. J. C.; ANDRADE, A. I.; SOUSA JUNIOR, W. C.; NISHIKAWA, A. Rate of occurrence of failures based on a nonhomogeneous Poisson process: an ozone analyzer case study. **Environmental monitoring and assessment**, 2012.
- MOZUMDER, C.; REDDY, K. V.; PRATAP, D. Air pollution modeling from remotely sensed data using regression techniques. **Journal of the Indian Society of Remote Sensing**, 2012.
- MUKERJEE, S.; WILLIS, R. D.; WALKER, J. T.; et al. Seasonal effects in land use regression models for nitrogen dioxide, coarse particulate matter, and gaseous ammonia in Cleveland, Ohio. **Atmospheric Pollution Research**, v. 3, n. 3, p. 352–361, 2012.
- MULLER, E. V.; ARANHA, S. R. R.; ROZA, W. S. S. DA; GIMENO, S. G. A. Distribuição espacial da mortalidade por doenças cardiovasculares no Estado do Paraná, Brasil: 1989-1991 e 2006-2008. **Cadernos de Saúde Pública**, v. 28, n. 6, p. 1067–1077, 2012.
- NAGPURE, A. S.; GURJAR, B. R. Development and evaluation of Vehicular Air Pollution Inventory model. **Atmospheric Environment**, v. 59, p. 160–169, 2012. Elsevier Ltd.

- NAKAGAWA, L.; COMARU, F. DE A.; TRIGOSO, F. B. M. Geração de energia e seus impactos socioambientais: o caso da UTE Piratininga. **Revista Brasileira de Energia**, v. 19, n. 1, p. 29–47, 2013.
- NANDASENA, S.; WICKREMASINGHE, A. R.; SATHIAKUMAR, N. Respiratory Health Status of Children From Two Different Air Pollution Exposure Settings of Sri Lanka : A Cross-Sectional Study. **American Journal of Industrial Medicine**, 2012.
- NARDO, F. DI; SAULLE, R.; TORRE, G. LA. Green areas and health outcomes: a systematic review of the scientific literature. **Epidemiology biostatistics and public health**, v. 7, n. 4, 2010.
- NATAL, D. Fundamentos de epidemiologia. In: A. Philippi; M. de A. Romero; G. C. Bruna (Eds.); **Curso de Gestão Ambiental**. 1º ed., p.375–410, 2004. Barueri, São Paulo: Manole.
- NICOLE, W. Air Pollution and Diabetes Risk. **Environmental Health Perspectives**, v. 123, n. 5, p. 901689, 2015.
- NIELSEN, T. S.; HANSEN, K. B. Do green areas affect health? Results from a Danish survey on the use of green areas and health indicators. **Health & place**, v. 13, n. 4, p. 839–850, 2007.
- NIEUWSTADT, F. T. M. Distribution - part II . The gaussian plume model. **Atmospheric Environment (1967)**, v. 14, n. 1976, p. 259–265, 1980.
- NING, Z.; WUBULIHAIREN, M.; YANG, F. PM, NO<sub>x</sub> and butane emissions from on-road vehicle fleets in Hong Kong and their implications on emission control policy. **Atmospheric Environment**, v. 61, n. 2, p. 265–274, 2012.
- NORDIO, F.; ZANOBETTI, A.; COLICINO, E.; KLOOG, I.; SCHWARTZ, J. Changing patterns of the temperature–mortality association by time and location in the US, and implications for climate change. **Environment international**, v. 81, n. 80, p. 80–86, 2015.
- NOWAK, D. J.; HEISLER, G. M. Air quality effects of urban trees and parks. , 2010. National Recreation and Park Association. Disponível em: <[www.nrpa.org](http://www.nrpa.org)>. .
- O’NEILL, S. M.; LAHM, P. W.; FITCH, M. J.; BROUGHTON, M. Summary and analysis of approaches linking visual range, PM<sub>2.5</sub> concentrations, and air quality health impact indices for wildfires. **Journal of the Air & Waste Management Association**, v. 63, n. 9, 2013.
- O’TOOLE, T.; CONKLIN, D.; BHATNAGAR, A. Environmental risk factors for heart disease. **Reviews on environmental health**, v. 23, n. 3, p. 167–202, 2008.
- OKADA, H.; KUHN, C.; FEILLET, H.; BACH, J. F. The “hygiene hypothesis” for autoimmune and allergic diseases: An update. **Clinical and Experimental Immunology**, v. 160, n. 1, p. 1–9, 2010.



- OLIVEIRA, B. F. A. DE; IGNOTTI, E.; ARTAXO, P.; et al. Risk assessment of PM<sub>2.5</sub> to child residents in Brazilian Amazon region with biofuel production. **Environmental health**, v. 11, n. 64, p. 1–11, 2012.
- OLIVIÉ, D. J. L.; CARIOLLE, D.; TEYSSÈDRE, H.; et al. Modeling the climate impact of road transport, maritime shipping and aviation over the period 1860–2100 with an AOGCM. **Atmospheric Chemistry and Physics**, v. 12, n. 3, p. 1449–1480, 2012.
- OLSZAK, T.; AN, D.; ZEISSIG, S.; et al. Microbial Exposure During Early Life Has Persistent Effects on Natural Killer T Cell Function. **Science**, v. 336, n. 6080, p. 489–493, 2012.
- OMS. **Guidelines for indoor air quality**. 1st ed. Copenhagen: OMS, 2010.
- OMS. Outdoor air pollution a leading environmental cause of cancer deaths. (OMS, Ed.), 2013. Geneva. Disponível em: <[http://www.iarc.fr/en/media-centre/iarcnews/pdf/pr221\\_E.pdf](http://www.iarc.fr/en/media-centre/iarcnews/pdf/pr221_E.pdf)>. .
- PADRÓ-MARTÍNEZ, L. T.; PATTON, A. P.; TRULL, J. B.; et al. Mobile monitoring of particle number concentration and other traffic-related air pollutants in a near-highway neighborhood over the course of a year. **Atmospheric Environment**, v. 61, p. 253–264, 2012.
- PANT, P. P.; TRIPATHI, A. K. Analysis of some biochemical parameters of plants as indicator of air pollution. **Journal of environmental science, computer science and engineering & technology**, v. 1, n. 1, p. 14–21, 2012.
- PAOLI, L.; MUNZI, S.; FIORINI, E.; GAGGI, C.; LOPPI, S. Influence of angular exposure and proximity to vehicular traffic on the diversity of epiphytic lichens and the bioaccumulation of traffic-related elements. **Environmental science and pollution research international**, 2012.
- PARK, D.; OH, M.; YOON, Y.; PARK, E.; LEE, K. Source identification of PM<sub>10</sub> pollution in subway passenger cabins using positive matrix factorization. **Atmospheric Environment**, v. 49, p. 180–185, 2012.
- PARK, S. S.; SIM, S. Y.; BAE, M.-S.; SCHAUER, J. J. Size distribution of water-soluble components in particulate matter emitted from biomass burning. **Atmospheric Environment**, v. 73, p. 62–72, 2013. Elsevier Ltd.
- PAULA SANTOS, U.; BRAGA, A. L. F.; GIORGI, D. M. A.; et al. Effects of air pollution on blood pressure and heart rate variability: a panel study of vehicular traffic controllers in the city of São Paulo, Brazil. **European heart journal**, v. 26, n. 2, p. 193–200, 2005.
- PAULEIT, S.; DUHME, F. Assessing the environmental performance of land cover types for urban planning. **Landscape and Urban Planning**, v. 52, p. 1–20, 2000.
- PENG, J.; DONG, W.; YUAN, W.; et al. Effects of increased CO<sub>2</sub> on land water balance from 1850 to 1989. **Theoretical and Applied Climatology**, 2012.

- PETÄJÄ, T.; LAAKSO, L.; GRÖNHOLM, T.; et al. In-situ observations of Eyjafjallajökull ash particles by hot-air balloon. **Atmospheric Environment**, v. 48, p. 104–112, 2012.
- PHALEN, R. F. **Introduction to air pollution science: a public health perspective**. 1st ed. Burlington: Alpha Press, 2012a.
- PHALEN, R. F. **Introduction to air pollution science: a public health perspective**. 1st ed. Burlington: Alpha Press, 2012b.
- PIRJOLA, L.; LÄHDE, T.; NIEMI, J. V.; et al. Spatial and temporal characterization of traffic emissions in urban microenvironments with a mobile laboratory. **Atmospheric Environment**, v. 63, p. 156–167, 2012.
- PONGRATZ, J.; CALDEIRA, K. Attribution of atmospheric CO<sub>2</sub> and temperature increases to regions: importance of preindustrial land use change. **Environmental research letters**, v. 7, 2012.
- POULSEN, E.; KENNEDY, L. W. Using Dasymetric Mapping for Spatially Aggregated Crime Data. **Journal of Quantitative Criminology**, v. 20, n. 3, p. 243–263, 2004.
- POULSEN, E.; KENNEDY, L. W.; FREITAS, M. DE B. C.; XAVIER, A. M. DE S.; FRAGOSO, R. M. DE S. Using Dasymetric Mapping for Spatially Aggregated Crime Data. **Agricultural and Resource Economics Review**, v. 3, n. 3, p. 243–263, 2004.
- POWELL, H.; LEE, D.; BOWMAN, A. Estimating constrained concentration-response functions between air pollution and health. **Environmetrics**, v. 23, n. 3, p. 228–237, 2011.
- POWELL, L. M.; SLATER, S.; CHALOUPKA, F. J. The relationship between community physical activity settings and race, ethnicity and socioeconomic status. **Evidence-Based Preventive Medicine**, v. 1, n. 2, p. 135–144, 2004.
- POWER, M. C.; KIOUMOURTZOGLOU, M. -A.; HART, J. E.; et al. The relation between past exposure to fine particulate air pollution and prevalent anxiety: observational cohort study. **Bmj**, v. 350, 2015. Disponível em: <<http://www.bmj.com/content/350/bmj.h1111>>. .
- POZZER, A.; ZIMMERMANN, P.; DOERING, U. M.; et al. Effects of business-as-usual anthropogenic emissions on air quality. **Atmospheric Chemistry and Physics**, v. 12, n. 15, p. 6915–6937, 2012.
- PRESS, F.; GROTZINGER, J.; SIEVER, R.; JORDAN, T. H. **Para entender a Terra**. 4th ed. Porto Alegre: Bookman, 2006.
- QUIROS, D. C.; ZHANG, Q.; CHOI, W.; et al. Air quality impacts of a scheduled 36-h closure of a major highway. **Atmospheric Environment**, v. 67, p. 404–414, 2013. Elsevier Ltd.
- R CORE TEAM. Programa de computador. **R: a language and environment for statistical computing (versão 2.10.1)**, 2013. Austria.

- RAITH, E. **Stadtmorphologie: Annäherungen, Umsetzungen, Aussichten**. Alemanha, 2000.
- REICH, B.; FUENTES, M.; DUNSON, D. Bayesian spatial quantile regression. **American Statistical Association**, v. 106, n. 493, p. 6–20, 2011.
- REIS, L. B.; FADIGAS, E. A.; CARVALHO, C. E. **Energia, Recursos Naturais e a Prática do Desenvolvimento Sustentável**. 1º ed. Barueri, São Paulo: Manole, 2005.
- REIS, S.; GRENNFELT, P.; KLIMONT, Z.; et al. From Acid Rain to Climate Change. **Science**, v. 338, p. 1153–1152, 2012.
- REISEN, F.; MEYER, C. P. (MICK); KEYWOOD, M. D. Impact of biomass burning sources on seasonal aerosol air quality. **Atmospheric Environment**, v. 67, p. 437–447, 2013. Elsevier Ltd.
- RÉQUIA JÚNIOR, W. J.; ABREU, L. M. Poluição atmosférica e a saúde de crianças e idosos no Distrito Federal no período de 2007 a 2009: utilização do método de correlação com time delay. **Revista Brasileira de Geografia Médica e da Saúde - Hygeia**, v. 7, n. 13, p. 95–108, 2011.
- RIBEIRO, H.; CARDOSO, M. R. A. Air pollution and children's health in São Paulo (1986–1998). **Social Science & Medicine**, v. 57, n. 11, p. 2013–2022, 2003.
- RIGHI, S.; FARINA, F.; MARINELLO, S.; et al. Development and evaluation of emission disaggregation models for the spatial distribution of non-industrial combustion atmospheric pollutants. **Atmospheric Environment**, v. 79, p. 85–92, 2013. Elsevier Ltd.
- RIVERA, M.; BASAGAÑA, X.; AGUILERA, I.; et al. Spatial distribution of ultrafine particles in urban settings: a land use regression model. **Atmospheric Environment**, v. 54, p. 657–666, 2012.
- ROADMAN, M. .; SCUDLARK, J. .; MEISINGER, J. .; ULLMAN, W. . Validation of Ogawa passive samplers for the determination of gaseous ammonia concentrations in agricultural settings. **Atmospheric Environment**, v. 37, n. 17, p. 2317–2325, 2003.
- ROBAA, S. M. Effect of Urbanization and Industrialization Processes on Outdoor Thermal Human Comfort in Egypt. **Atmospheric and Climate Sciences**, v. 01, n. 03, p. 100–112, 2011.
- RODRIGUEZ, L. M.; BIERINGER, P. E.; WARNER, T. Urban transport and dispersion model sensitivity to wind direction uncertainty and source location. **Atmospheric Environment**, v. 64, p. 25–39, 2013.
- ROSENLUND, M.; FORASTIERE, F.; STAFOGGIA, M.; et al. Comparison of regression models with land-use and emissions data to predict the spatial distribution of traffic-related air pollution in Rome. **Journal of exposure science & environmental epidemiology**, v. 18, n. 2, p. 192–9, 2008.

- ROSENLUND, M.; PICCIOTTO, S.; FORASTIERE, F.; STAFOGGIA, M.; PERUCCI, C. A. Traffic-related air pollution in relation to incidence and prognosis of coronary heart disease. **Epidemiology**, v. 19, n. 1, p. 121–8, 2008.
- ROY, B.; VINCKE, P. Relational systems of preference with one or more pseudo-criteria: some new concepts and results. **Management Science**, v. 30, n. 11, 1984.
- RUNDELL, K. W. Effect of air pollution on athlete health and performance. **British journal of sports medicine**, v. 46, n. 6, p. 407–12, 2012.
- RYAN, P. H.; LEMASTERS, G. K. A review of land-use regression models for characterizing intraurban air pollution exposure. **Inhalation toxicology**, v. 19, p. 127–33, 2007.
- SAATY, T. L. How to make a decision: the analytic hierarchy process. **European Journal of Operational Research**, v. 48, n. 1, p. 9–26, 1990.
- SAATY, T. L. **Método de Análise Hierárquica**. São Paulo: Makron Books, 1991.
- SABALIAUSKAS, K.; JEONG, C.-H.; YAO, X.; et al. Five-year roadside measurements of ultrafine particles in a major Canadian city. **Atmospheric Environment**, v. 49, p. 245–256, 2012.
- SAEB, K.; MALEKZADEH, M.; KARDAR, S. Air Pollution Estimation from traffic flows in Tehran highways. **Current World Environment**, v. 7, n. 1, p. 1–6, 2012.
- SALLIS, J.; FLOYD, M.; RODRÍGUEZ, D.; SAELENS, B. The role of built environments in physical activity, obesity, and CVD. **Circulation**, v. 125, n. 5, 2012.
- SAMPSON, R.; MORENOFF, J.; GANNON-ROWLEY, T. Assessing “Neighborhood effects”: social processes and new directions in research. **Annual reviews of sociology**, v. 28, p. 443–478, 2002.
- SÁNCHEZ, L. E. **Avaliação de impacto ambiental**. 1º ed. São Paulo: Oficina de textos, 2008.
- SANTANA, E.; CUNHA, K. B.; FERREIRA, A. L.; ZAMBONI, A. **Padrões de qualidade do ar: experiência comparada Brasil, EUA e União Europeia**. 1º ed. Brasília: Instituto de Energia e Meio Ambiente, 2012.
- SANTOS, O. M.; GUEDES, M. L. S.; ARAÚJO, C. V. M. Potencial de espécies vegetais nativas do pólo industrial de Camaçari (BA, Brasil) como acumuladoras de elementos químicos contidos na poluição atmosférica. **Journal of the Brazilian Society of Ecotoxicology**, v. 7, n. 1, p. 15–20, 2012.
- SARKHOSH, M.; MAHVI, A. H.; ZARE, M. R.; FAKHRI, Y.; SHAMSOLAHI, H. R. Indoor contaminants from Hardcopy Devices: Characteristics of VOCs in photocopy centers. **Atmospheric Environment**, v. 63, p. 307–312, 2012.

- ŠAUER, P.; MÁDR, M. ECONOMIC GROWTH AND AIR POLLUTION IN THE CZECH REPUBLIC: DECOUPLING CURVES. **International Journal of Economics and finance studies**, v. 4, n. 2, p. 205–213, 2012.
- SAYEGH, S. P. Forest biomonitoring of the largest Slovene thermal power plant with respect to reduction of air pollution. **Environmental monitoring and assessment**, , n. 2010, 2012.
- SCOGGINS, A.; KJELLSTROM, T.; FISHER, G.; CONNOR, J.; GIMSON, N. Spatial analysis of annual air pollution exposure and mortality. **The Science of the total environment**, v. 321, n. 1-3, p. 71–85, 2004.
- SEDF. Censo escolar. Disponível em: <[www.sesdf.gov.br](http://www.sesdf.gov.br)>. Acesso em: 11/12/2012.
- SEDHAB. Base de dados: **organização territorial do Distrito Federal**, 2012. Brasília.
- SEDUMA. Zoneamento ecológico-econômico do Distrito Federal. (GDF, Ed.), 2009. Brasília. Disponível em: <<http://www.zee-df.com.br>>. .
- SEMOB. Terminais. Disponível em: <[www.semob.df.gov.br/informacoes/terminais.html](http://www.semob.df.gov.br/informacoes/terminais.html)>. Acesso em: 15/8/2013.
- SHAH, S. A. Use of Geographic Information System in Land Use Studies : a micro level analysis. **European Journal of Applied Sciences**, v. 4, n. 3, p. 123–128, 2012.
- SILVA, A. P. DA; MORATO, R. G.; KAWAKUBO, F. S. Mapeamento da distribuição espacial da população utilizando o método dasimétrico: exemplo de caso no Sudeste do Brasil. **Revista Brasileira de Geografia Física**, v. 06, n. 01, p. 37–48, 2013.
- SILVA, C. B. P.; SALDIVA, P. H. N.; AMATO-LOURENÇO, L. F.; RODRIGUES-SILVA, F.; MIRAGLIA, S. G. E. K. Evaluation of the air quality benefits of the subway system in São Paulo, Brazil. **Journal of environmental management**, v. 101, p. 191–6, 2012.
- SILVA, J. X.; ZAIDAN, R. T. **Geoprocessamento & Meio Ambiente**. Rio de Janeiro: Bertrand Brasil, 2011.
- SILVA, R. G.; LIMA, J. E. Avaliação econômica da poluição do ar na Amazônia Ocidental: um estudo de caso do Estado do Acre. **Revista de estudos regionais**, v. 44, n. 02, p. 157–178, 2006.
- SILVA, T. N.; FREITAS, F. S. N. DE; CANDIANI, G. Avaliação das emissões superficiais do gás de aterros sanitários de grande porte. **Engenharia Sanitária e Ambiental**, v. 18, n. 2, p. 95–104, 2013.
- SINGH, A.; PALAZOGLU, A. Climatic variability and its influence on ozone and PM pollution in 6 non-attainment regions in the United States. **Atmospheric Environment**, v. 51, p. 212–224, 2012.
- SINGH, R. B.; KUMAR, D. Remote sensing and GIS for land use/cover mapping and integrated land management: case from the middle Ganga plain. **Earth Science**, 2012.

- SINGHE, A. L.; JAMAL, S. A study of risk factors associated with indoor air pollution in the low income households in Aligarh city , India. **Journal environmental research and management**, v. 3, n. 1, p. 1–8, 2012a.
- SINGHE, A. L.; JAMAL, S. Assessing vulnerability of women to indoor air pollution. **Research Journal fo Environmental and Earth Sciences**, v. 4, n. 11, p. 982–989, 2012b.
- SLAMA, R.; DARROW, L.; PARKER, J.; et al. Meeting report: Atmospheric pollution and human reproduction. **Environmental Health Perspectives**, v. 116, n. 6, p. 791–798, 2008.
- SLEZAKOVA, K.; CASTRO, D.; DELERUE–MATOS, C.; et al. Impact of vehicular traffic emissions on particulate-bound PAHs: Levels and associated health risks. **Atmospheric Research**, v. 127, p. 141–147, 2013. Elsevier B.V.
- SMITH, M.; GOODCHILD, M.; LONGLEY, P. **Geospatial Analysis: a comprehensive guide to principles, techniques and software tools**. Second ed. Leicester: Matador, 2007.
- SMITH, T.; KRIEBEL, D. **A biologic approach to environmental assessment and epidemiology**. 1st ed. New York: Oxford University Press, 2010.
- SNOW, J. Snow on cholera: a reprint of two papers. , 1936. Nova York: Hafner publishing company.
- SO, K. L.; WANG, T. On the local and regional influence on ground-level ozone concentrations in Hong Kong. **Environmental pollution**, v. 123, p. 307–317, 2003.
- SOKHI, R. S. **World Atlas of Atmospheric Pollution**. 1st ed. Nova York: Anthen press, 2011.
- SOLOMON, P. A.; COSTANTINI, M.; GRAHAME, T. J.; et al. **Air pollution and health: bridging the gap from sources to health outcomes: conference summary**. USA: Air quality atmospheric health, 2011.
- SPEDDING, D. J. **Contaminación atmosférica**. Barcelona: Reverté, 2002.
- SRIVASTAVA, K. P.; KUMAR, S. V. Impact of Air-Pollution on pH of soil of Saran , Bihar , India. **Research Journal of Recent Sciences**, v. 1, n. 4, p. 9–13, 2012.
- STEINKE, E. T. **Climatologia fácil**. 1. ed. São Paulo: Oficina de textos, 2012.
- SU, J. G.; JERRETT, M.; BECKERMAN, B. A distance-decay variable selection strategy for land use regression modeling of ambient air pollution exposures. **The Science of the total environment**, v. 407, n. 12, p. 3890–3898, 2009.
- SU, J. G.; JERRETT, M.; BECKERMAN, B.; et al. Predicting traffic-related air pollution in Los Angeles using a distance decay regression selection strategy. **Environmental research**, v. 109, n. 6, p. 657–70, 2009. Elsevier.
- SZKLO, M.; NIETO, J. **Epidemiology beyond the basics**. 1st ed. Maryland: An Aspen Publication, 2000.

- TANG, Y. S.; CAPE, J. N.; SUTTON, M. A. Development and types of passive samplers for monitoring atmospheric NO<sub>2</sub> and NH<sub>3</sub> concentrations. **The Scientific World Journal**, v. 1, n. 2, p. 513–529, 2001.
- TARSO, P.; OLIVEIRA, S. DE; BUCHALA, D.; et al. Processo analítico hierárquico aplicado à vulnerabilidade natural à erosão. **Geociências**, v. 28, n. 4, p. 417–424, 2009.
- TASDEMIR, Y.; SALIHOGLU, G.; SALIHOGLU, N. K.; BIRGÜL, A. Air-soil exchange of PCBs: Seasonal variations in levels and fluxes with influence of equilibrium conditions. **Environmental pollution**, v. 169, p. 90–97, 2012.
- TAYRA, F.; RIBEIRO, H.; NARDOCCI, A. DE C. Avaliação Econômica dos Custos da Poluição em Cubatão - SP com Base nos Gastos com Saúde Relacionados às Doenças dos Aparelhos Respiratório e Circulatório. **Saúde Sociedade**, v. 21, n. 3, p. 760–775, 2012.
- THAMBAVANI, S.; PRATHIPA, V. Bio monitoring of air pollution around urban and industrial sites. **Journal of Research in biology**, v. 2, n. 1, 2012.
- THEPANONDH, S.; TORUKSA, W. Proximity analysis of air pollution exposure and its potential risk. **Journal of environmental monitoring**, v. 13, n. 5, p. 1264–70, 2011.
- TIAN, N.; WILSON, G.; ZHAN, B. Female breast cancer mortality clusters within racial groups in the United States. **Health & Place**, v. 16, n. 2, p. 209–218, 2010.
- TOBLER, W. A computer movie simulating urban growth in the Detroit region. **Economic Geography**, v. 46, n. 2, p. 234–240, 1970.
- TOLEDO, G. I. F. M.; NARDOCCI, A. C. Poluição veicular e saúde da população : uma revisão sobre o município de São Paulo ( SP ), Brasil. **Revista Brasileira Epidemiologia**, v. 14, n. 3, p. 445–454, 2011.
- TORRICELLI, A. A. M.; MATSUDA, M.; NOVAES, P.; et al. Effects of ambient levels of traffic-derived air pollution on the ocular surface: Analysis of symptoms, conjunctival goblet cell count and mucin 5AC gene expression. **Environmental Research**, v. 131, p. 59–63, 2014.
- TOURI, L.; MARCHETTI, H.; SARI-MINODIER, I.; MOLINARI, N.; CHANEZ, P. The airport atmospheric environment: respiratory health at work. **European Respiratory Review**, v. 22, n. 128, p. 124–130, 2013.
- TRAN, L. T.; KNIGHT, C. G.; O'NEILL, R. V; et al. Fuzzy decision analysis for integrated environmental vulnerability assessment of the mid-Atlantic Region. **Environmental management**, v. 29, n. 6, p. 845–859, 2002.
- TRASANDE, L.; THURSTON, G. D. The role of air pollution in asthma and other pediatric morbidities. **The Journal of allergy and clinical immunology**, v. 115, n. 4, p. 689–99, 2005.

TRONCOSO, R.; CIFUENTES, L. A. Effects of environmental alerts and pre-emergencies on pollutant concentrations in Santiago, Chile. **Atmospheric Environment**, v. 61, p. 550–557, 2012.

TSAI, S.; YANG, Y.; LIOU, S.; WU, T.; YANG, C. Air pollution and hospital admissions for chronic obstructive pulmonary disease : are their potentially sensitive groups ? **Advances in Environmental Research**, v. 1, n. 1, p. 57–68, 2012.

TURNER, D. B. **Workbook of atmospheric dispersion estimates: an introduction to dispersion modeling**. 2nd ed. Ohio: CRC Press, 1970.

UBA. Air monitoring networks. Disponível em:  
<<http://www.umweltbundesamt.de/en/topics/air/measuringobservingmonitoring/air-monitoring-networks>>. Acesso em: 26/2/2013.

UEDA, A. C.; TOMAZ, E. Inventário de emissão de fontes veiculares da região metropolitana de Campinas, São Paulo. **Química Nova**, v. 34, n. 9, p. 1496–1500, 2011.

UPTON, G.; COOK, I. **Understanding Statistics**. 1st ed. Londres: Oxford University Press, 1996.

VALDÉS, A.; ZANOBETTI, A.; HALONEN, J. I.; et al. Elemental concentrations of ambient particles and cause specific mortality in Santiago, Chile: a time series study. **Environmental health**, v. 11, n. 82, 2012.

VARGAS, F. A.; ROJAS, N. Y.; PACHON, J. E.; RUSSELL, A. G. PM10 characterization and source apportionment at two residential areas in Bogota. **Atmospheric Pollution Research**, v. 3, n. 1, p. 72–80, 2012.

VASCONCELLOS, E. A. **Transporte e meio ambiente**. 1. ed. São Paulo: Annablume, 2006.

VERAS, M. M.; CALDINI, E. G.; DOLHNIKOFF, M.; SALDIVA, P. H. N. Air pollution and effects on reproductive-system functions globally with particular emphasis on the Brazilian population. **Journal of toxicology and environmental health. Part B, Critical reviews**, v. 13, n. 1, p. 1–15, 2010.

VERSTRAETEN, W.; NEU, J.; WILLIAMS, J.; et al. Rapid increases in tropospheric ozone production and export from China. **Nature geoscience**, v. 38, n. 23, 2015.

VESILIND, A.; MORGAN, S. **Introdução à Engenharia Ambiental**. 2nd ed. São Paulo: Cengage Learning, 2011.

VILLANUEVA, K.; PEREIRA, G.; KNUIMAN, M.; et al. The impact of the built environment on health across the life course: design of a cross-sectional data linkage study. **BMJ open**, v. 3, p. 1–7, 2013.



- VLACHOKOSTAS, C.; ACHILLAS, C.; MOUSSIOPOULOS, N.; et al. Decision support system for the evaluation of urban air pollution control options: application for particulate pollution in Thessaloniki, Greece. **Science of the total environment**, v. 407, n. 23, p. 5937–5948, 2009.
- VLACHOKOSTAS, C.; NASTIS, S. A.; ACHILLAS, C.; et al. Economic damages of ozone air pollution to crops using combined air quality and GIS modelling. **Atmospheric Environment**, v. 44, n. 28, p. 3352–3361, 2010. Elsevier Ltd.
- WAI, T.; WAI, W.; TAM, S.; et al. Developing a risk-based air quality health index. **Atmospheric Environment**, v. 76, p. 52–58, 2013. Elsevier Ltd.
- WALL, M.; LARSON, N.; FORSYTH, A.; et al. Patterns of Obesogenic Neighborhood Features and Adolescent Weight: A comparison of statistical approaches. **American Journal of Preventive Medicine**, v. 42, n. 5, 2012.
- WALLACE, H. W.; JOBSON, B. T.; ERICKSON, M. H.; et al. Comparison of wintertime CO to NO<sub>x</sub> ratios to MOVES and MOBILE6.2 on-road emissions inventories. **Atmospheric Environment**, v. 63, p. 289–297, 2012.
- WALLACE, J.; CORR, D.; DELUCA, P.; KANAROGLOU, P.; MCCARRY, B. Mobile monitoring of air pollution in cities: the case of Hamilton, Ontario, Canada. **Journal of environmental monitoring**, v. 11, n. 5, p. 998–1003, 2009.
- WANG, D. G.; YANG, M.; JIA, H. L.; ZHOU, L.; LI, Y. F. Levels, distributions and profiles of polychlorinated biphenyls in surface soils of Dalian, China. **Chemosphere**, v. 73, p. 38–42, 2008.
- WANG, G.; MACERA, C. A.; SCUDDER-SOUCIE, B.; et al. A cost-benefit analysis of physical activity using bike/pedestrian trails. **Health Promotion Practice**, v. 6, n. 2, 2005.
- WANG, J.-D. **Basic principles and practical applications in epidemiological research**. 1st ed. Singapore: World Scientific, 2002.
- WANG, Q.; BI, X.-H.; WU, J.-H.; ZHANG, Y.-F.; FENG, Y.-C. Heavy metals in urban ambient PM(10) and soil background in eight cities around China. **Environmental monitoring and assessment**, , n. 2002, 2012.
- WANG, Q.; CHEN, J.; TIAN, Y. Remote sensing image interpretation study serving urban planning based on GIS. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXVII, n. Part B4, p. 453–456, 2008.
- WANG, Q.; YUAN, X.; LAI, Y.; MA, C.; REN, W. Research on interactive coupling mechanism and regularity between urbanization and atmospheric environment: a case study in Shandong Province, China. **Stochastic Environmental Research and Risk Assessment**, v. 2, n. 1955, 2012.

WANG, R.; HENDERSON, S. B.; SBIHI, H.; ALLEN, R. W.; BRAUER, M. Temporal stability of land use regression models for traffic-related air pollution. **Atmospheric Environment**, v. 64, p. 312–319, 2013.

WEBER, N.; HAASE, D.; FRANCK, U. Zooming into temperature conditions in the city of Leipzig: How do urban built and green structures influence earth surface temperatures in the city? **Science of the total environment**, v. 496, p. 289–298, 2014a.

WEBER, N.; HAASE, D.; FRANCK, U. Assessing modelled outdoor traffic-induced noise and air pollution around urban structures using the concept of landscape metrics. **Landscape and Urban Planning**, v. 125, p. 105–116, 2014b.

WHO. 7 million premature deaths annually linked to air pollution. Disponível em: <<http://www.who.int/mediacentre/news/releases/2014/air-pollution/en/>>. .

WHO. Global Health Observatory. Disponível em: <[http://www.who.int/gho/ncd/mortality\\_morbidity/en/](http://www.who.int/gho/ncd/mortality_morbidity/en/)>. Acesso em: 10/6/2014b.

WILLIAMS, J. E.; WEELE, M. VAN; VELTHOVEN, P. F. J. VAN; et al. The Impact of Uncertainties in African Biomass Burning Emission Estimates on Modeling Global Air Quality, Long Range Transport and Tropospheric Chemical Lifetimes. **Atmosphere**, v. 3, p. 132–163, 2012.

WILLIAMS, L. A.; ULRICH, C. M.; LARSON, T.; et al. Proximity to traffic, inflammation, and immune function among women in the Seattle, Washington, Area. **Environmental Health Perspectives**, v. 117, n. 3, p. 373–378, 2009.

WILSON, A. M.; SALLOWAY, J. C.; WAKE, C. P.; KELLY, T. Air pollution and the demand for hospital services: a review. **Environment international**, v. 30, n. 8, p. 1109–18, 2004.

WU, Q.; HAN, G.; TAO, F.; TANG, Y. Chemical composition of rainwater in a karstic agricultural area, Southwest China: The impact of urbanization. **Atmospheric Research**, v. 111, p. 71–78, 2012.

XIA, T.-Y.; WANG, J.; SONG, K.; DA, L. Variations in air quality during rapid urbanization in Shanghai, China. **Landscape Ecology**, v. 10, p. 181–190, 2014. 328.

XIAO, Z.; WU, J.; HAN, S.; et al. Vertical characteristics and source identification of PM10 in Tianjin. **Journal of Environmental Sciences**, v. 24, n. 1, p. 112–115, 2012.

XU, Z.; HU, W.; WILLIAMS, G.; et al. Air pollution, temperature and pediatric influenza in Brisbane, Australia. **Environment international**, v. 59, p. 384–388, 2013.

YAMAMOTO, J. K.; LANDIM, P. B. **Geoestatística: conceitos e aplicações**. 1st ed. São Paulo: Oficina de textos, 2013.

YANNOPOULOS, P. C. Quick and economic spatial assessment of urban air quality. In: F. Nejadkoorki (Ed.); **Advance air pollution**. 1st ed., p.391–428, 2011. Croatia: InTech.

- YEN, I. H.; SYME, L. The Social Environment and Health: A Discussion of the Epidemiologic Literature. **Annual review of Public Health**, v. 20, p. 287–308, 1999.
- YERRAMILI, A.; DODLA, V. B. R.; YERRAMILI, S. Air pollution, modeling and GIS based decision support systems for air quality risk assessment. In: F. Nejadkoorki (Ed.); **Advance air pollution**. 1st ed., p.295–324, 2011. Croatia.
- YIM, S. H. L.; STETTLER, M. E. J.; BARRETT, S. R. H. Air quality and public health impacts of UK airports. Part II: Impacts and policy assessment. **Atmospheric Environment**, v. 67, p. 184–192, 2013. Elsevier Ltd. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1352231012009818>>. Acesso em: 15/3/2013.
- YOUSSEF, H.; LIOUSSE, C.; ASSAMOI, E.; et al. Quantifying wildfires exposure for investigating health-related effects. **Atmospheric Environment**, v. 97, p. 239–251, 2014.
- YU, H. L.; LIN, Y.-C.; SIVAKUMAR, B.; KUO, Y.-M. A study of the temporal dynamics of ambient particulate matter using stochastic and chaotic techniques. **Atmospheric Environment**, v. 69, p. 37–45, 2013.
- ZANDBERGEN, P. A; GREEN, J. W. Error and bias in determining exposure potential of children at school locations using proximity-based GIS techniques. **Environmental Health Perspectives**, v. 115, n. 9, p. 1363–1370, 2007.
- ZANOBETTI, A.; SCHWARTZ, J. The effect of fine and coarse particulate air pollution on mortality: a national analysis. **Environmental health perspectives**, v. 117, n. 6, p. 898–903, 2009.
- ZHANG, Q.; FISCHER, H. J.; WEISS, R. E.; ZHU, Y. Ultrafine particle concentrations in and around idling school buses. **Atmospheric Environment**, v. 69, n. 2, p. 65–75, 2013.
- ZHAO, M.; ZHANG, Y.; MA, W.; et al. Characteristics and ship traffic source identification of air pollutants in China's largest port. **Atmospheric Environment**, v. 64, p. 277–286, 2013.
- ZHENG, J.; FENG, X.; LIU, P.; ZHONG, L.; LAI, S. Site location optimization of regional air quality monitoring network in China: methodology and case study. **Journal of environmental monitoring**, v. 13, n. 11, p. 3185–3195, 2011.
- ZHOU, Y.; LEVY, J. Factors influencing the spatial extent of mobile source air pollution impacts: a meta-analysis. **BMC Public health**, v. 7, n. 89, p. 1–11, 2007.
- ŽIBERT, J.; PRAŽNIKAR, J. Cluster analysis of particulate matter (PM10) and black carbon (BC) concentrations. **Atmospheric Environment**, v. 57, p. 1–12, 2012.
- ZOU, B.; PENG, F.; WAN, N.; MAMADY, K.; WILSON, G. JS. C. D. OF A. P. E. I. ACROSS THE U. S. Spatial Cluster Detection of Air Pollution Exposure Inequities across the United States. **PloS one**, v. 9, n. 3, 2014.
- ZOU, B.; WILSON, J. G.; ZENG, Y. Air pollution exposure assessment methods utilized in epidemiological studies. **Journal of environmental monitoring**, v. 11, p. 475–490, 2009.

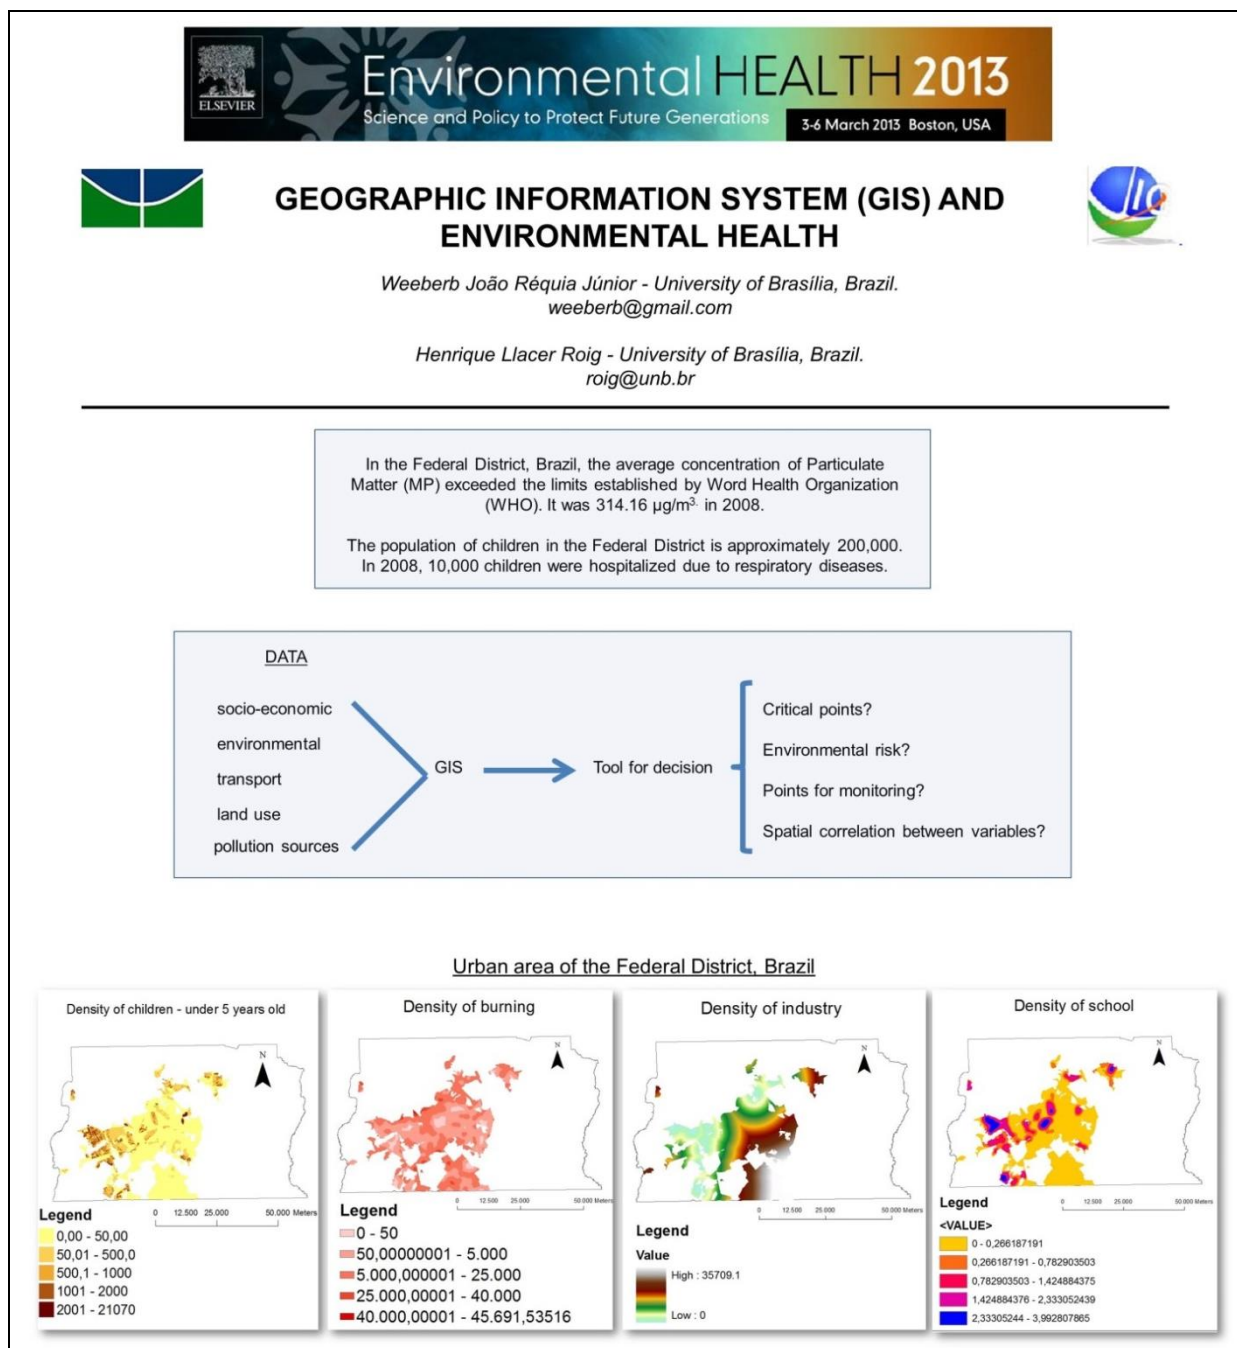
## Apêndices.

---

### **APÊNDICE A – PUBLICAÇÃO EM EVENTOS**


## A.1. ENVIRONMENTAL HEALTH, BOSTON, USA, 2013

### A.1.1. Geographic Information System (GIS) and environmental health





## A.2. URBAN ENVIRONMENTAL POLLUTION, TORONTO, CANADÁ, 2014


### A.2.1. Multi-criteria model in GIS for determination of sampling points of air pollution



**Urban Environmental Pollution**  
12 – 15 June 2014 • Toronto, Canada  
CLIMATE CHANGE AND URBAN ENVIRONMENT







### MULTI-CRITERIA MODEL IN GEOGRAPHIC INFORMATION SYSTEMS FOR DETERMINATION OF SAMPLING POINTS OF AIR POLLUTION

*Weeberb João Réquia Júnior – University of Brasília, Brazil – weeberb@gmail.com*  
*Henrique Llacer Roig - University of Brasília, Brazil - roig@unb.br*

**INTRODUCTION**

Government has mobilized to invest in the monitoring of air quality, as well as the identification of its actual impact on human health. The investment is directed towards the deployment of an efficient monitoring network, representative for each study area. However, many urban areas still have poor networks, often without monitored air quality. For example, in the Federal District of Brazil (FD), the monitoring network is still incomplete and not representative of the reality of the city. This situation in the DF as well as other areas in Brazil and other countries compromises the development and implementation of public health and environmental policies.

In cities that don't have a monitoring network of air quality, one public policy strategy could be using alternative parameters with spatial information. Thus, the aim of this study was to develop a model that defines priority areas for efficient monitoring of air pollution.

**AREA OF THE STUDY**

The study was carried out in the FD region, which is located in the city of Brasília, the capital of Brazil (Figure 1).

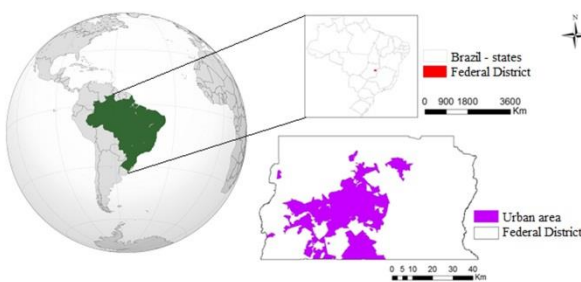


Figure 1 – Area of the study.

**MATERIAL AND METHODS**

Methods used in this study was concentrated on multi-criteria model and spatial assessment. In relation to the multi-criteria model, was represented by Analytic Hierarchy Process (AHP). Regarding for spatial assessment, was represented by Geographic Information System (GIS). Figure 2 shows the overall structure of the study.

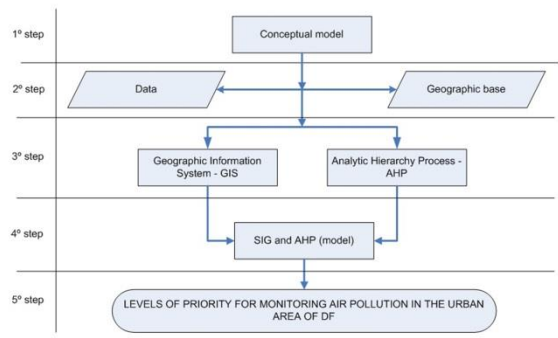


Figure 2 – Methodological stages of the research

It is emphasized that the conceptual model (first step) was developed with three primary attributes: a) human exposure, b) sources of pollution and c) environmental characteristics.

**RESULTS**

Figure 3 shows the result of the generated map with a description of priority levels in the urban area of FD.

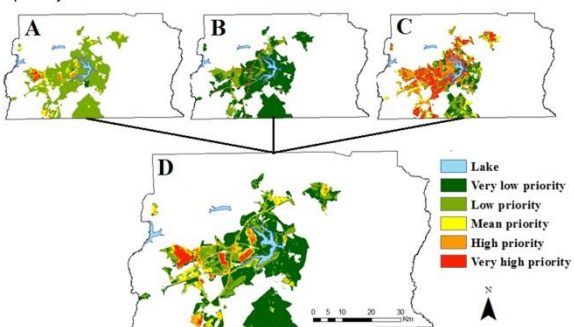


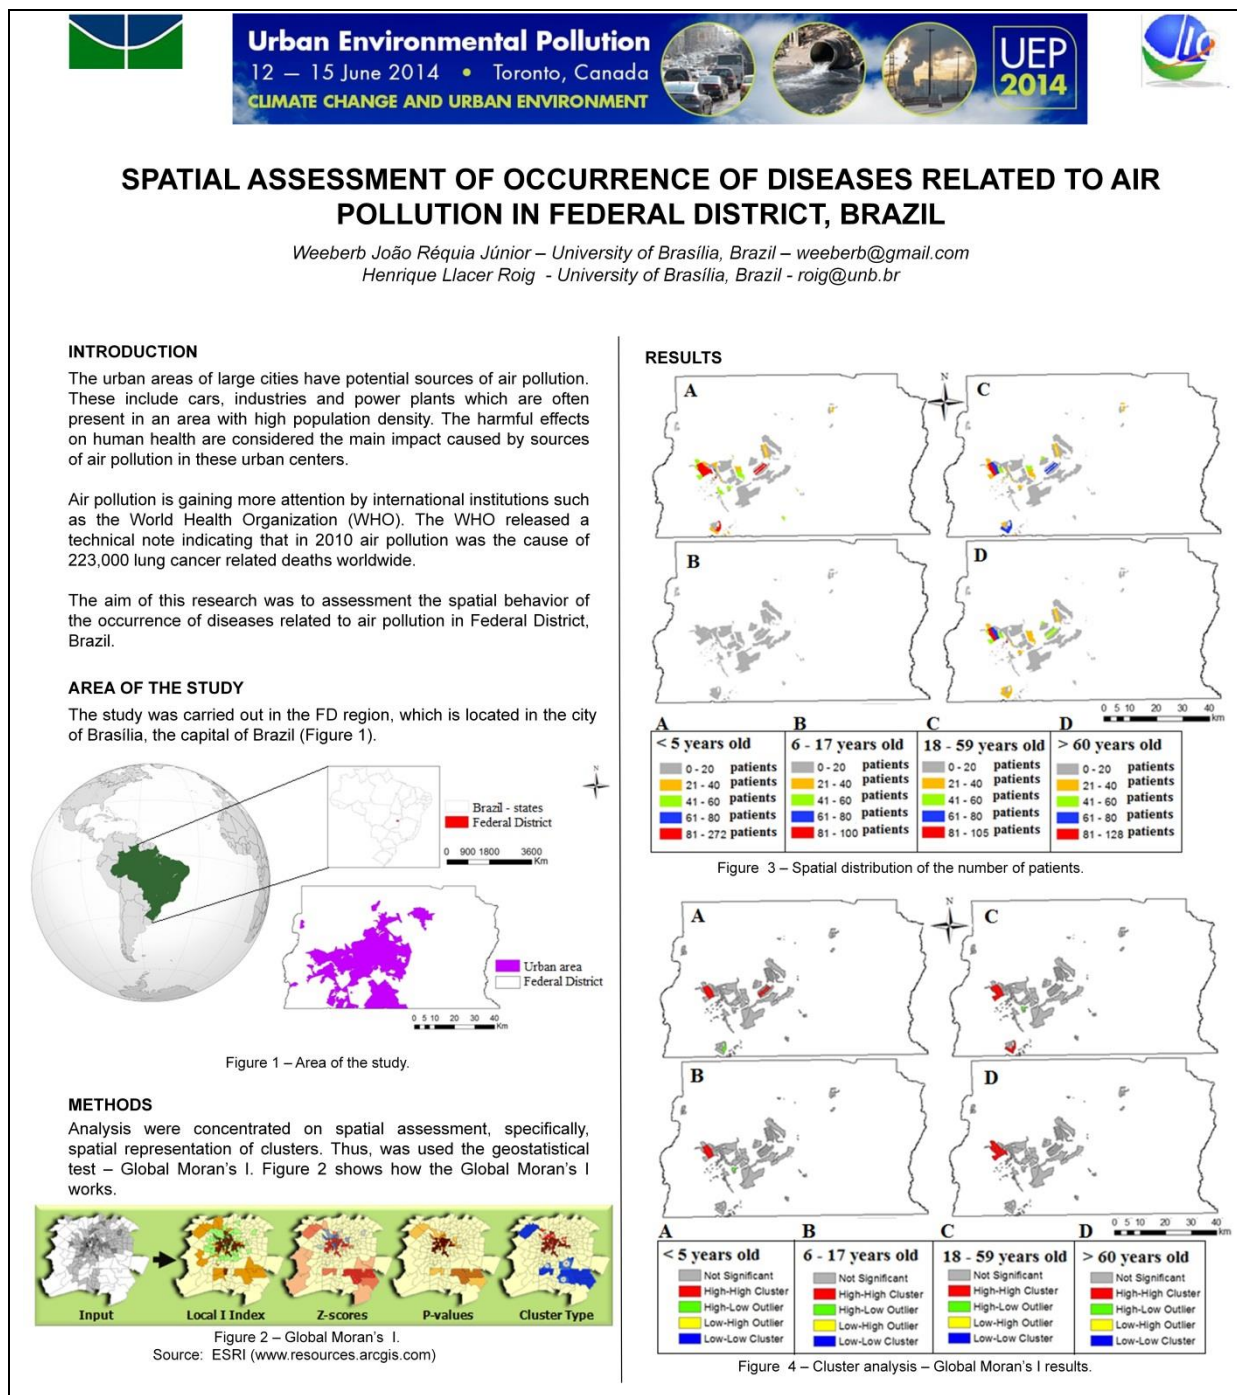
Figure 3 – Levels of priority for monitoring air pollution.  
Note: A–human exposure; B–sources of pollution; C–environmental characteristics; D–final favorability map.

**CONCLUSION**

The result of this study is a tool for the cities that don't have a monitoring network of air quality. Also could even serve as an additional tool to analyze regions that already have an established monitoring network.



## A.2.2. Spatial assessment of occurrence of diseases related to air pollution in Federal District, Brazil



**APÊNDICE B – PUBLICAÇÃO EM PERIÓDICOS**



## B.1. ATMOSPHERIC ENVIRONMENT

## B.1.1. Spatial distribution of vehicle emission inventories in the Federal District, Brazil

Atmospheric Environment 112 (2015) 32–39

Contents lists available at ScienceDirect

**Atmospheric Environment**

journal homepage: [www.elsevier.com/locate/atmosenv](http://www.elsevier.com/locate/atmosenv)




---

## Spatial distribution of vehicle emission inventories in the Federal District, Brazil

Weeberb João Réquia Jr. <sup>a, b, \*</sup>, Petros Koutrakis <sup>a</sup>, Henrique Llacer Roig <sup>b</sup>

<sup>a</sup> Department of Environmental Health, Harvard School of Public Health, 401 Park Drive, Landmark Center West, Boston, MA 02215, United States  
<sup>b</sup> Geoscience Institute, University of Brasília, Campus Darcy Ribeiro, Brasília, Distrito Federal 709109, Brazil



---

**H I G H L I G H T S**

- We used a bottom-up method to predict emissions and to characterize their spatial patterns using Global Moran's.
- Our findings suggested that light duty vehicles are primarily responsible for the main vehicular emissions.
- CO<sub>2</sub> is the pollutant with the highest emissions, over 30 million tons/year.

**A B S T R A C T**

Air pollution poses an important public health risk, especially in large urban areas. Information about the spatial distribution of air pollutants can be used as a tool for developing public policies to reduce source emissions. Air pollution monitoring networks provide information about pollutant concentrations; however, they are not available in every urban area. Among the 5570 cities in Brazil, for example, only 1.7% of them have air pollution monitoring networks. In this study we assess vehicle emissions for main traffic routes of the Federal District (state of Brazil) and characterize their spatial patterns. Toward this end, we used a bottom-up method to predict emissions and to characterize their spatial patterns using Global Moran's (Spatial autocorrelation analysis) and Getis-Ord General G (High/Low cluster analysis). Our findings suggested that light duty vehicles are primarily responsible for the vehicular emissions of CO (68.9%), CH<sub>4</sub> (93.6%), and CO<sub>2</sub> (57.9%), whereas heavy duty vehicles are primarily responsible for the vehicular emissions of NMHC (92.9%), NO<sub>x</sub> (90.7%), and PM (97.4%). Furthermore, CO<sub>2</sub> is the pollutant with the highest emissions, over 30 million tons/year. In the spatial autocorrelation analysis was identified cluster ( $p < 0.01$ ) for all types of vehicles and for all pollutants. However, we identified high cluster only for the light vehicles.

© 2015 Elsevier Ltd. All rights reserved.

---

**A R T I C L E I N F O**

*Article history:*  
Received 10 December 2014  
Received in revised form  
2 April 2015  
Accepted 13 April 2015  
Available online 14 April 2015

*Keywords:*  
Air pollution  
Vehicle emission inventories  
Spatial patterns

**1. Introduction**

Urban air pollution is considered as an important public health risk (Kheirbek et al., 2012; Nandasena et al., 2012; Gallardo et al., 2012). For example, the World Health Organization (WHO) reported that exposures to gaseous and particulate air pollutants are responsible for 223,000 deaths worldwide in 2010 due to lung cancer (OMSOMS, 2013).

Vehicles such as passenger cars, buses, trucks, and motorcycles

are the main sources of air pollution in urban areas and their emissions account for 30% of NO<sub>x</sub> and 14% CO<sub>2</sub> of global emissions (Vasconcellos, 2006). In Brazil, approximately 40% of CO<sub>2</sub> is associated with vehicular emissions (MCT, 2013).

Information about pollutant emissions released in urban areas is critical to public health policies for human health and environmental protection. In this context, air pollution monitoring networks are the main mechanism for obtaining information about gaseous and particulate air pollutants (Wallace et al., 2012; Hasenfratz et al., 2012). However, they are not available in many urban centers, since their capital and operation costs are high and require specialized professional personnel (Kanaroglou et al., 2005; Joly and Peuch, 2012).

In Brazil, for example, there are a total of 5570 cities, but only 1.7% of them have an air pollution monitoring network. Nationally,

---

\* Corresponding author. Department of Environmental Health, Harvard School of Public Health, 401 Park Drive, Landmark Center West, Boston, MA 02215, United States.  
E-mail addresses: [weeberb@gmail.com](mailto:weeberb@gmail.com), [wjrequia@hsph.harvard.edu](mailto:wjrequia@hsph.harvard.edu) (W.J. Réquia), [petros@hsph.harvard.edu](mailto:petros@hsph.harvard.edu) (P. Koutrakis), [roig@unb.br](mailto:roig@unb.br) (H.L. Roig).

<http://dx.doi.org/10.1016/j.atmosenv.2015.04.029>  
1352-2310/© 2015 Elsevier Ltd. All rights reserved.

## B.2. REVISTA BRASILEIRA DE GEOGRAFIA MÉDICA (HYGEIA)

### B.2.1. Avaliação espacial entre poluição do ar e saúde em áreas com limitação de dados

10/6/2015 Gmail - [Hygeia] Agradecimento pela Submissão

 Weeberb Réquia <weeberb@gmail.com>

---

**[Hygeia] Agradecimento pela Submissão**

---

**Samuel do Carmo Lima** <samuel@ufu.br> Tue, Apr 28, 2015 at 4:52 PM  
To: "Weeberb J. J. Réquia" <weeberb@gmail.com>

Weeberb J. J. Réquia,

Agradecemos a submissão do seu manuscrito "AVALIAÇÃO ESPACIAL ENTRE POLUIÇÃO DO AR E SAÚDE EM ÁREAS COM LIMITAÇÃO DE DADOS" para Hygeia. Através da interface de administração do sistema, utilizado para a submissão, será possível acompanhar o progresso do documento dentro do processo editorial, bastando logar no sistema localizado em:

URL do Manuscrito:  
<http://www.seer.ufu.br/index.php/hygeia/author/submission/30056>  
Login: weeberb

Em caso de dúvidas, envie suas questões para este email. Agradecemos mais uma vez considerar nossa revista como meio de transmitir ao público seu trabalho.

Samuel do Carmo Lima  
Hygeia  
Hygeia  
<http://www.seer.ufu.br/index.php/hygeia/index>

## B.3. JOURNAL HEALTH

### B.3.1. Analyzing spatial patterns of cardiorespiratory diseases in the Federal District, Brazil

Health, 2015, 7, 1283-1293

Published Online October 2015 in SciRes. <http://www.scirp.org/journal/health>

<http://dx.doi.org/10.4236/health.2015.710143>



# Analyzing Spatial Patterns of Cardiorespiratory Diseases in the Federal District, Brazil

Weeberb Requia, Henrique Roig

Campus Darcy Ribeiro, University of Brasilia, Brasilia, Brazil

Email: [weeberb@gmail.com](mailto:weeberb@gmail.com)

Received 24 July 2015; accepted 16 October 2015; published 19 October 2015

Copyright © 2015 by authors and Scientific Research Publishing Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## Abstract

Cardiorespiratory diseases are a serious public health problem worldwide. Identification of spatial patterns in health events is an efficient tool to guide public policies in environmental health. However, only few studies have considered spatial pattern analysis which is considered the evaluation of spatial autocorrelation, degree of autocorrelation and dependence behavior in terms of distances. Therefore, the objective of this study is to propose a set of procedures to evaluate the spatial patterns of cardiorespiratory diseases in the Federal District, Brazil. Specifically, our proposal will be based on four questions: a) is the spatial distribution of all patients clustered, random or dispersed? b) what is the degree of clustering for either high values or low values of patients? c) what is the spatial dependence behavior? d) considering the spatial variation, at what distance does the type of distribution (cluster, random or disperse) begin to change? We chose four methods to answer these questions Global Moran's I (question "a"); Getis-Ord General G (question "b"); semivariogram analysis (question "c"); and multi-distance spatial cluster-K-function (question "d"). Our results suggest that there is a different behavior for people up to 5 years old (cluster,  $p < 0.01$ ), especially in distances below 2.5 km. For people above 59 years old, cluster is significant just in short distances (<200 m). For other age groups, the spatial distribution is basically random. Our study showed that it was possible to capture evidences of health disparities in the Federal District.

## Keywords

Environmental Health, Spatial Patterns, Cardiorespiratory Diseases

## 1. Introduction


Cardiorespiratory diseases are a serious public health problem worldwide [1]. According to World Health Or-

How to cite this paper: Requia, W. and Roig, H. (2015) Analyzing Spatial Patterns of Cardiorespiratory Diseases in the Federal District, Brazil. *Health*, 7, 1283-1293. <http://dx.doi.org/10.4236/health.2015.710143>

## B.4. JOURNAL OF THE AIR & WASTE MANAGEMENT ASSOCIATION

### B.4.1. A spatial multicriteria model for determining air pollution at sample locations

This article was downloaded by: [Weeberb Requia]  
 On: 23 January 2015, At: 09:48  
 Publisher: Taylor & Francis  
 Informa Ltd Registered in England and Wales Registered Number: 1072954 Registered office: Mortimer House,  
 37-41 Mortimer Street, London W1T 3JH, UK



#### Journal of the Air & Waste Management Association

Publication details, including instructions for authors and subscription information:  
<http://www.tandfonline.com/loi/uawm20>

#### A spatial multicriteria model for determining air pollution at sample locations

Weeberb João Réquia Júnior<sup>ab</sup>, Henrique Llacer Roig<sup>a</sup> & Petros Koutrakis<sup>b</sup>

<sup>a</sup> University of Brasília, Brasília, Federal District, Brazil

<sup>b</sup> Department of Environmental Health, Harvard School of Public Health, Harvard University, Boston, MA, USA

Accepted author version posted online: 14 Oct 2014. Published online: 21 Jan 2015.



[Click for updates](#)

**To cite this article:** Weeberb João Réquia Júnior, Henrique Llacer Roig & Petros Koutrakis (2015) A spatial multicriteria model for determining air pollution at sample locations, Journal of the Air & Waste Management Association, 65:2, 232-243, DOI: [10.1080/10962247.2014.971976](https://doi.org/10.1080/10962247.2014.971976)

**To link to this article:** <http://dx.doi.org/10.1080/10962247.2014.971976>

PLEASE SCROLL DOWN FOR ARTICLE

Taylor & Francis makes every effort to ensure the accuracy of all the information (the "Content") contained in the publications on our platform. However, Taylor & Francis, our agents, and our licensors make no representations or warranties whatsoever as to the accuracy, completeness, or suitability for any purpose of the Content. Any opinions and views expressed in this publication are the opinions and views of the authors, and are not the views of or endorsed by Taylor & Francis. The accuracy of the Content should not be relied upon and should be independently verified with primary sources of information. Taylor and Francis shall not be liable for any losses, actions, claims, proceedings, demands, costs, expenses, damages, and other liabilities whatsoever or howsoever caused arising directly or indirectly in connection with, in relation to or arising out of the use of the Content.

This article may be used for research, teaching, and private study purposes. Any substantial or systematic reproduction, redistribution, reselling, loan, sub-licensing, systematic supply, or distribution in any form to anyone is expressly forbidden. Terms & Conditions of access and use can be found at <http://www.tandfonline.com/page/terms-and-conditions>



## TECHNICAL PAPER

## A spatial multicriteria model for determining air pollution at sample locations

Weeberb João Réquia Júnior<sup>1,2,\*</sup>, Henrique Llacer Roig,<sup>1</sup> and Petros Koutrakis<sup>2</sup>

<sup>1</sup>University of Brasília, Brasília, Federal District, Brazil

<sup>2</sup>Department of Environmental Health, Harvard School of Public Health, Harvard University, Boston, MA, USA

\*Please address correspondence to: Weeberb João Réquia Júnior, Department of Environmental Health, Harvard School of Public Health, Harvard University, 401 Park Drive, Landmark Center West, Boston, MA 02215, USA; e-mail: [wjrequia@hsph.harvard.edu](mailto:wjrequia@hsph.harvard.edu)

*Atmospheric pollution in urban centers has been one of the main causes of human illness related to the respiratory and circulatory system. Efficient monitoring of air quality is a source of information for environmental management and public health. This study investigates the spatial patterns of atmospheric pollution using a spatial multicriteria model that helps target locations for air pollution monitoring sites. The main objective was to identify high-priority areas for measuring human exposures to air pollutants as they relate to emission sources. The method proved to be viable and flexible in its application to various areas.*

*Implications:* Spatial multicriteria models provide a tool for air pollution management in urban areas. Analytic hierarchy process (AHP) modeling can help with the process of prioritizing monitoring site locations and minimizing costs.

### Introduction

Excessive pollutant concentrations in the atmosphere compromise human health (Rao et al., 2011; Phalen, 2012). Unsustainable industrial development and growing transportation fleets that consume fossil fuels are the main sources of gas and particle emissions in the atmosphere (W. Wang et al., 2012).

To minimize the impacts of atmospheric pollution, government and research institutions have developed instruments to guide and control air quality management (Camargo et al., 2011). These instruments are used at monitoring stations to carry out air quality sampling (Austin et al., 2013).

However, the implementation of monitoring networks presents particular challenges, including the costs of implementation and operation (Thambavani and Prathipa, 2012) and the selection of optimal monitoring station sites (Ademe, 2002). Regarding site selections, no clear set of criteria exists based on the specific contextual conditions of specific urban areas.

Consequently, spatial analysis methods can be employed to improve the design of air-quality monitoring networks. The highlighted set of available methods includes multicriteria models, which are known as analytic hierarchy process (AHP) models, and geographic information systems (GIS).

The AHP method generates hierarchical weights for all problem variables. The AHP method was developed by Saaty (1990) and has been regularly used in the environmental field (Greening and Bernow, 2004; Tarso et al., 2009; Barros et al., 2007). In addition, GIS models are applied in interdisciplinary areas to develop spatial relationships among the studied variables (Li et al., 2012).

This study evaluates the dynamics of atmospheric pollution by using a multicriteria model and GIS to determine relevant sites for air pollution monitors.

### Materials and Methods

The study was carried out in the Federal District (FD) region of Brasília, the capital of Brazil. The region is between 15° 30' and 16° 03' latitude South and 47° 25' and 48° 12' longitude West and covers an area of 5,814 km<sup>2</sup>. In the FD, most atmospheric pollution sources are located in urban areas. Thus, this study was only conducted within the urban zones of the FD (Figure 1).

This study was performed in five stages. In the first stage, a conceptual model was defined to establish a hierarchy network using the AHP model. The second stage represents geographical data collection. In the third stage, the collected data were spatially mapped and the weights for the AHP model were defined. In the fourth stage, the data that were mapped in the third stage were modeled. Finally, a map was created that showed the optimal air quality monitoring sites (Figure 2).

#### Conceptual model, data, and geographic bases


The conceptual model is represented by a hierarchical network that is defined by the AHP. Once a goal is identified, the AHP method structures the respective criteria and alternatives to follow a hierarchical order (Figure 3).

With the aim of identifying optimal monitoring sites, three main model criteria were used, human exposure, pollution sources, and environmental characteristics (Figure 4).

## B.5. JOURNAL ENVIRONMENT INTERNATIONAL

## B.5.1. A novel land use approach for assessment of human health: the relationship between urban structure types and cardiorespiratory disease risk

Environment International 85 (2015) 334–342



Contents lists available at ScienceDirect

**Environment International**

journal homepage: [www.elsevier.com/locate/envint](http://www.elsevier.com/locate/envint)



---

## A novel land use approach for assessment of human health: The relationship between urban structure types and cardiorespiratory disease risk

Weeberb João Réquia Júnior<sup>a,b,\*</sup>, Henrique Llacer Roig<sup>b,1</sup>, Petros Koutrakis<sup>a,2</sup>

<sup>a</sup> Harvard University, United States  
<sup>b</sup> University of Brasilia, Brazil

 CrossMark

---

**ARTICLE INFO**

**Article history:**  
Received 3 August 2015  
Received in revised form 29 September 2015  
Accepted 30 September 2015  
Available online xxxxx

**Keywords:**  
Land use  
Urban structure types  
Human health  
Cardiorespiratory diseases  
Risk

**ABSTRACT**

Extensive evidence shows that in addition to lifestyle factors, environmental aspects are an important risk factor for human health. Numerous approaches have been used to estimate the relationship between environment and health. For example, the urban characteristics, especially the types of land use, are considered a potential proxy indicator to evaluate risk of disease. Although several studies have used land use variables to assess human health, none of them has used the concept of Urban Morphology by Urban Structure Types (USTs) as indicators of land use. The aim of this study was to assess the relationship between USTs and cardiorespiratory disease risks in the Federal District, Brazil. Toward this end, we used a quantile regression model to estimate risk. We used 21 types of UST. Income and population density were used as covariates in our sensitivity analysis. Our analysis showed an association between cardiorespiratory diseases risk and 10 UST variables (1 related to rural area, 6 related to residential area, 1 recreational area, 1 public area and 1 commercial area). Our findings suggest that the conventional land use method may be missing important information about the effect of land use on human health. The use of USTs can be an approach to complement the conventional method. This should be of interest to policy makers in order to enhance public health policies and to create future strategies in terms of urban planning, land use and environmental health.

© 2015 Elsevier Ltd. All rights reserved.

---

**1. Introduction**

Cardiorespiratory diseases represent a large fraction of the global burden of diseases (Mortimer et al., 2012). According to the World Health Organization (WHO, 2014), in 2012 cardiovascular and respiratory diseases were responsible for 17.5 and 4 million deaths globally, respectively. Studies have shown that in addition to lifestyle factors, environmental factors are considered as an important risk factor for cardiorespiratory diseases (O'Toole et al., 2008).

Researchers have used numerous approaches to investigate the relationship between environment and health. For example, they have investigated the effects of land use on human health and have reported effects of land use types on mental diseases (Villanueva et al., 2013), obesity (Wall et al., 2012; Fraser et al., 2012), body mass index (James et al., 2014) and cardiorespiratory diseases (Chum and O'Campo, 2015).

The assumption that air pollution is directly related to disease is based on the following: 1) Air pollution is considered an important

cause of cardiorespiratory diseases (Buonanno et al., 2013; Gonzalez-Barcala et al., 2013); 2) Vehicle traffic is a significant source of air pollution (Réquia Júnior et al., 2015b; Réquia Júnior et al., 2015a; Song et al., 2012). For example, Lozano et al. (2012) estimated that the particulate matter – PM<sub>2.5</sub> (main pollutant emitted by vehicles) contributes to approximately two million premature deaths per year, ranking it as the 13th leading cause of worldwide mortality, and; 3) We expected to find higher concentration of vehicles in urban land use (especially in the city centers) than in surrounding areas (Cervero, 2013). Also, we expected to find higher concentrations of air pollutants in land use characterized by tall buildings, which minimize the dispersion of gases and particulates (Baik et al., 2012; Pirjola et al., 2012); 4) Consequently, we expected that the urban center (especially where there are high-rise buildings) is likely to be the critical type of land use in terms of human exposure to air pollutants.

Although several studies have explored land use variables to assess human health, none of them has introduced the concept of Urban Morphology by Urban Structure Types (USTs) as proxy indicators of land use. According to Heiden et al. (2012), USTs are spatial indicators, which describe the urban system through their physical properties (e.g., size, surface materials), their environmental characteristics (e.g., climate, hydrology) and their function properties (e.g., land use). The UST approach is more specific than the conventional method because it

---

\* Corresponding author at: 401 Park Drive, Landmark Center West, Boston, MA 02215, United States.  
E-mail addresses: [weeberb@gmail.com](mailto:weeberb@gmail.com) (W.J. Réquia Júnior), [roig@unh.br](mailto:roig@unh.br) (H.L. Roig), [petros@hsph.harvard.edu](mailto:petros@hsph.harvard.edu) (P. Koutrakis).

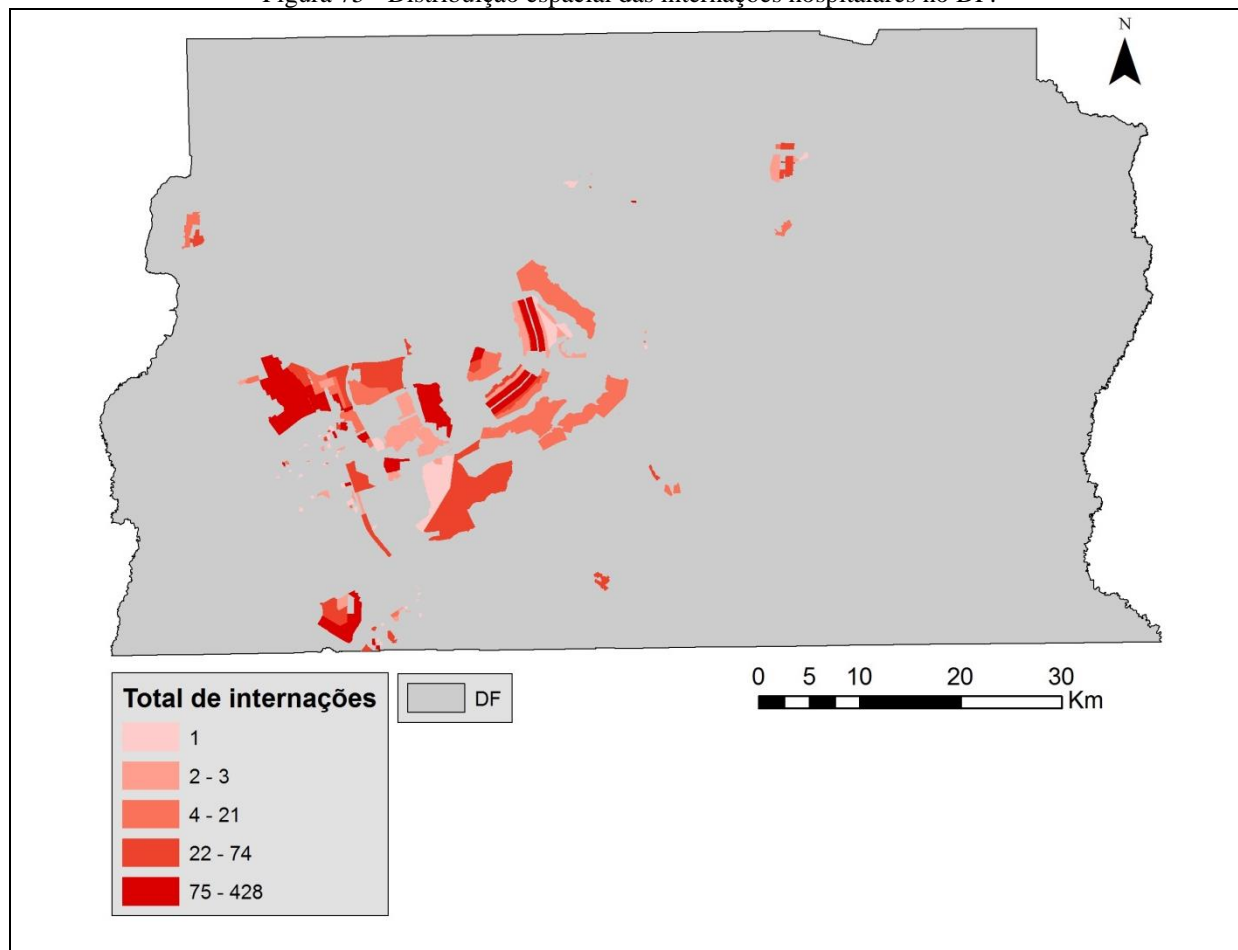
<sup>1</sup> Campus Darcy Ribeiro, Brasília, Distrito Federal 70910900, Brazil.  
<sup>2</sup> 401 Park Drive, Landmark Center West, Boston, MA 02215, United States.

<http://dx.doi.org/10.1016/j.envint.2015.09.026>  
0160-4120/© 2015 Elsevier Ltd. All rights reserved.

**APÊNDICE C – REPRESENTAÇÃO ESPACIAL DAS VARIÁVEIS UTILIZADAS  
NESTA PESQUISA**

## C.1. INTERNAÇÕES HOSPITALARES

Figura 75 - Distribuição espacial das internações hospitalares no DF.



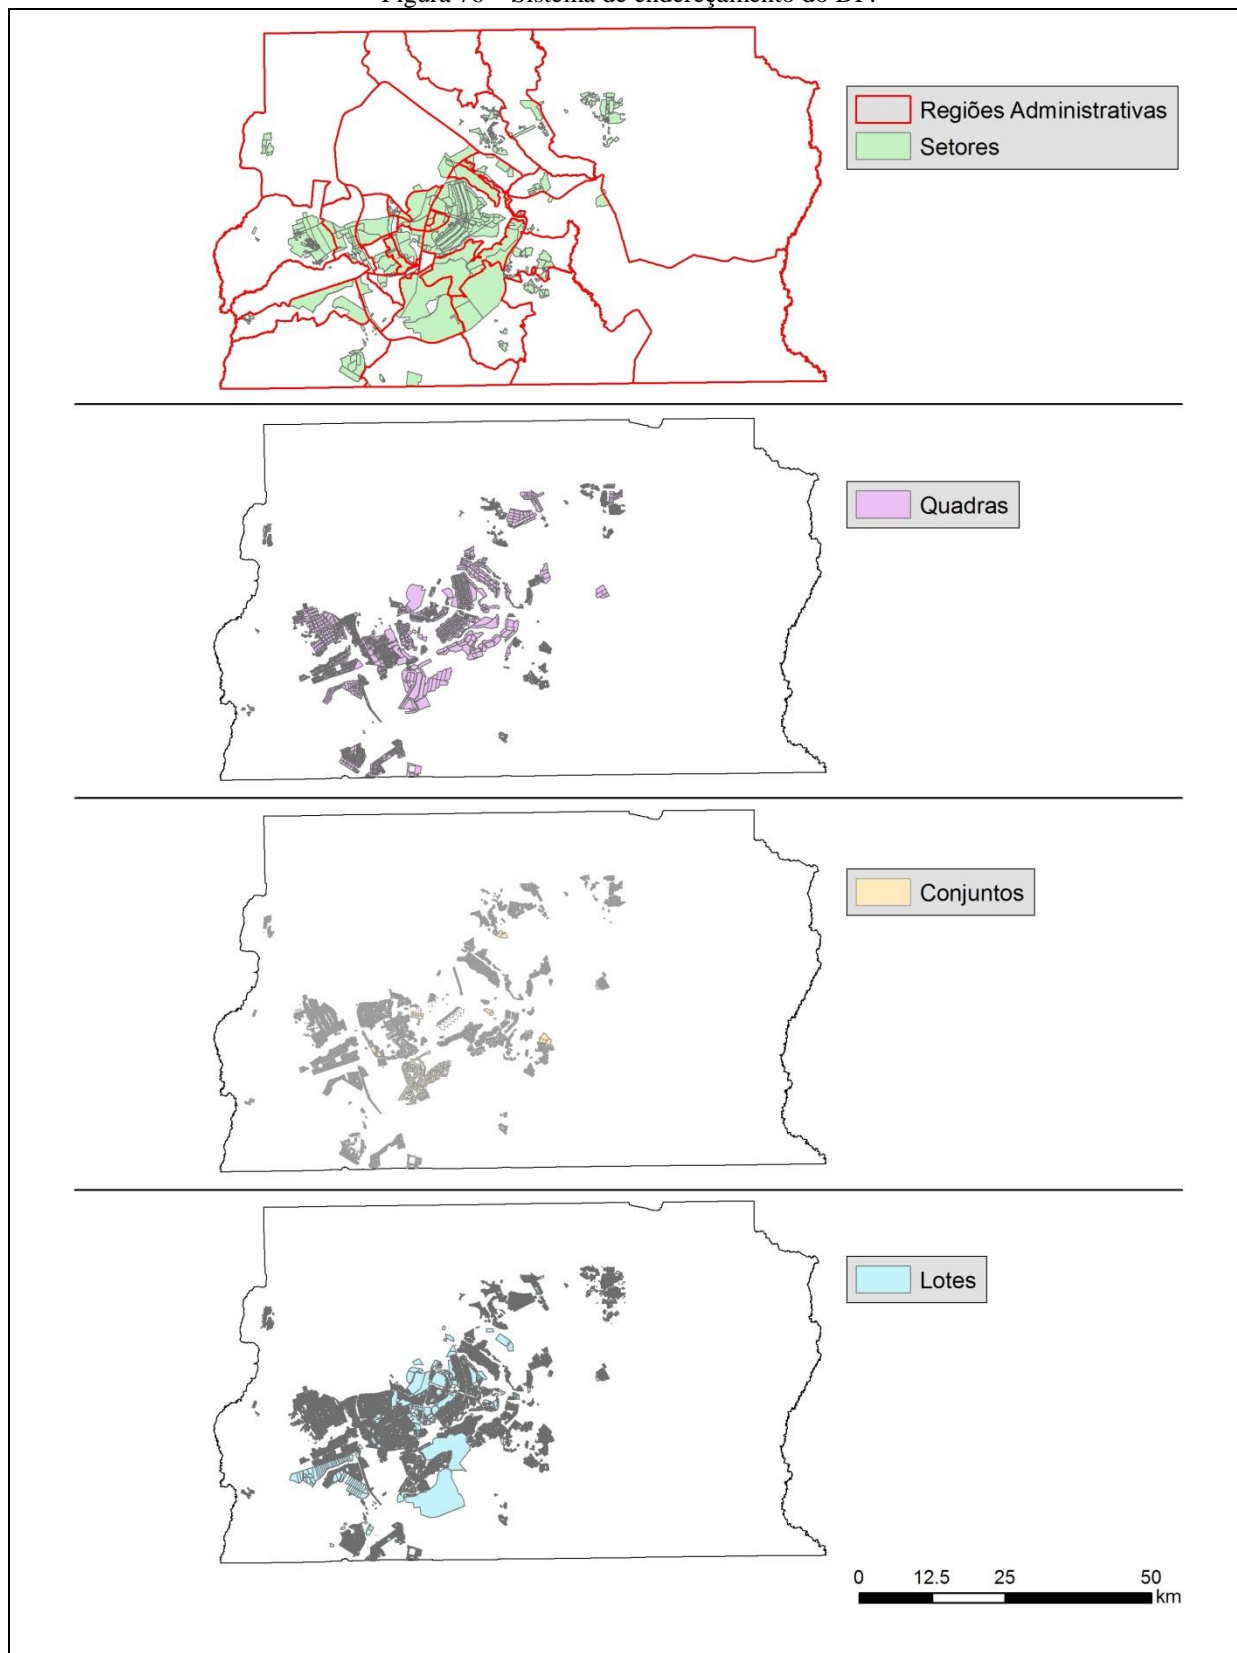
Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado - quantile.



## C.2. ENDEREÇAMENTO

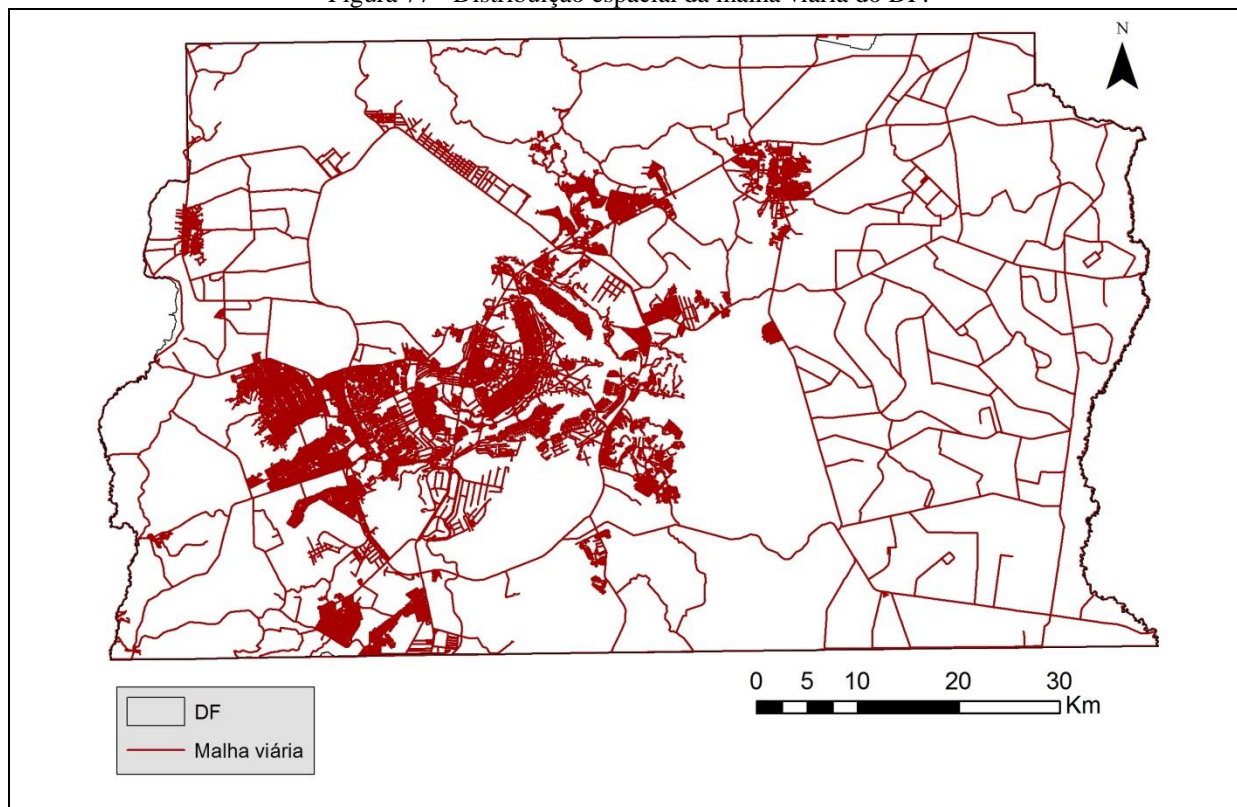
Figura 76 – Sistema de endereçamento do DF.



Fonte: Produção do próprio autor.

## C.3. MALHA VIÁRIA

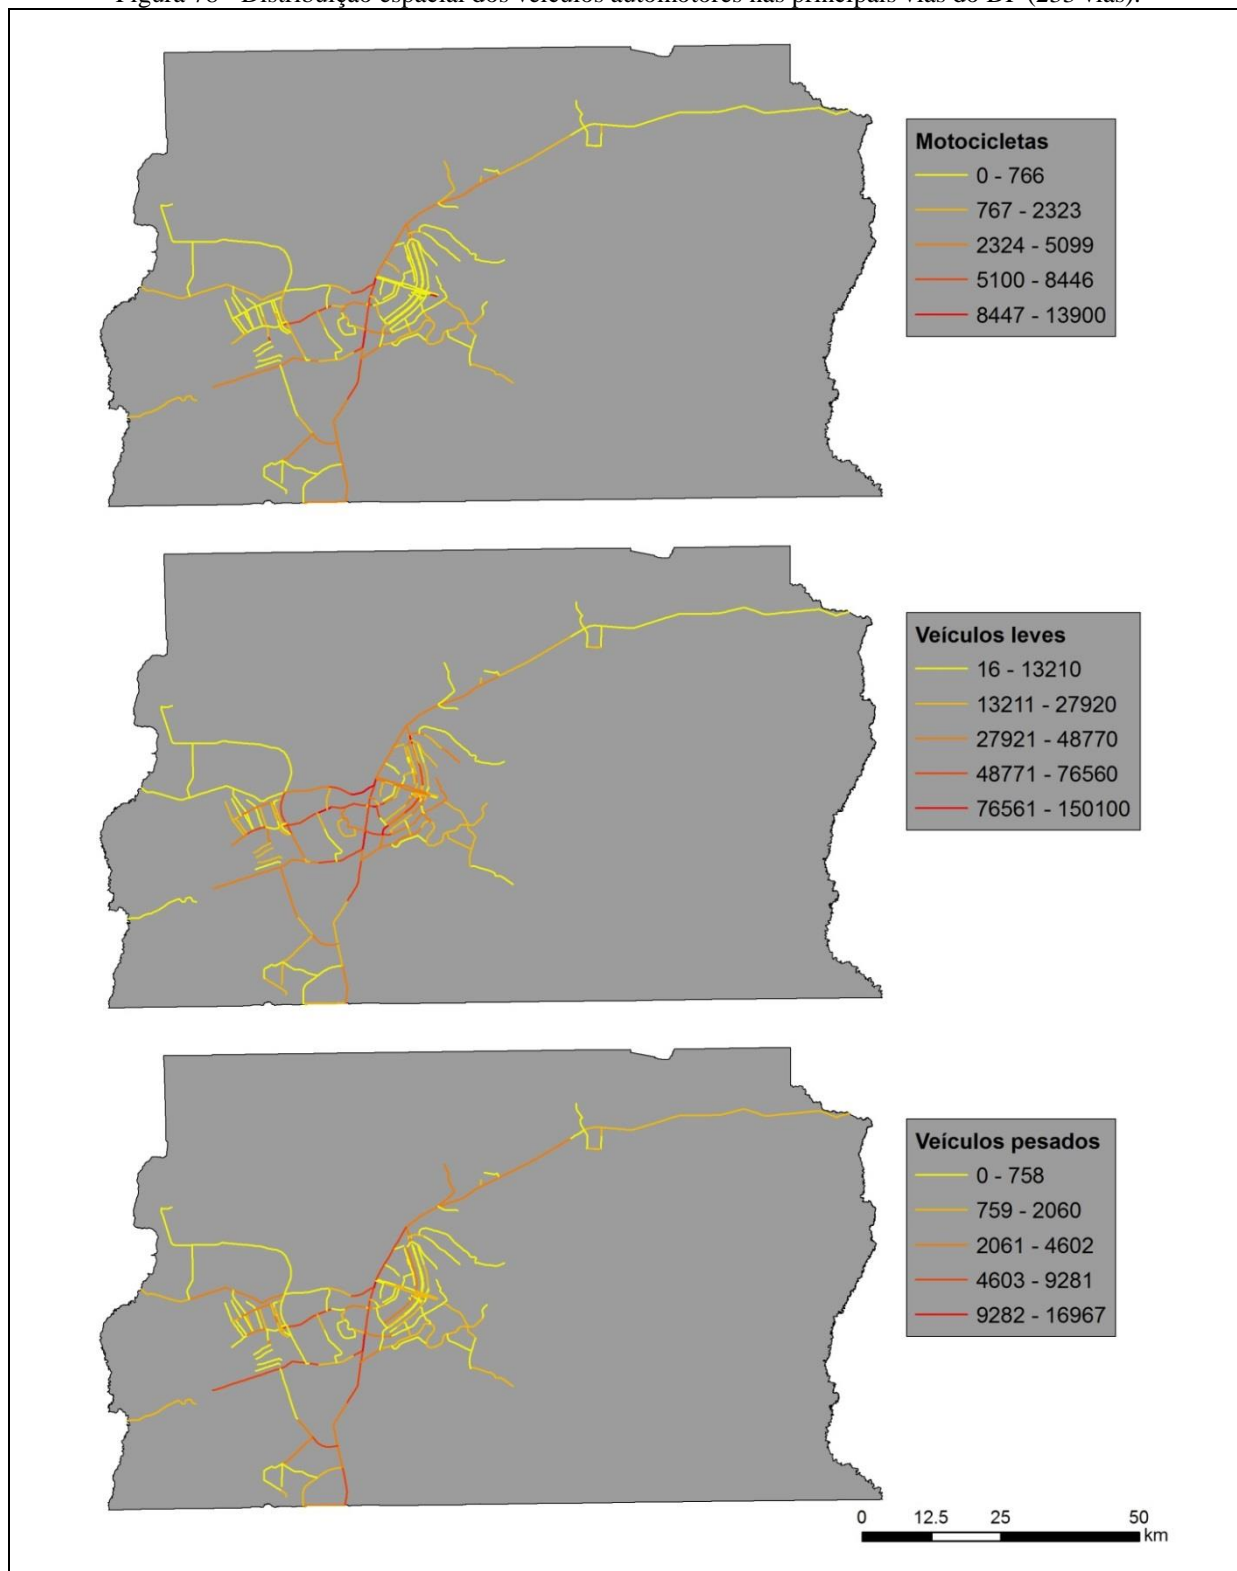
Figura 77 - Distribuição espacial da malha viária do DF.



Fonte: Produção do próprio autor.

## C.4. VEÍCULOS

Figura 78 - Distribuição espacial dos veículos automotores nas principais vias do DF (233 vias).

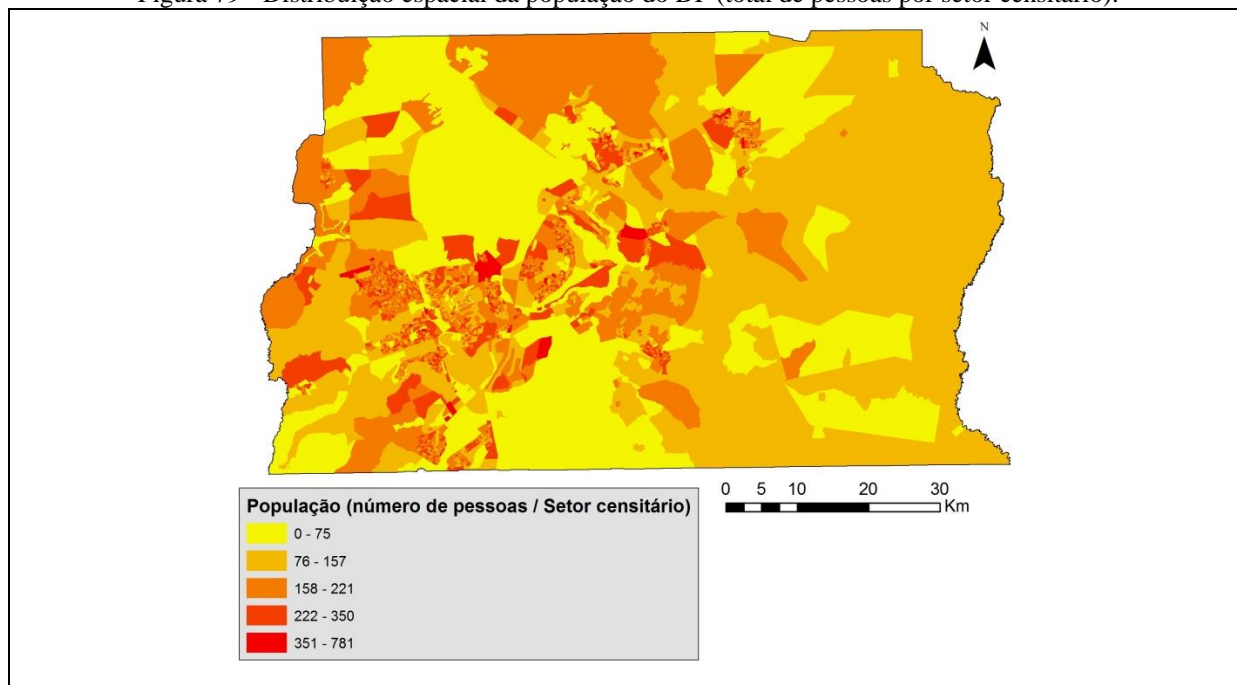


Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado – natural breaks (jenks).

## C.5. POPULAÇÃO

Figura 79 - Distribuição espacial da população do DF (total de pessoas por setor censitário).

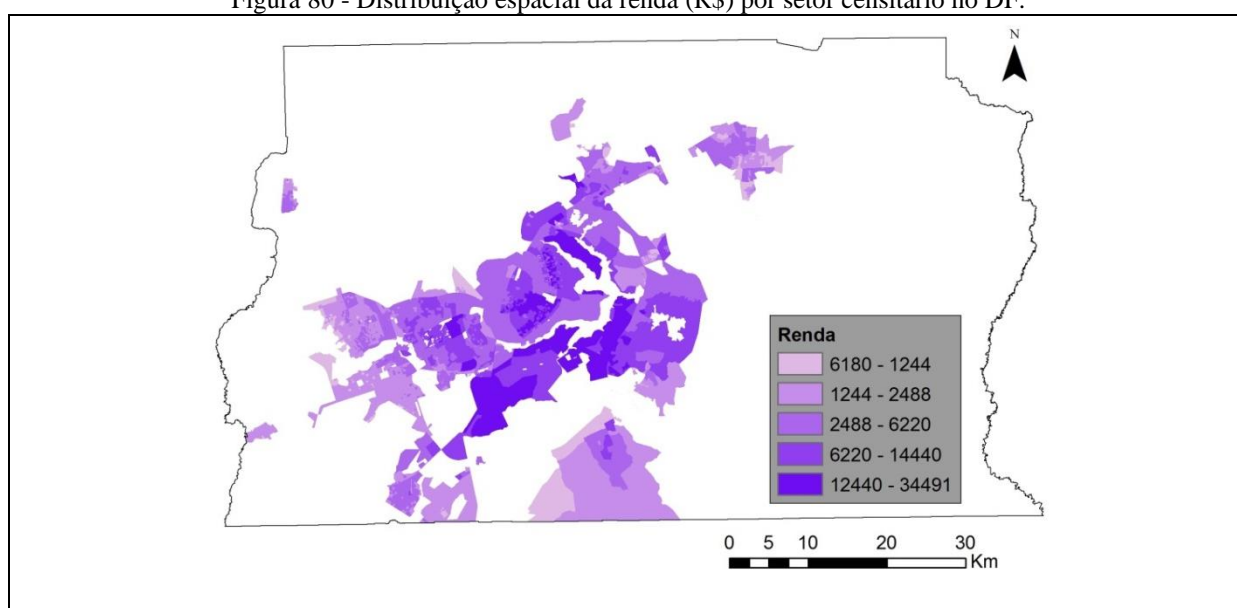


Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado – natural breaks (jenks).

## C.6. RENDA

Figura 80 - Distribuição espacial da renda (R\$) por setor censitário no DF.

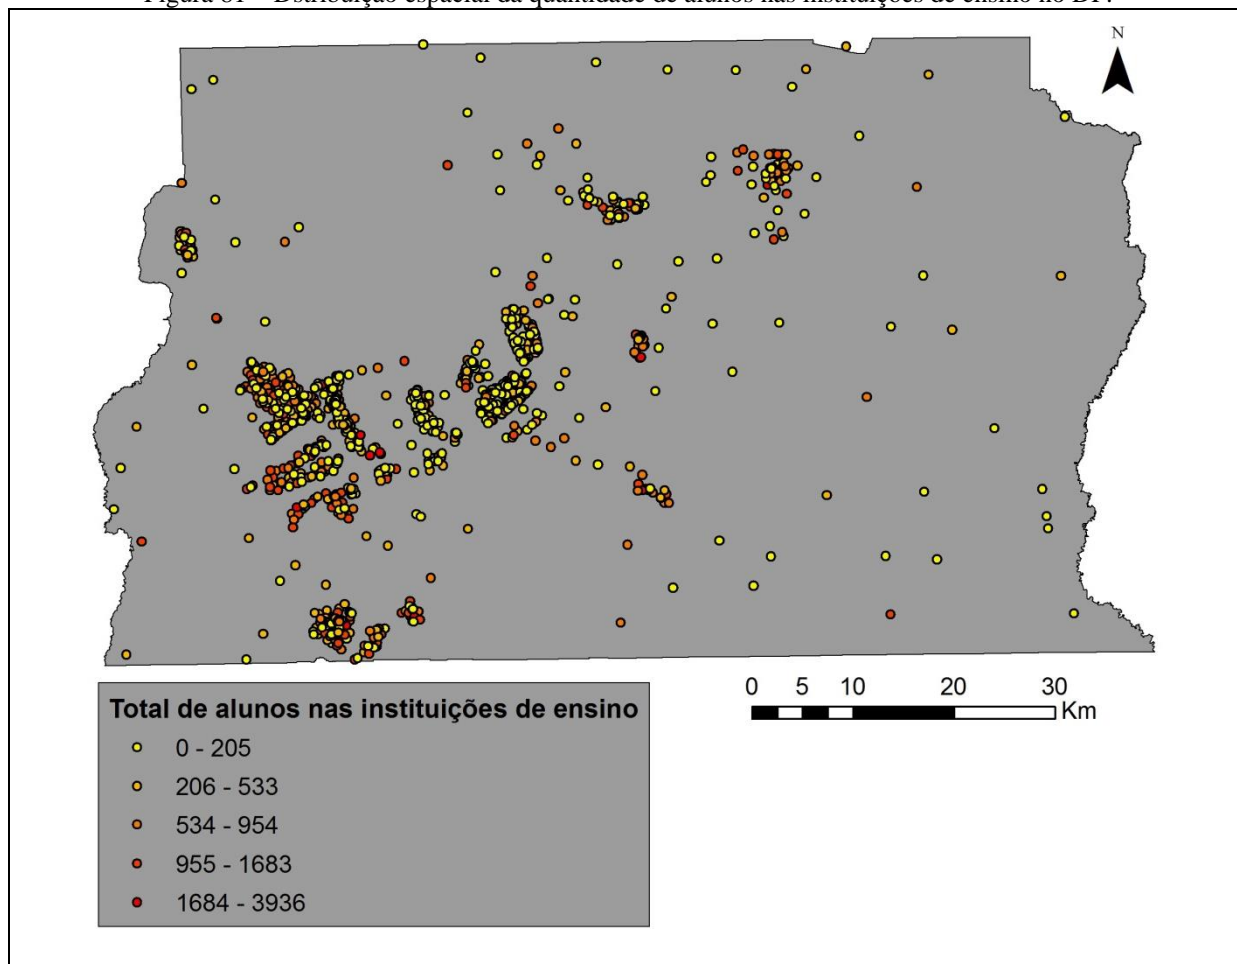


Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado – natural break (jenks).

## C.7. INSTITUIÇÕES DE ENSINO

Figura 81 – Distribuição espacial da quantidade de alunos nas instituições de ensino no DF.

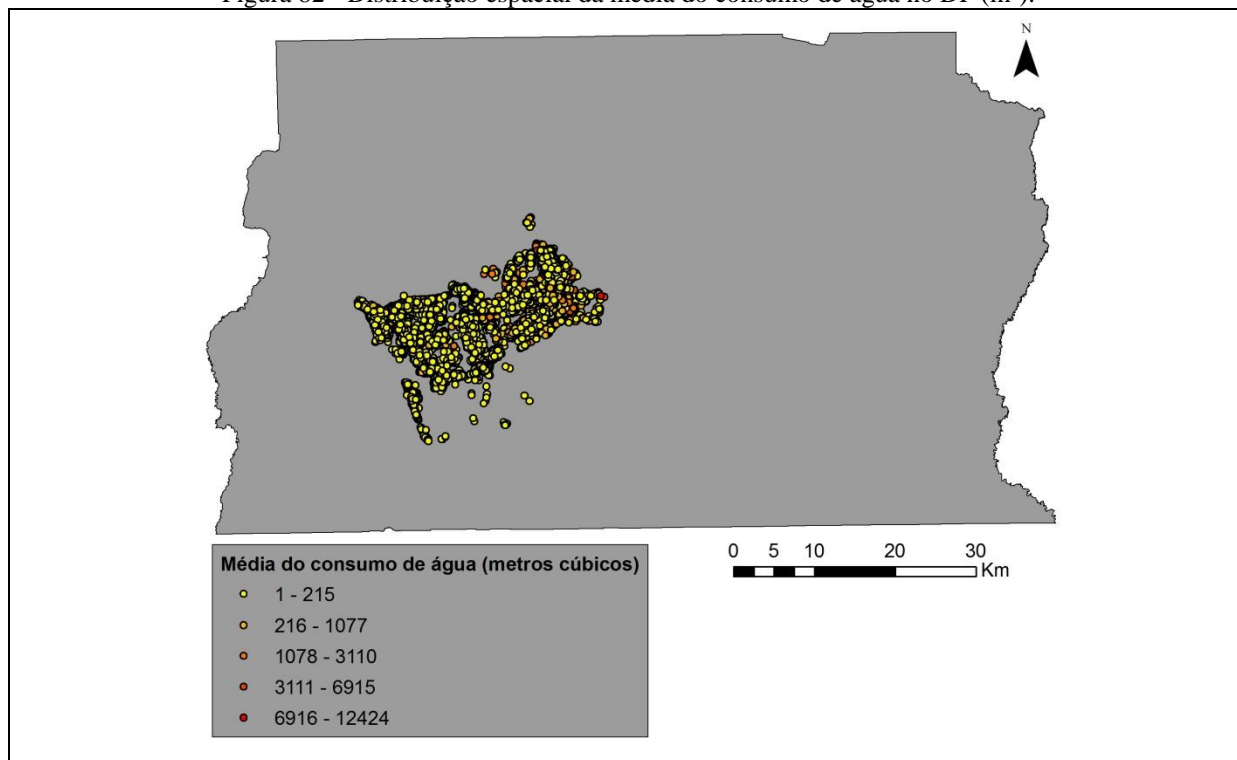


Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado – natural break (jenks).

## C.8. HIDRÔMETROS

Figura 82 - Distribuição espacial da média do consumo de água no DF (m<sup>3</sup>).

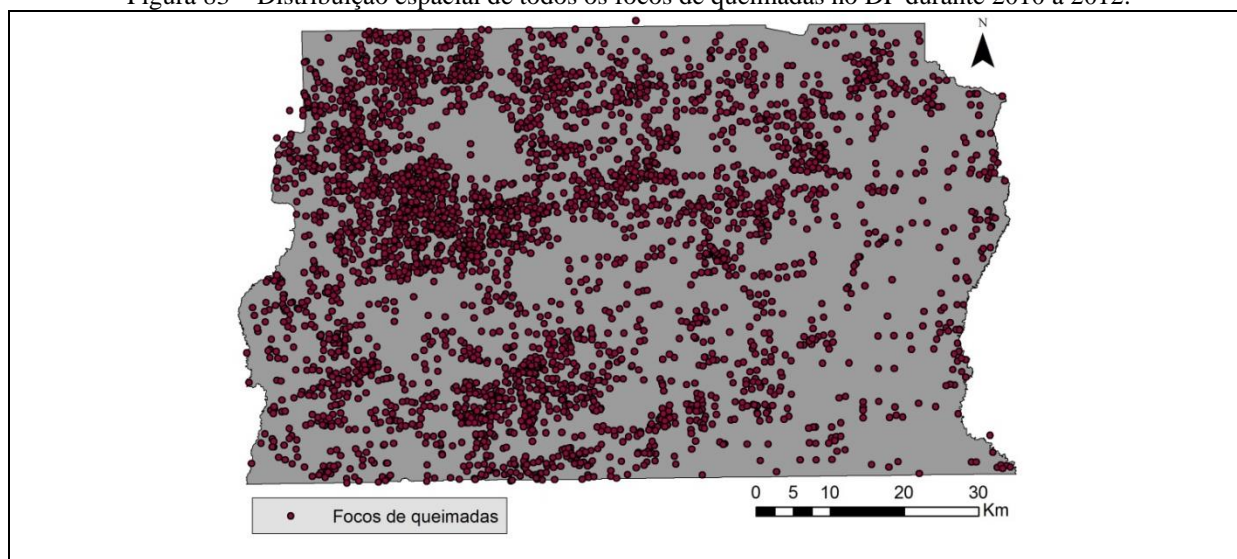


Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado – natural break (jenks).

## C.9. QUEIMADAS

Figura 83 – Distribuição espacial de todos os focos de queimadas no DF durante 2010 a 2012.

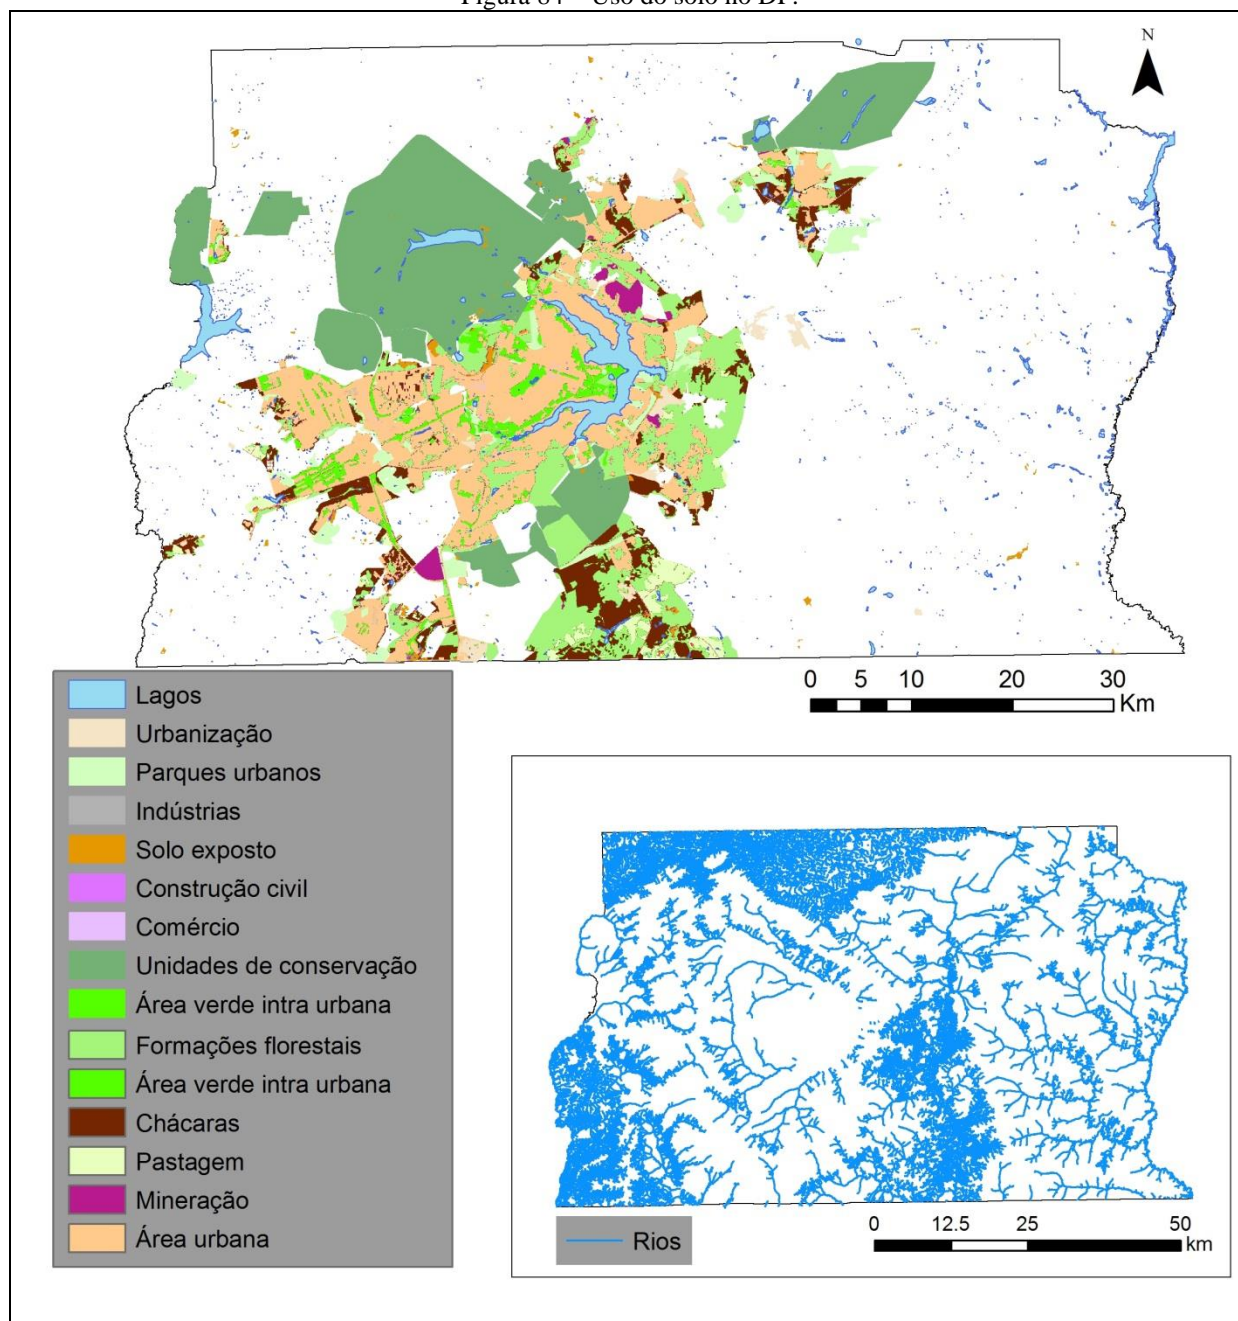


Fonte: Produção do próprio autor.



## C.10. USO DO SOLO


Figura 84 – Uso do solo no DF.



Fonte: Produção do próprio autor.

### C.11. RODOVIÁRIAS E TERMINAIS DE ÔNIBUS

Figura 85 - Distribuição espacial do número de linhas por rodoviárias e terminais de ônibus no DF.

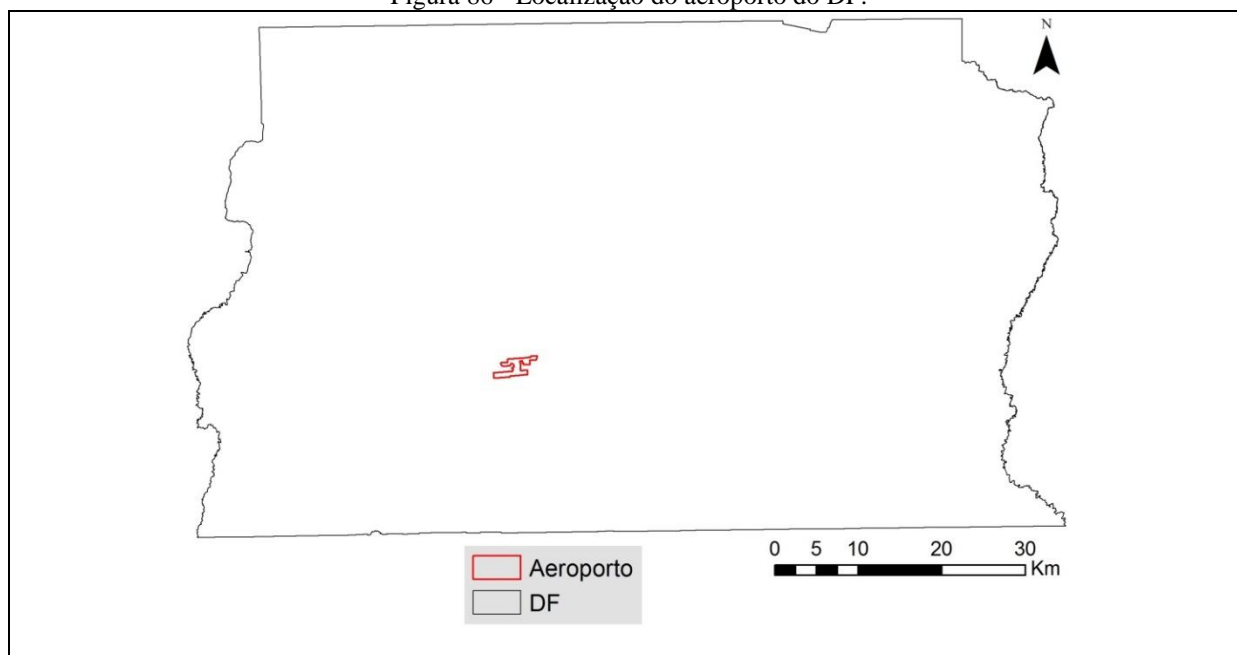


Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado – natural breaks (jenks).

### C.12. AEROPORTO

Figura 86 - Localização do aeroporto do DF.

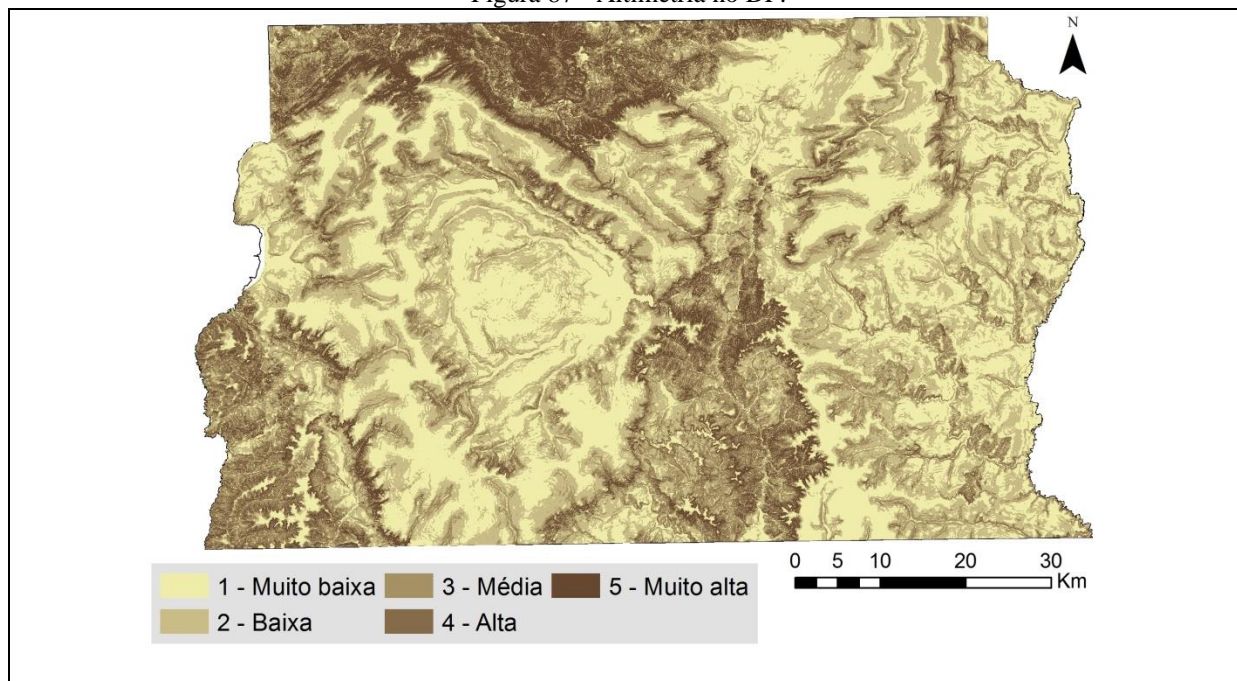


Fonte: Produção do próprio autor.



## C.13. ALTIMETRIA


Figura 87 - Altimetria no DF.



Fonte: Produção do próprio autor.

## C.14. UMIDADE

Figura 88 – Umidade relativa do ar no DF.




Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado – natural breaks (jenks).

## C.15. TEMPERATURA

Figura 89 – Temperatura no DF.




Fonte: Produção do próprio autor.

Nota: Método de classificação utilizado – natural breaks (jenks).

## C.16. IMAGEM AÉREA

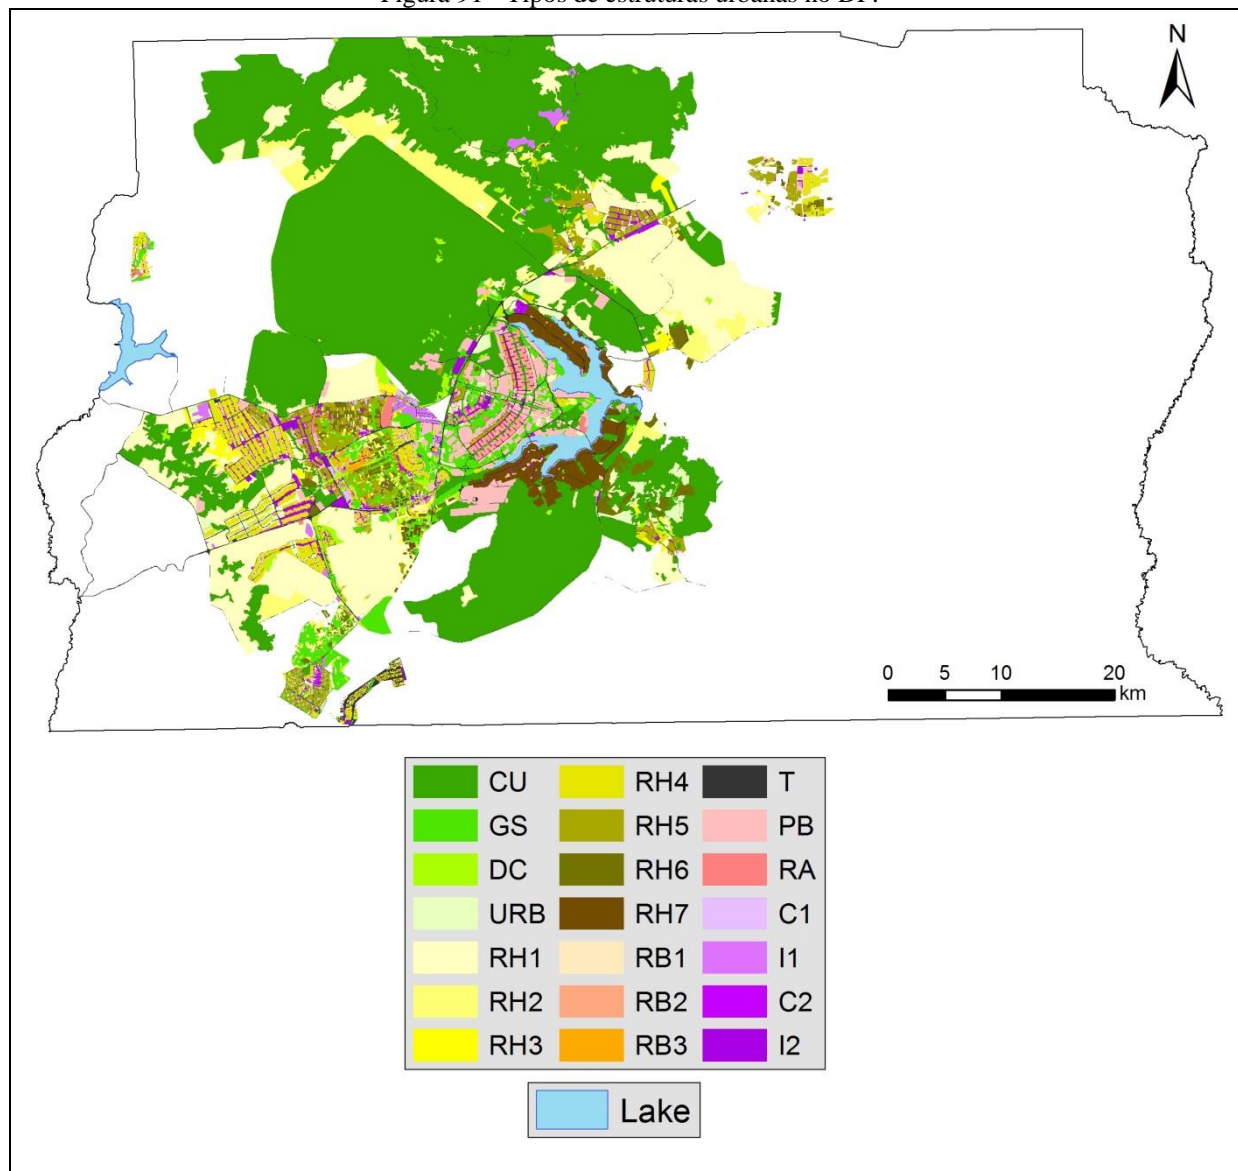
Figura 90 - Mosaico de ortofotos do DF.



Fonte: Produção do próprio autor.

## C.17. TIPOS DE ESTRUTURAS URBANAS

Figura 91 - Tipos de estruturas urbanas no DF.



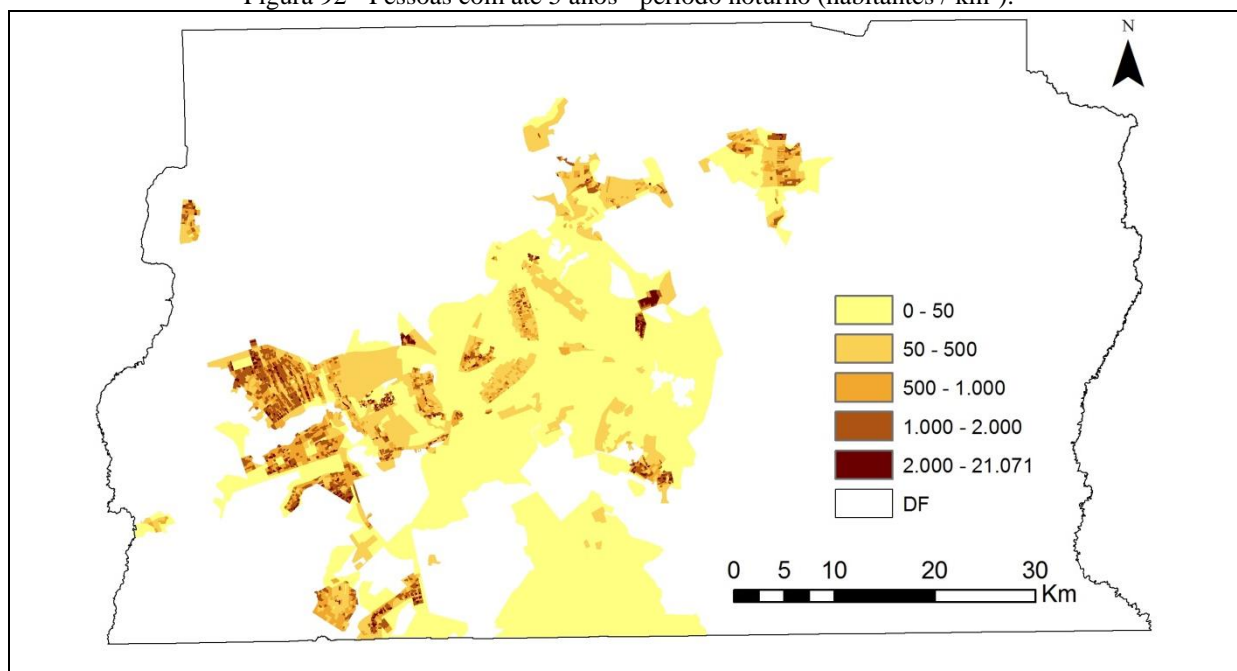
Fonte: Produção do próprio autor.

**APÊNDICE D – RESULTADO DA ESPACIALIZAÇÃO DOS DADOS PARA A  
ANÁLISE DE ÁREAS PRIORITÁRIAS PARA MENSURAÇÃO DA EXPOSIÇÃO  
HUMANA À POLUIÇÃO ATMOSFÉRICA**

## D.1. CRITÉRIO EXPOSIÇÃO HUMANA

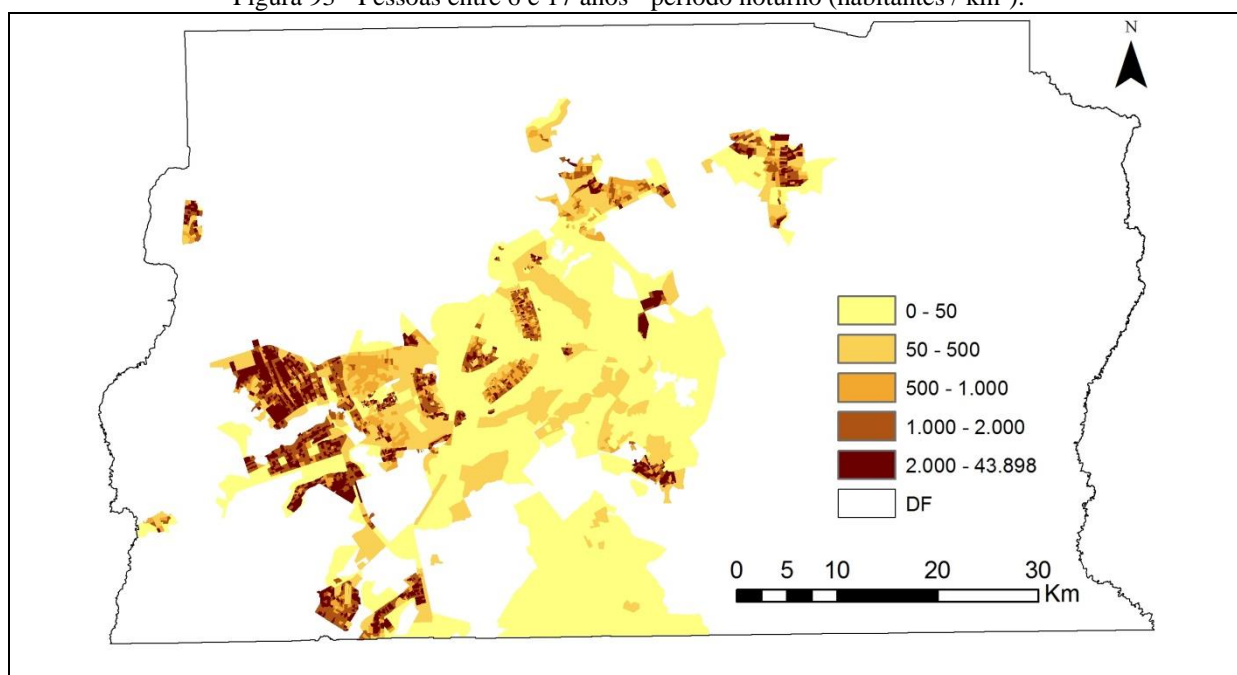
### D.1.1. Presença humana

Figura 92 - Pessoas com até 5 anos - período noturno (habitantes / km<sup>2</sup>).



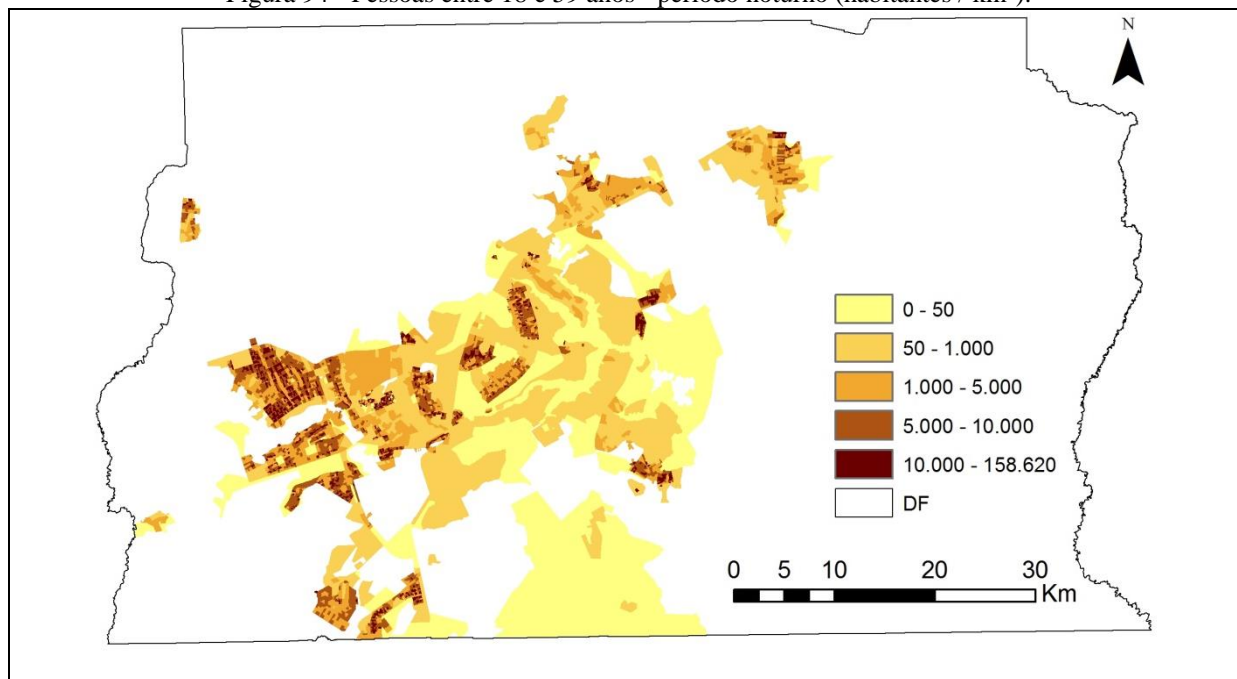
Fonte: Produção do próprio autor.

Figura 93 - Pessoas entre 6 e 17 anos - período noturno (habitantes / km<sup>2</sup>).

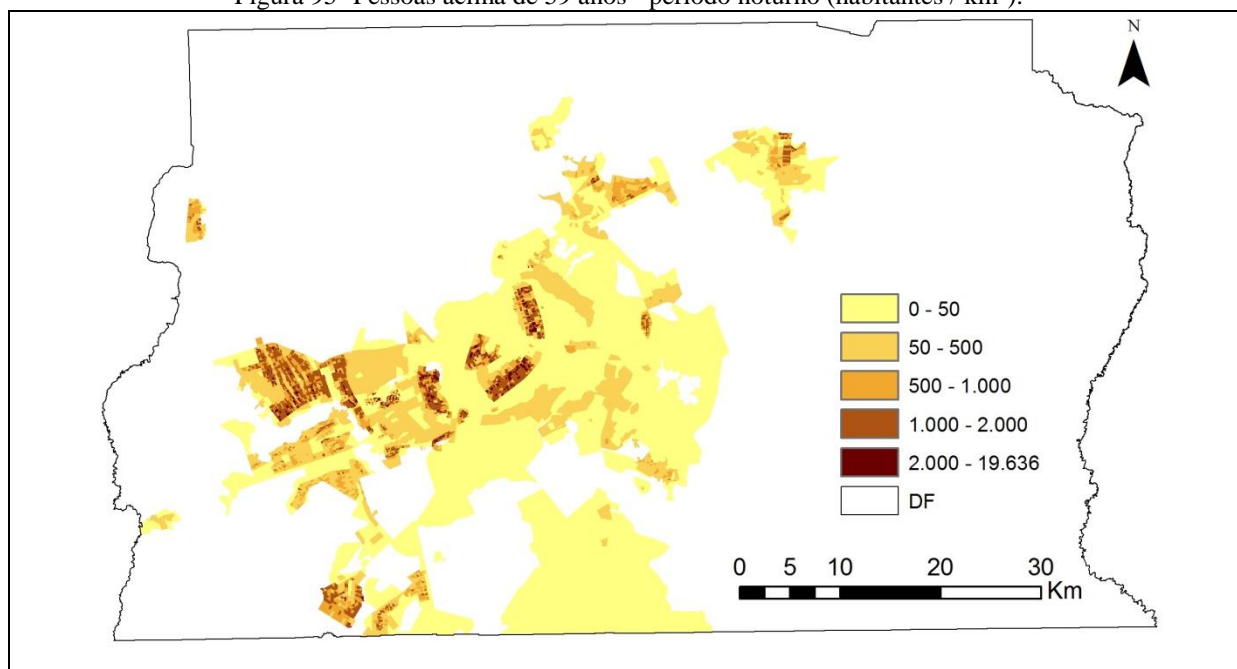


Fonte: Produção do próprio autor.

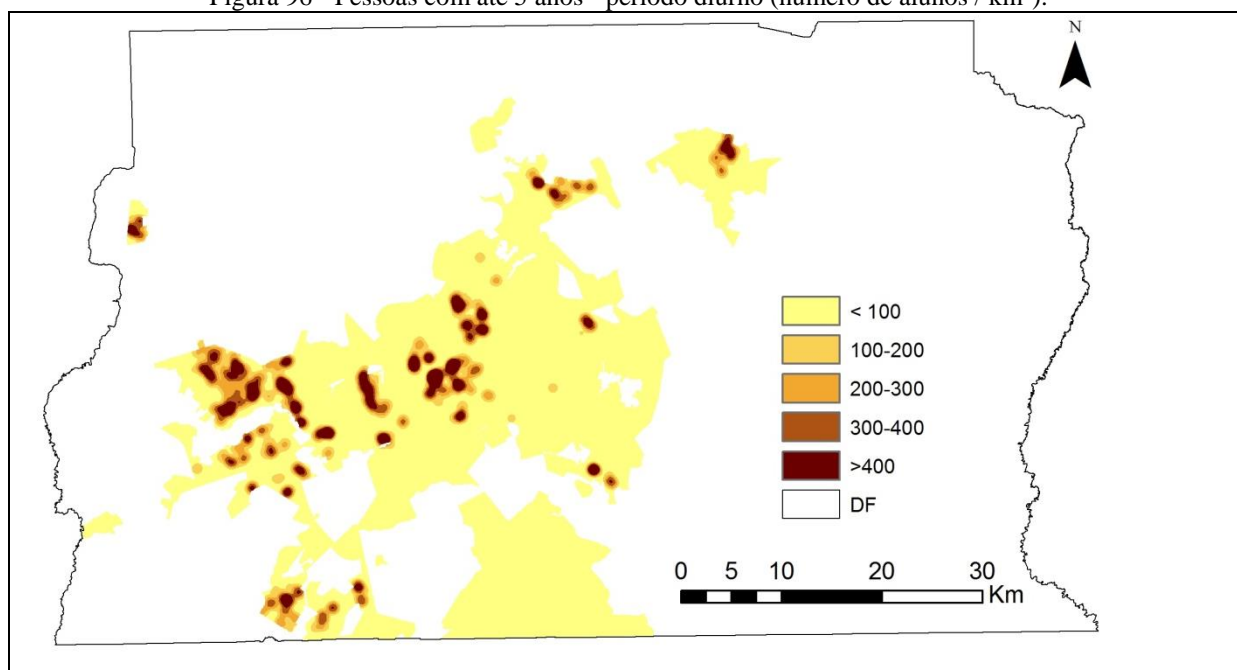


Figura 94 - Pessoas entre 18 e 59 anos - período noturno (habitantes / km<sup>2</sup>).

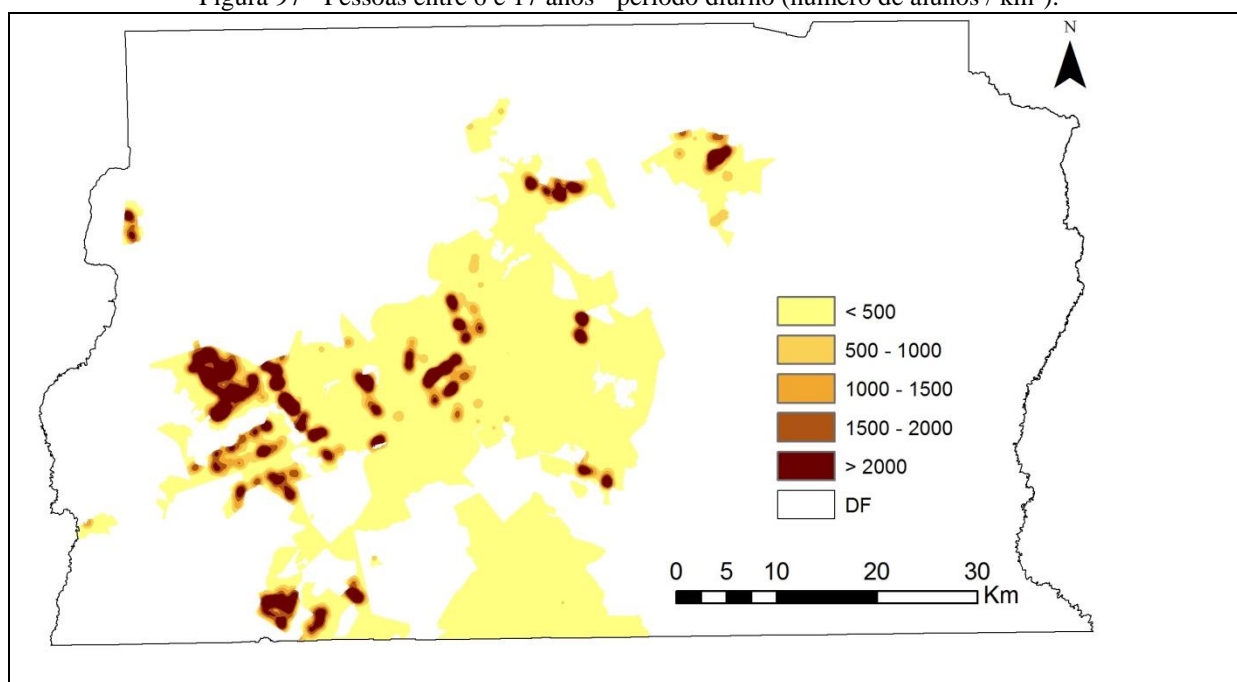
Fonte: Produção do próprio autor.

Figura 95 - Pessoas acima de 59 anos - período noturno (habitantes / km<sup>2</sup>).

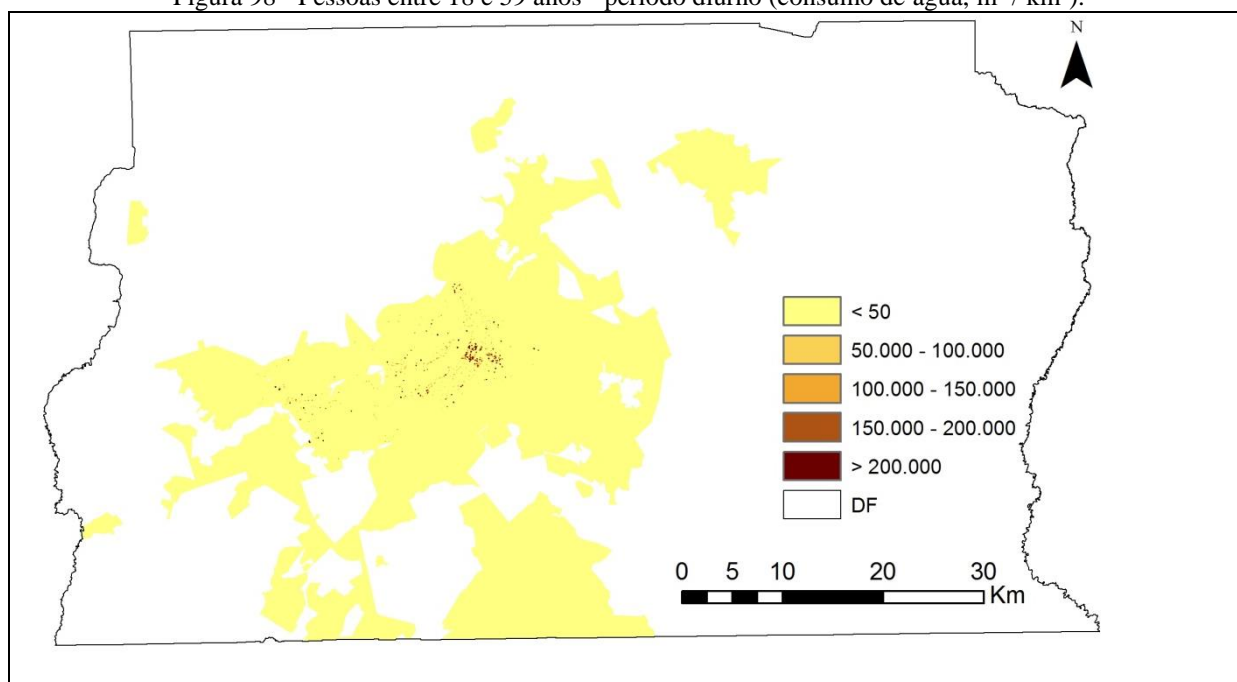
Fonte: Produção do próprio autor.

Figura 96 - Pessoas com até 5 anos - período diurno (número de alunos / km<sup>2</sup>).

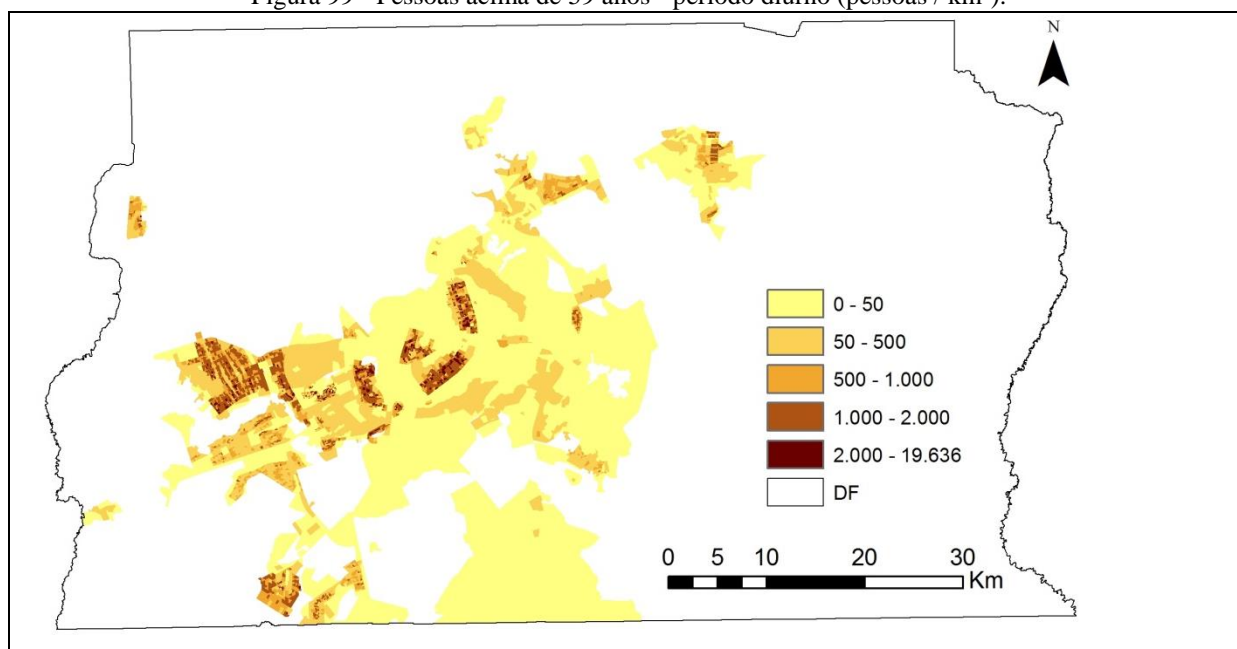
Fonte: Produção do próprio autor.

Figura 97 - Pessoas entre 6 e 17 anos - período diurno (número de alunos / km<sup>2</sup>).

Fonte: Produção do próprio autor.

Figura 98 - Pessoas entre 18 e 59 anos - período diurno (consumo de água, m<sup>3</sup> / km<sup>2</sup>).

Fonte: Produção do próprio autor.

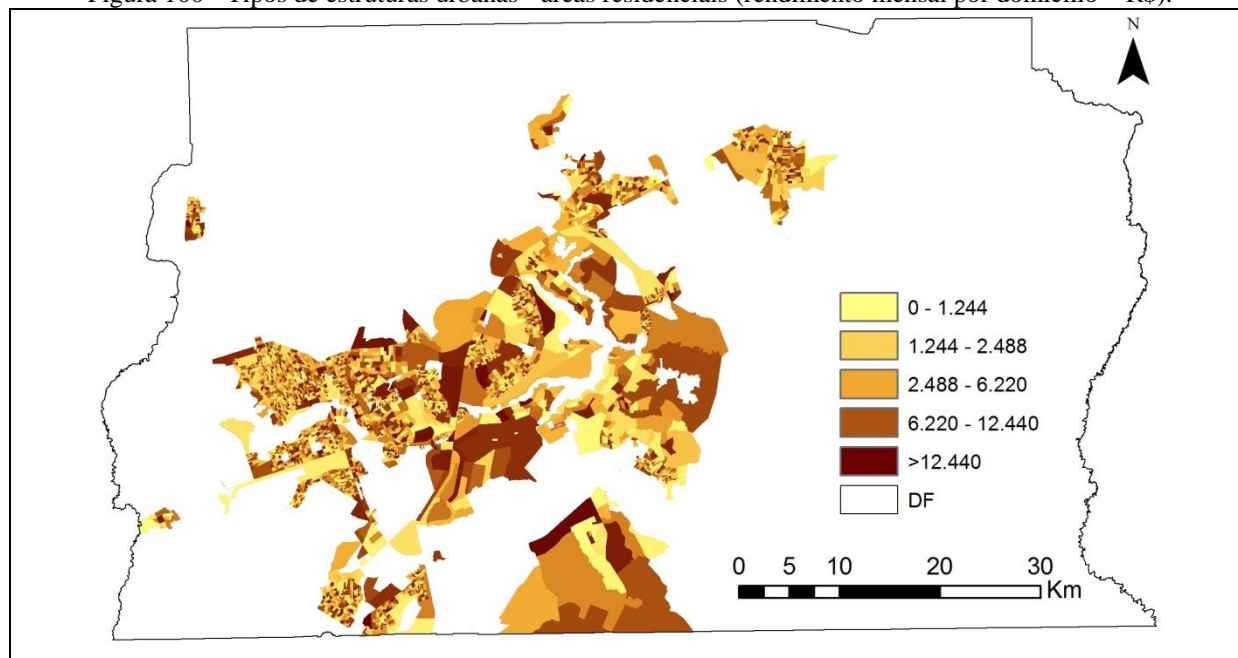
Figura 99 - Pessoas acima de 59 anos - período diurno (pessoas / km<sup>2</sup>).

Fonte: Produção do próprio autor.



### D.1.2. Tipos de estruturas das edificações

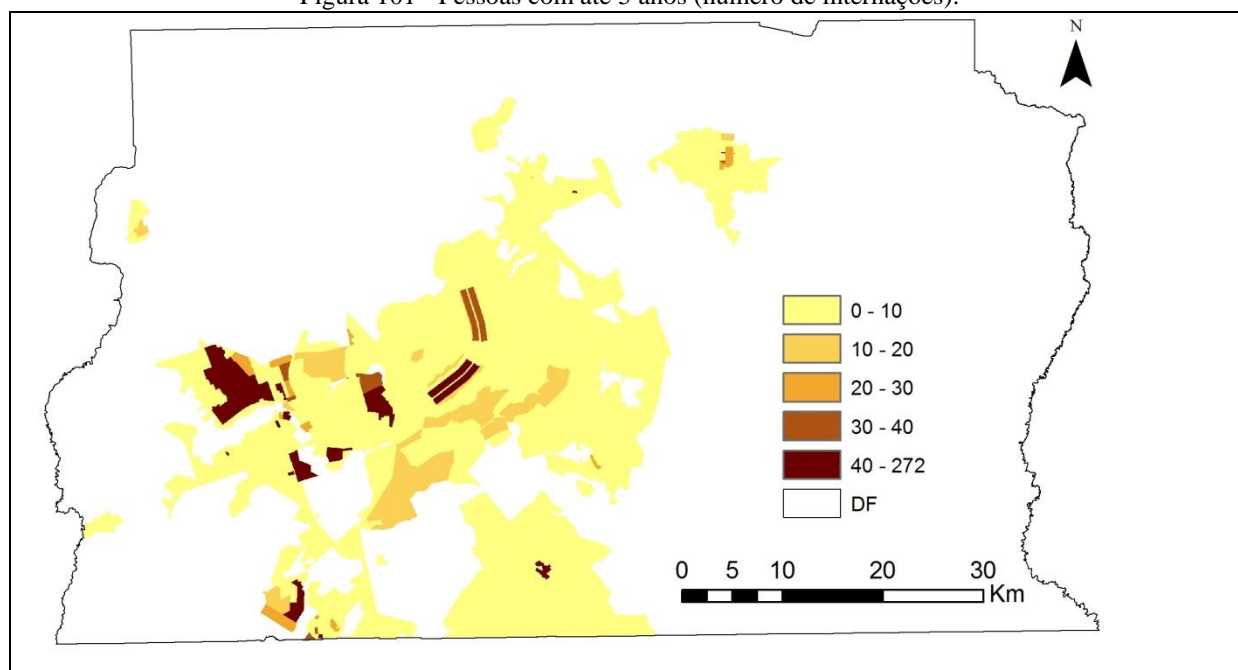
Figura 100 - Tipos de estruturas urbanas - áreas residenciais (rendimento mensal por domicílio – R\$).



Fonte: Produção do próprio autor.

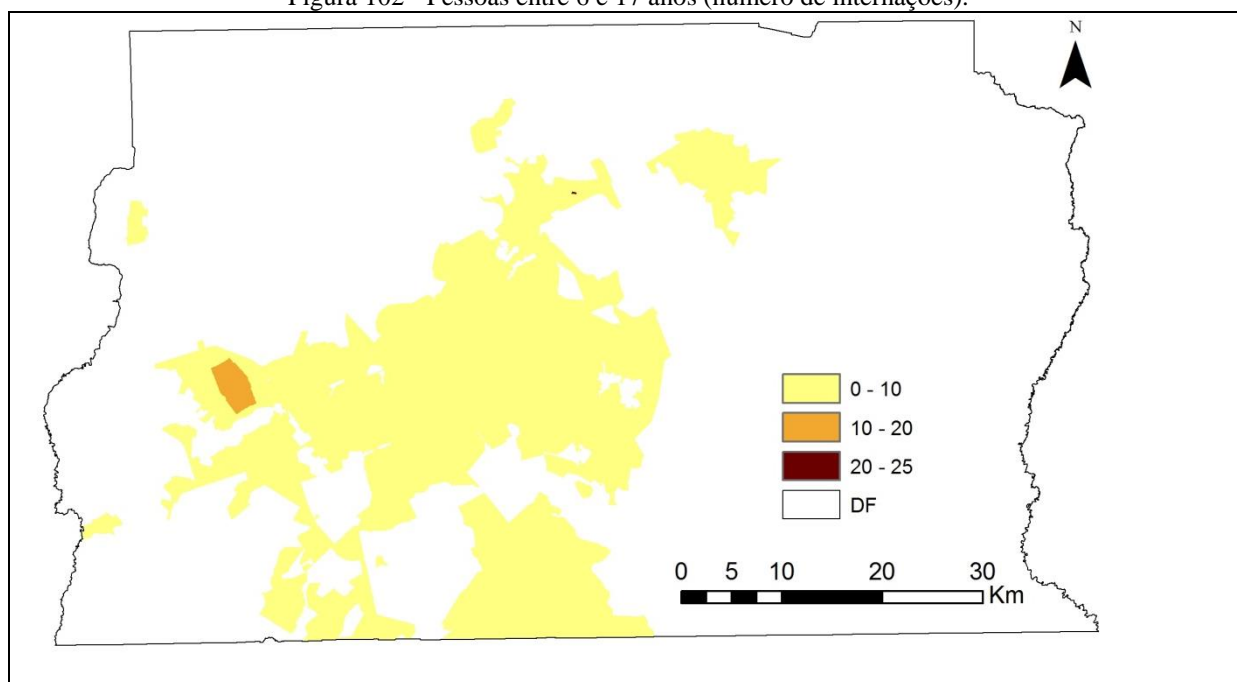
### D.1.3. Efeitos no ser humano

Figura 101 - Pessoas com até 5 anos (número de internações).



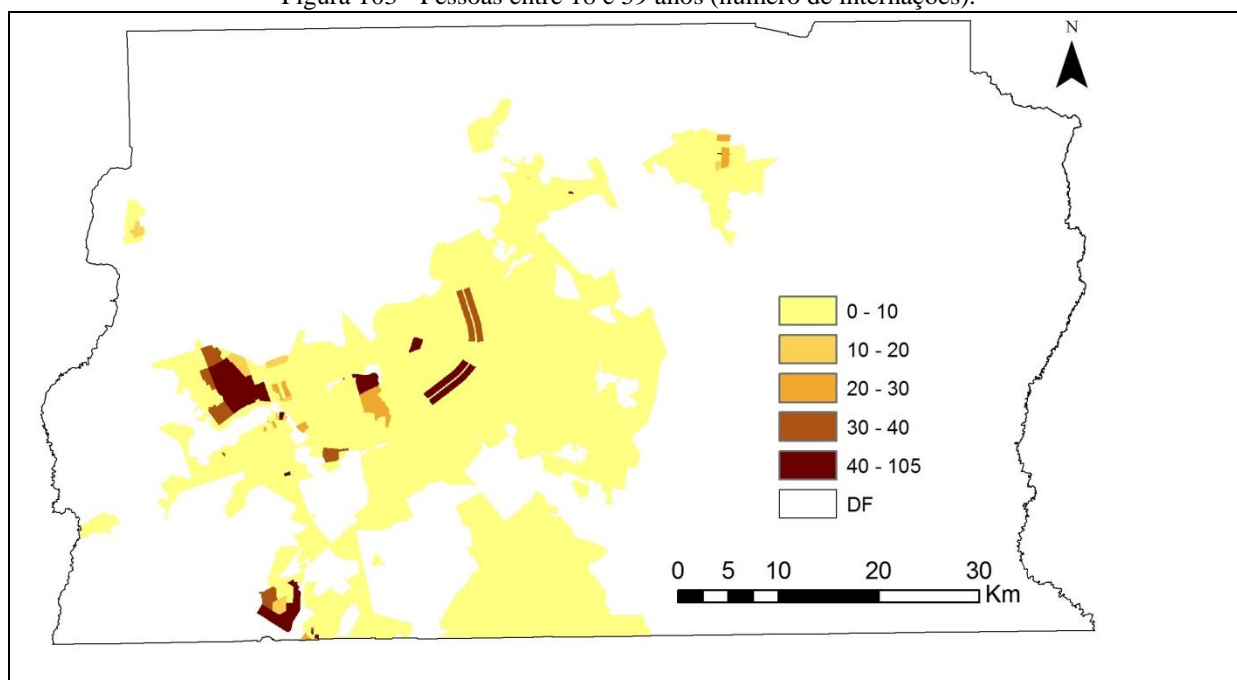
Fonte: Produção do próprio autor.

Figura 102 - Pessoas entre 6 e 17 anos (número de internações).



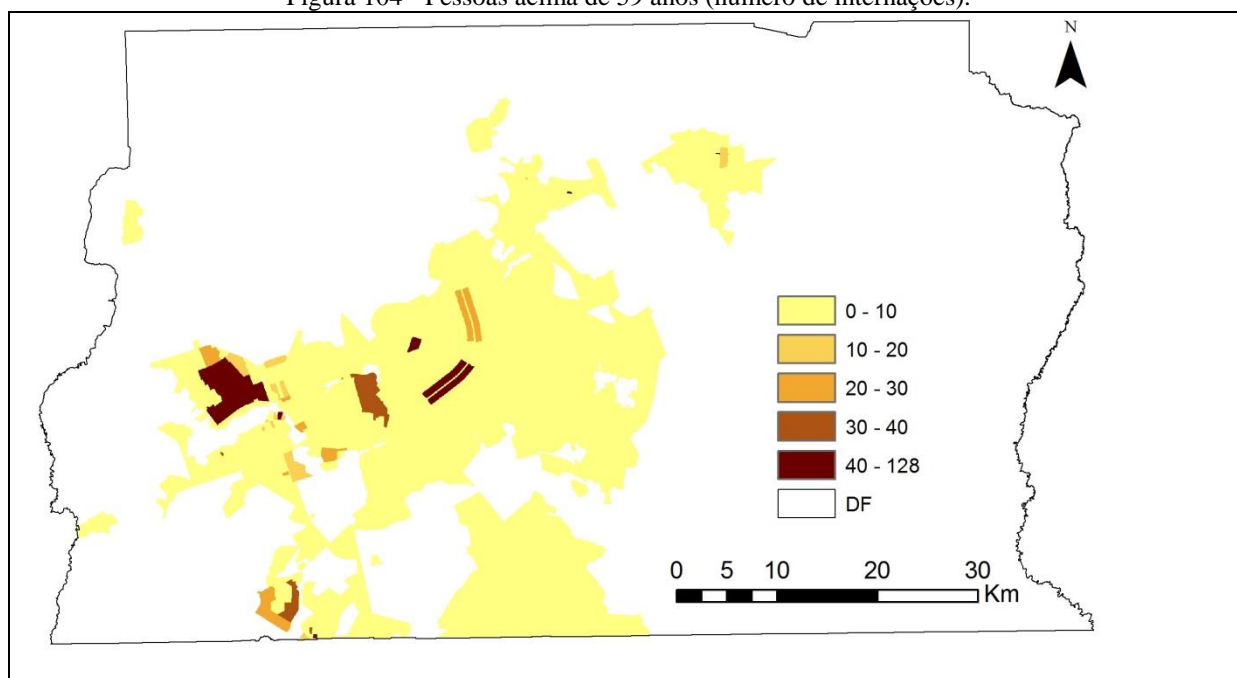
Fonte: Produção do próprio autor.

Figura 103 - Pessoas entre 18 e 59 anos (número de internações).



Fonte: Produção do próprio autor.

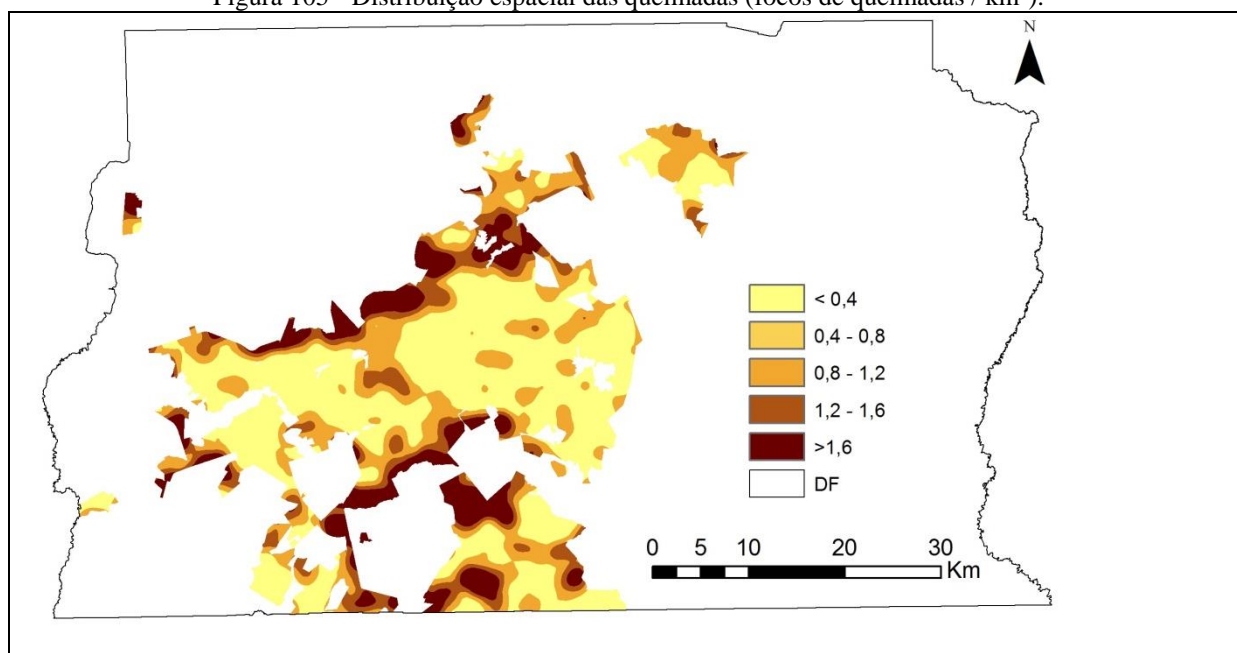
Figura 104 - Pessoas acima de 59 anos (número de internações).



Fonte: Produção do próprio autor.

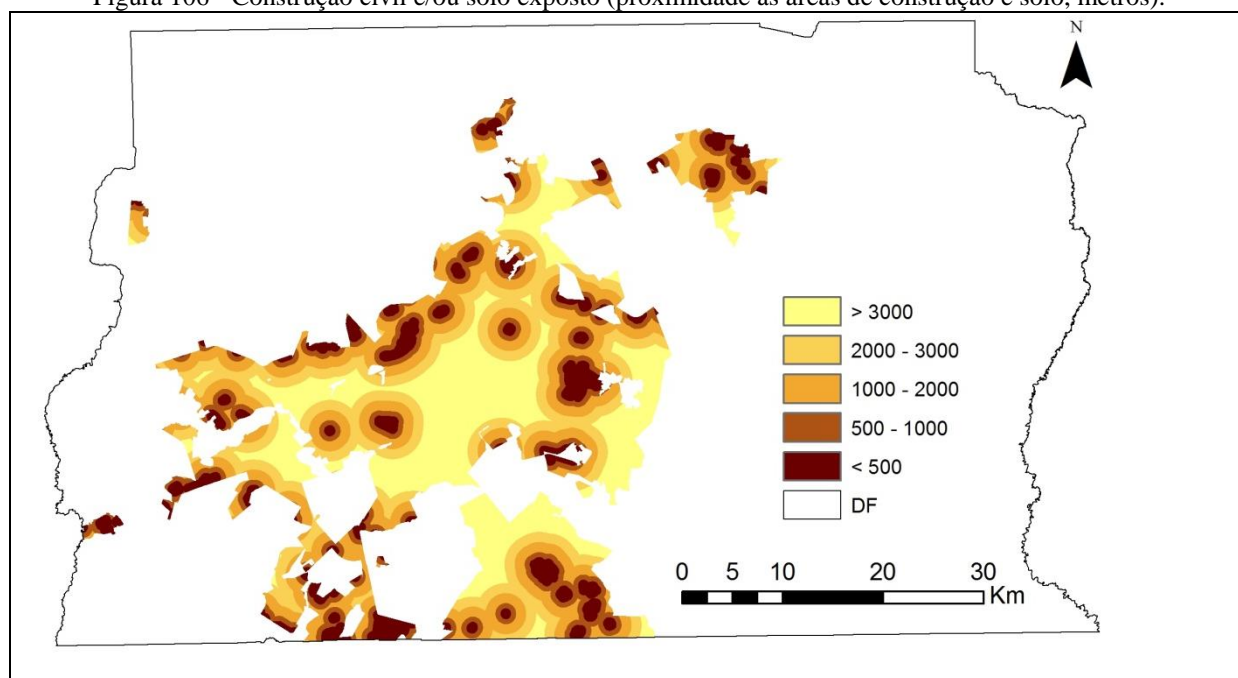
## D.2. CRITÉRIO FONTES DE POLUIÇÃO

### D.2.1. Fixas

Figura 105 - Distribuição espacial das queimadas (focos de queimadas / km<sup>2</sup>).

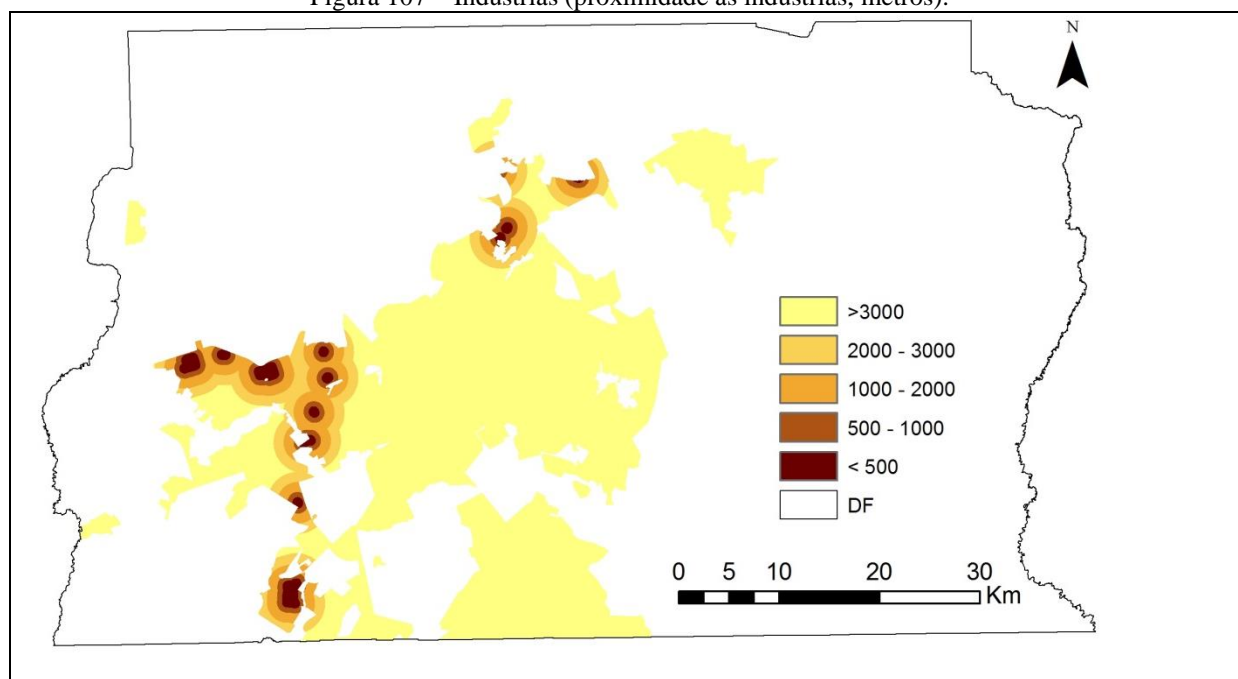
Fonte: Produção do próprio autor.

Figura 106 - Construção civil e/ou solo exposto (proximidade às áreas de construção e solo, metros).



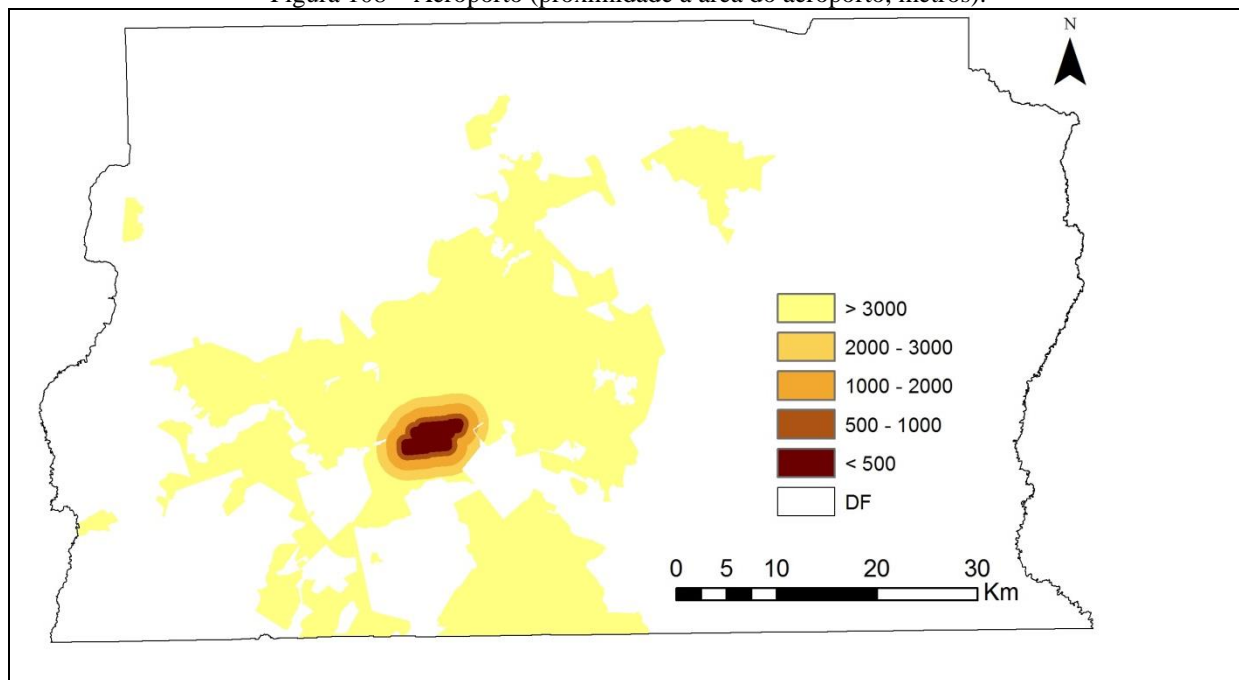
Fonte: Produção do próprio autor.

Figura 107 – Indústrias (proximidade às indústrias, metros).

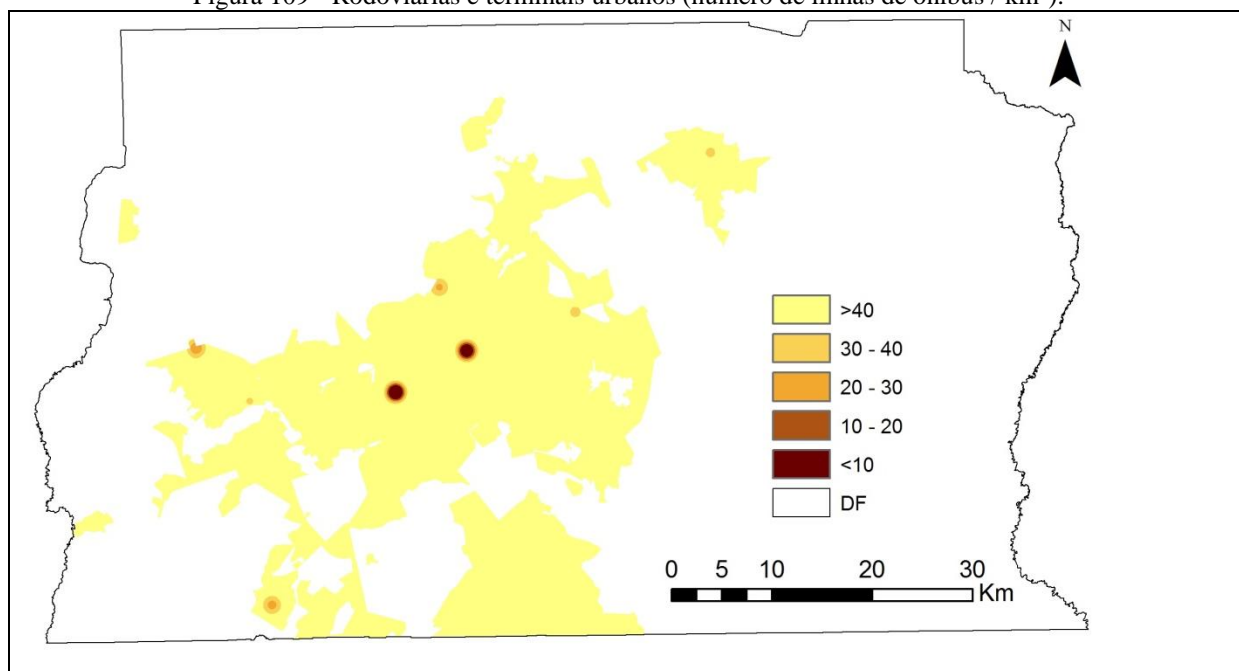


Fonte: Produção do próprio autor.

Figura 108 – Aeroporto (proximidade à área do aeroporto, metros).



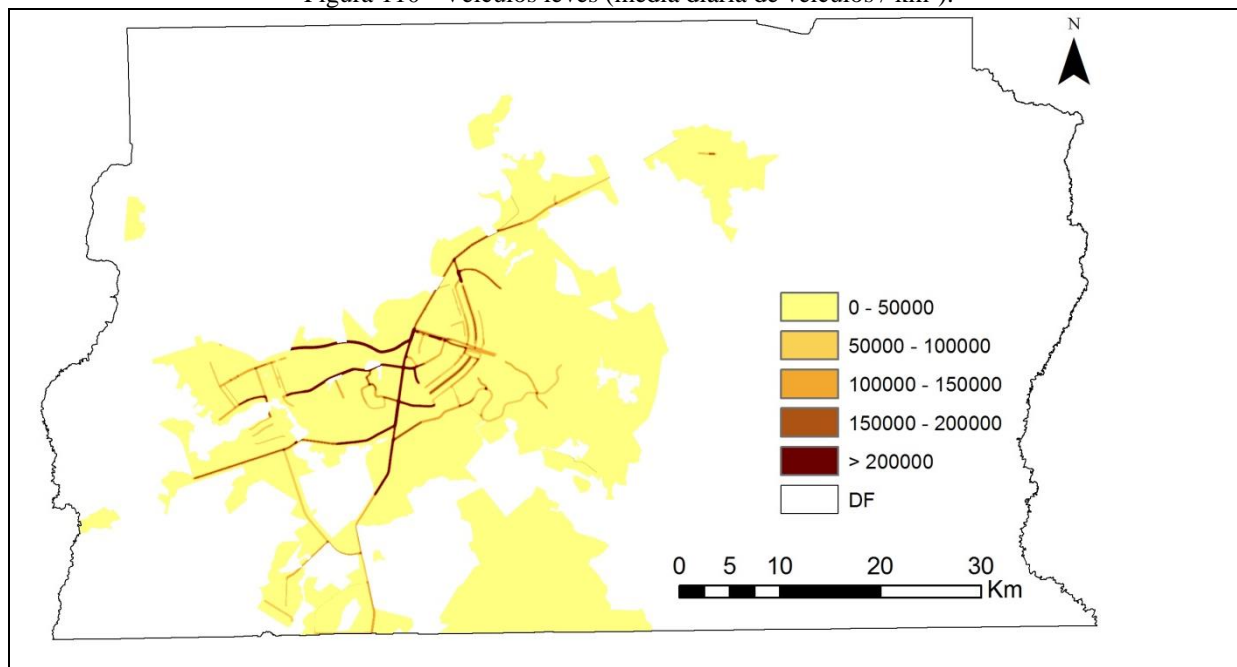
Fonte: Produção do próprio autor.

Figura 109 - Rodoviárias e terminais urbanos (número de linhas de ônibus / km<sup>2</sup>).

Fonte: Produção do próprio autor.

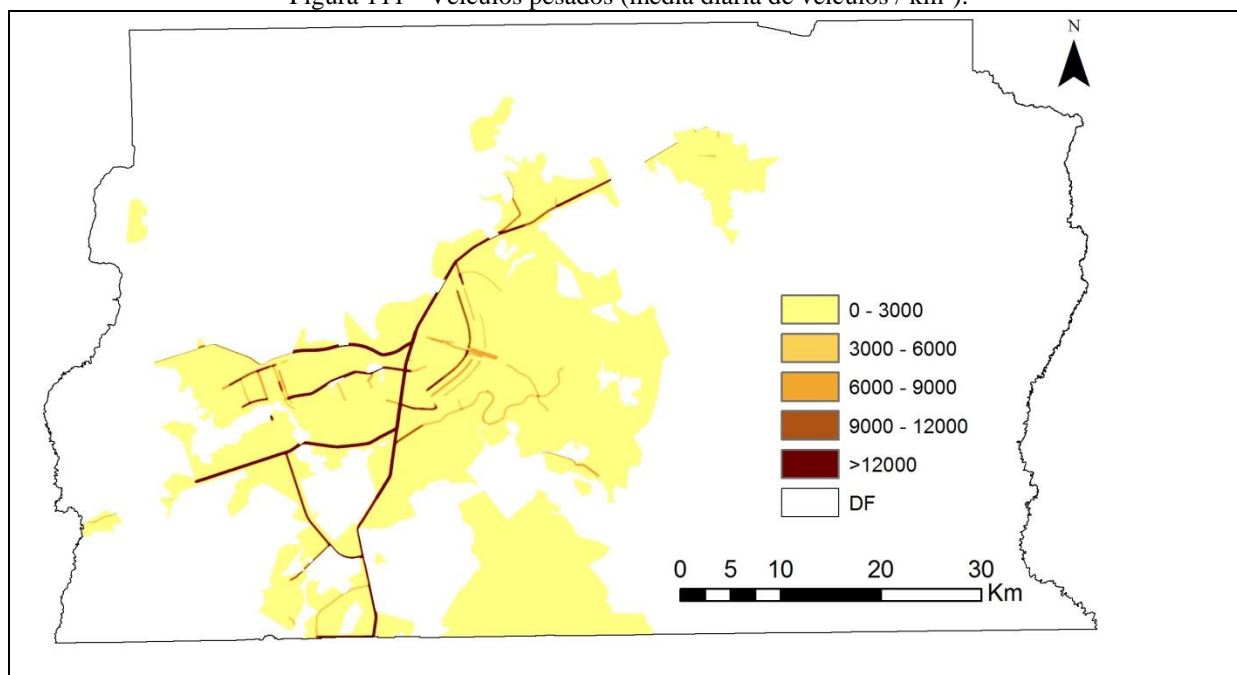
## D.2.2. Móveis

Figura 110 - Veículos leves (média diária de veículos / km<sup>2</sup>).



Fonte: Produção do próprio autor.

Figura 111 - Veículos pesados (média diária de veículos / km<sup>2</sup>).

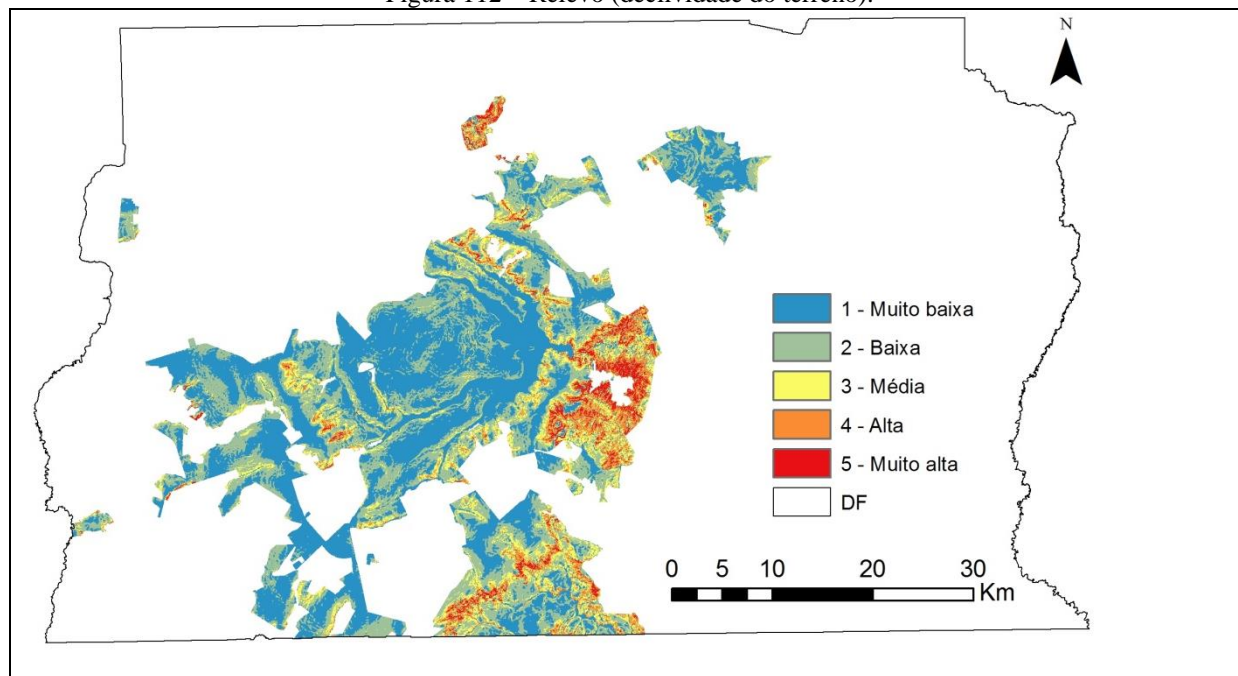


Fonte: Produção do próprio autor.



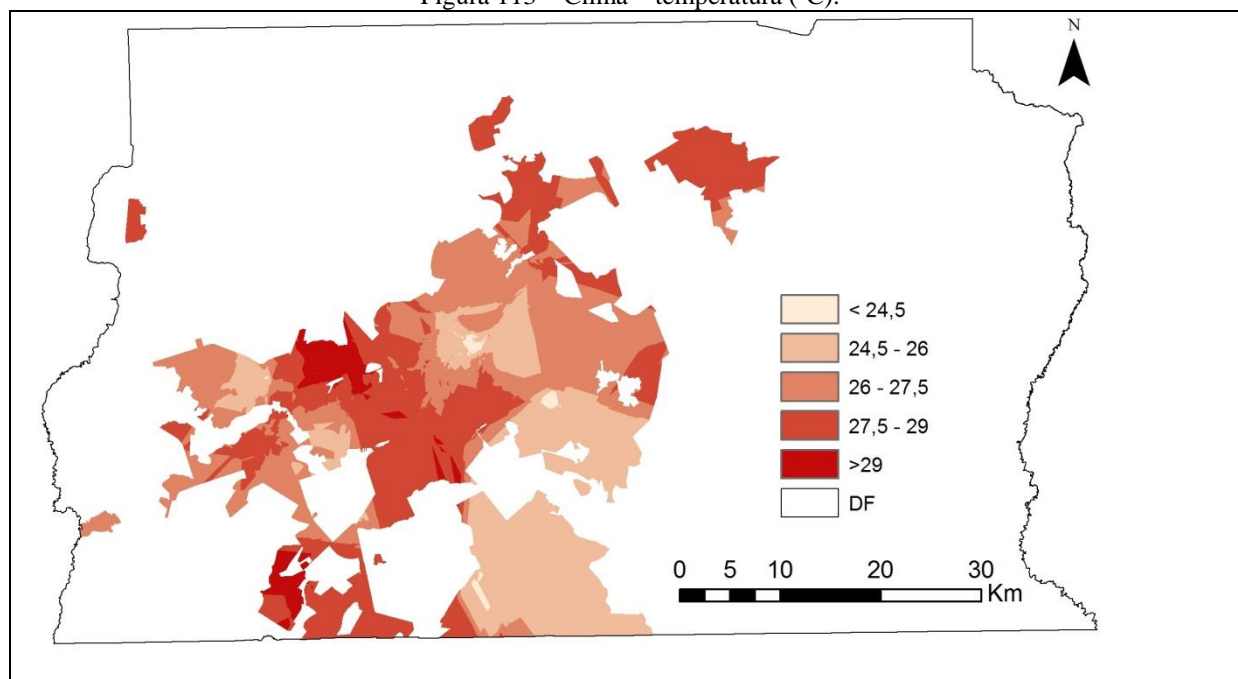
## D.3. CRITÉRIO CARACTERÍSTICA DO AMBIENTE

Figura 112 – Relevo (declividade do terreno).



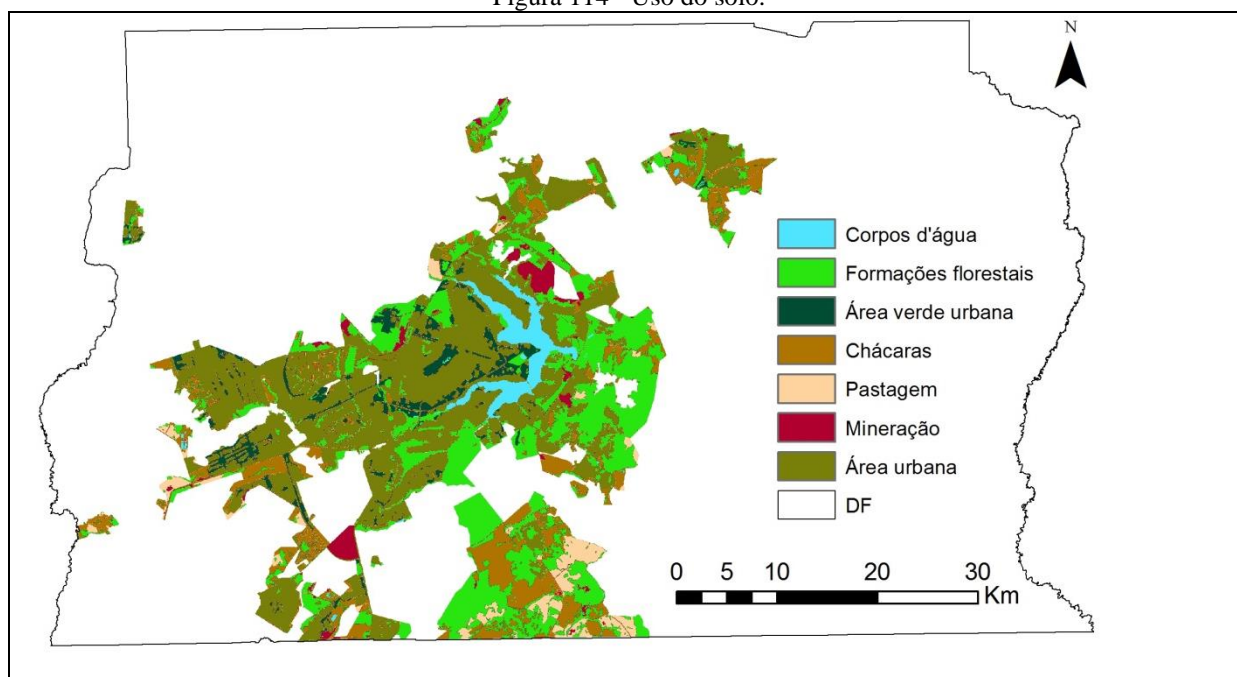
Fonte: Produção do próprio autor.

Figura 113 – Clima – temperatura (°C).



Fonte: Produção do próprio autor.

Figura 114 - Uso do solo.



Fonte: Produção do próprio autor.



## **APÊNDICE E – SCRIPTS UTILIZADOS**

## E.1. MODELO QUANTILE REGRESSION (UMA VARIÁVEL PREDITORA)

O seguinte script apresenta um exemplo do modelo quantile regression para uma única variável preditora. A variável preditora considerada neste script é nomeada como *predictor variable A*. Essa variável foi medida em 15 diferentes situações, que na presente tese, são os tamanhos dos *buffers*.

```
###Import dataset
mydata<-read.csv("C:/Users/mydata.csv")
View(mydata)
attach(mydata)

###Install the package for quantile regression
install.packages("quantreg")
library(quantreg)

###Specification of each variable
##Response variable
Y <- cbind(total hospital admissions / population)
##Predictor variables (per buffer)
X1 <- cbind(predictor variable A_buffer 1)
X2 <- cbind(predictor variable A_buffer 2)
X3 <- cbind(predictor variable A_buffer 3)
X4 <- cbind(predictor variable A_buffer 4)
X5 <- cbind(predictor variable A_buffer 5)
X6 <- cbind(predictor variable A_buffer 6)
X7 <- cbind(predictor variable A_buffer 7)
X8 <- cbind(predictor variable A_buffer 8)
X9 <- cbind(predictor variable A_buffer 9)
X10 <- cbind(predictor variable A_buffer 10)
X11 <- cbind(predictor variable A_buffer 11)
X12 <- cbind(predictor variable A_buffer 12)
X13 <- cbind(predictor variable A_buffer 13)
X14 <- cbind(predictor variable A_buffer 14)
X15 <- cbind(predictor variable A_buffer 15)

###Calculation of IQR
quantile(X1, .75) - quantile(X1, .25)
quantile(X2, .75) - quantile(X2, .25)
quantile(X3, .75) - quantile(X3, .25)
quantile(X4, .75) - quantile(X4, .25)
quantile(X5, .75) - quantile(X5, .25)
quantile(X6, .75) - quantile(X6, .25)
quantile(X7, .75) - quantile(X7, .25)
quantile(X8, .75) - quantile(X8, .25)
quantile(X9, .75) - quantile(X9, .25)
quantile(X10, .75) - quantile(X10, .25)
quantile(X11, .75) - quantile(X11, .25)
quantile(X12, .75) - quantile(X12, .25)
quantile(X13, .75) - quantile(X13, .25)
```

```

quantile(X14, .75) - quantile(X14, .25)
quantile(X15, .75) - quantile(X15, .25)

###Quantile regression model
iqr<-X1/(quantile(X1, .75) - quantile(X1, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile1.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X1,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X1",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
abline(lm(Y~X1, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile1.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X2/(quantile(X2, .75) - quantile(X2, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile2.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X2,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X2",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
abline(lm(Y~X2, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile2.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X3/(quantile(X3, .75) - quantile(X3, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile3.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X3,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X3",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
abline(lm(Y~X3, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile3.png",width=8,height=6,units="in",res=100)
dev.off()

```

```

##
iqr<-X4/(quantile(X4, .75) - quantile(X4, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile4.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X4,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X4",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
abline(lm(Y~X4, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile4.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X5/(quantile(X5, .75) - quantile(X5, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile5.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X5,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X5",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
abline(lm(Y~X5, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile5.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X6/(quantile(X6, .75) - quantile(X6, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile6.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X6,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X6",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
abline(lm(Y~X6, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile6.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X7/(quantile(X7, .75) - quantile(X7, .25))
taus <- c(.05,.1,.25,.75,.9,.95)

```

```

mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile7.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X7,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X7",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
  abline(lm(Y~X7, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile7.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X8/(quantile(X8, .75) - quantile(X8, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile8.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X8,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X8",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
  abline(lm(Y~X8, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile8.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X9/(quantile(X9, .75) - quantile(X9, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile9.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X9,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X9",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
  abline(lm(Y~X9, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile9.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X10/(quantile(X10, .75) - quantile(X10, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile10.txt")

```

```

plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X10,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X10",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
  abline(lm(Y~X10, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile10.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X11/(quantile(X11, .75) - quantile(X11, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile11.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X11,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X11",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
  abline(lm(Y~X11, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile11.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X12/(quantile(X12, .75) - quantile(X12, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile12.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X12,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X12",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
  abline(lm(Y~X12, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile12.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X13/(quantile(X13, .75) - quantile(X13, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile13.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X13,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X13",ylab="Hospital Admissions",pch="")

```

```

for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
  abline(lm(Y~X13, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile13.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X14/(quantile(X14, .75) - quantile(X14, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile14.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X14,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X14",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
  abline(lm(Y~X14, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile14.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqr<-X15/(quantile(X15, .75) - quantile(X15, .25))
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile15.txt")
plot(mod)
  par(mfrow=c(1,1))
plot(mydata$X15,mydata$,xlim=c(0,max),ylim=c(0,max),xlab="X15",ylab="Hospital Admissions",pch="")
for (i in 1:length(taus)) {
  abline(mod$coefficients[,i], col=i, lwd=1.2)
}
# legend(locator(1),"99th Percentile", bty="n",cex=.6)
# legend(locator(1),"95th Percentile", bty="n",cex=.6)
  abline(lm(Y~X15, data=mydata), col="blue", lty=2, lwd=1.7)
dev.copy(png,"myfile15.png",width=8,height=6,units="in",res=100)
dev.off()
##

```

## E.2. MODELO QUANTILE REGRESSION (MAIS DE UMA VARIÁVEL PREDITORA)

O seguinte script apresenta um exemplo do modelo quantile regression de uma variável preditora *A* sendo controlada pela variável *Income*. As variáveis *A* e *Income* foram medidas em 15 diferentes situações, que na presente tese, são os tamanhos dos *buffers*.

```
###Import dataset
mydata<-read.csv("C:/Users/mydata.csv")
View(mydata)
attach(mydata)

###Install the package for quantile regression
install.packages("quantreg")
library(quantreg)

###Specification of each variable
##Response variable
Y <- cbind(total hospital admissions / population)
##Predictor variable A (per buffer)
X1 <- cbind(A_buffer 1)
X2 <- cbind(A_buffer 2)
X3 <- cbind(A_buffer 3)
X4 <- cbind(A_buffer 4)
X5 <- cbind(A_buffer 5)
X6 <- cbind(A_buffer 6)
X7 <- cbind(A_buffer 7)
X8 <- cbind(A_buffer 8)
X9 <- cbind(A_buffer 9)
X10 <- cbind(A_buffer 10)
X11 <- cbind(A_buffer 11)
X12 <- cbind(A_buffer 12)
X13 <- cbind(A_buffer 13)
X14 <- cbind(A_buffer 14)
X15 <- cbind(A_buffer 15)
##Predictor variable Income – variable control (per buffer)
Z1 <- cbind(Income_buffer 1)
Z2 <- cbind(Income_buffer 2)
Z3 <- cbind(Income_buffer 3)
Z4 <- cbind(Income_buffer 4)
Z5 <- cbind(Income_buffer 5)
Z6 <- cbind(Income_buffer 6)
Z7 <- cbind(Income_buffer 7)
Z8 <- cbind(Income_buffer 8)
Z9 <- cbind(Income_buffer 9)
Z10 <- cbind(Income_buffer 10)
Z11 <- cbind(Income_buffer 11)
Z12 <- cbind(Income_buffer 12)
Z13 <- cbind(Income_buffer 13)
Z14 <- cbind(Income_buffer 14)
Z15 <- cbind(Income_buffer 15)
```



```

###Calculation of IQR (predictor variable A)
quantile(X1, .75) - quantile(X1, .25)
quantile(X2, .75) - quantile(X2, .25)
quantile(X3, .75) - quantile(X3, .25)
quantile(X4, .75) - quantile(X4, .25)
quantile(X5, .75) - quantile(X5, .25)
quantile(X6, .75) - quantile(X6, .25)
quantile(X7, .75) - quantile(X7, .25)
quantile(X8, .75) - quantile(X8, .25)
quantile(X9, .75) - quantile(X9, .25)
quantile(X10, .75) - quantile(X10, .25)
quantile(X11, .75) - quantile(X11, .25)
quantile(X12, .75) - quantile(X12, .25)
quantile(X13, .75) - quantile(X13, .25)
quantile(X14, .75) - quantile(X14, .25)
quantile(X15, .75) - quantile(X15, .25)

###Quantile regression model
iqrZ<-Z1/(quantile(Z1, .75) - quantile(Z1, .25))
iqrX<-X1/(quantile(X1, .75) - quantile(X1, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile1.txt")
plot(mod)
dev.copy(png,"myfile1.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqrZ<-Z2/(quantile(Z2, .75) - quantile(Z2, .25))
iqrX<-X2/(quantile(X2, .75) - quantile(X2, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile2.txt")
plot(mod)
dev.copy(png,"myfile2.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqrZ<-Z3/(quantile(Z3, .75) - quantile(Z3, .25))
iqrX<-X3/(quantile(X3, .75) - quantile(X3, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile3.txt")
plot(mod)
dev.copy(png,"myfile3.png",width=8,height=6,units="in",res=100)
dev.off()

##
iqrZ<-Z4/(quantile(Z4, .75) - quantile(Z4, .25))
iqrX<-X4/(quantile(X4, .75) - quantile(X4, .25))
iqr<- cbind(iqrZ, iqrX)

```

```

taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile4.txt")
plot(mod)
dev.copy(png,"myfile4.png",width=8,height=6,units="in",res=100)
dev.off()

```

```

##
iqrZ<-Z5/(quantile(Z5, .75) - quantile(Z5, .25))
iqrX<-X5/(quantile(X5, .75) - quantile(X5, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile5.txt")
plot(mod)
dev.copy(png,"myfile5.png",width=8,height=6,units="in",res=100)
dev.off()

```

```

##
iqrZ<-Z6/(quantile(Z6, .75) - quantile(Z6, .25))
iqrX<-X6/(quantile(X6, .75) - quantile(X6, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile6.txt")
plot(mod)
dev.copy(png,"myfile6.png",width=8,height=6,units="in",res=100)
dev.off()

```

```

##
iqrZ<-Z7/(quantile(Z7, .75) - quantile(Z7, .25))
iqrX<-X7/(quantile(X7, .75) - quantile(X7, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile7.txt")
plot(mod)
dev.copy(png,"myfile7.png",width=8,height=6,units="in",res=100)
dev.off()

```

```

##
iqrZ<-Z8/(quantile(Z8, .75) - quantile(Z8, .25))
iqrX<-X8/(quantile(X8, .75) - quantile(X8, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile8.txt")
plot(mod)
dev.copy(png,"myfile8.png",width=8,height=6,units="in",res=100)
dev.off()

```

```
##
iqrZ<-Z9/(quantile(Z9, .75) - quantile(Z9, .25))
iqrX<-X9/(quantile(X9, .75) - quantile(X9, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile9.txt")
plot(mod)
dev.copy(png,"myfile9.png",width=8,height=6,units="in",res=100)
dev.off()
```

```
##
iqrZ<-Z10/(quantile(Z10, .75) - quantile(Z10, .25))
iqrX<-X10/(quantile(X10, .75) - quantile(X10, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile10.txt")
plot(mod)
dev.copy(png,"myfile10.png",width=8,height=6,units="in",res=100)
dev.off()
```

```
##
iqrZ<-Z11/(quantile(Z11, .75) - quantile(Z11, .25))
iqrX<-X11/(quantile(X11, .75) - quantile(X11, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile11.txt")
plot(mod)
dev.copy(png,"myfile11.png",width=8,height=6,units="in",res=100)
dev.off()
```

```
##
iqrZ<-Z12/(quantile(Z12, .75) - quantile(Z12, .25))
iqrX<-X12/(quantile(X12, .75) - quantile(X12, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile12.txt")
plot(mod)
dev.copy(png,"myfile12.png",width=8,height=6,units="in",res=100)
dev.off()
```

```
##
iqrZ<-Z13/(quantile(Z13, .75) - quantile(Z13, .25))
iqrX<-X13/(quantile(X13, .75) - quantile(X13, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile13.txt")
plot(mod)
```

```
dev.copy(png,"myfile13.png",width=8,height=6,units="in",res=100)
dev.off()
```

```
##
```

```
iqrZ<-Z14/(quantile(Z14, .75) - quantile(Z14, .25))
iqrX<-X14/(quantile(X14, .75) - quantile(X14, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile14.txt")
plot(mod)
dev.copy(png,"myfile14.png",width=8,height=6,units="in",res=100)
dev.off()
```





```
##
```

```
iqrZ<-Z15/(quantile(Z15, .75) - quantile(Z15, .25))
iqrX<-X15/(quantile(X15, .75) - quantile(X15, .25))
iqr<- cbind(iqrZ, iqrX)
taus <- c(.05,.1,.25,.75,.9,.95)
mod<-rq(Y~iqr,tau=taus,data=mydata, method="fn", model=TRUE)
summary(mod, se="rank", alph=.05)
capture.output(mod, file = "myfile15.txt")
plot(mod)
dev.copy(png,"myfile15.png",width=8,height=6,units="in",res=100)
dev.off()
```





```
##
```

**APÊNDICE F – EXEMPLOS DOS TIPOS DE ESTRUTURAS URBANAS (IMAGEM DE SATÉLITE E DETALHE DO LOCAL)**





UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Unidades de conservação (CU)	Residências	Não se aplica		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Não se aplica		
	Taxa de área verde	Alta - muito alta		
	Renda	Não se aplica		
	Tamanho do lote	Não se aplica		
	Descrição	Áreas onde a ocupação urbana é limitada. Áreas protegidas por lei.		
Espaços verdes (GS)	Residências	Não se aplica		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Não se aplica		
	Taxa de área verde	Média		
	Renda	Não se aplica		
	Tamanho do lote	Não se aplica		
	Descrição	Área verde intraurbana.		





UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Áreas degradadas (DC)	Residências	Não se aplica		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Não se aplica		
	Taxa de área verde	Baixa - muito baixa		
	Renda	Não se aplica		
	Tamanho do lote	Não se aplica		
	Descrição	Áreas de solo exposto.		
Urbanização (URB)	Residências	Não se aplica		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Não se aplica		
	Taxa de área verde	Baixa - média		
	Renda	Não se aplica		
	Tamanho do lote	Não se aplica		
	Descrição	Áreas designadas para novas áreas urbanas (em processo de construção civil)		



UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Densidade muito baixa (RH1)	Residências	Maioria 1 andar, casas pequenas		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Não se aplica		
	Taxa de área verde	Média - alta		
	Renda	Muito baixa - baixa		
	Tamanho do lote	> 2000 m <sup>2</sup>		
	Descrição	Casas pequenas. Áreas rurais em inicial processo de legalização.		
Densidade baixa (RH2)	Residências	Maioria 1 andar, casas pequenas		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Não se aplica		
	Taxa de área verde	Baixa - média		
	Renda	Média		
	Tamanho do lote	> 2000 m <sup>2</sup>		
	Descrição	Área rural em processo avançado de legalização.		



UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Área marginal (RH3)	Residências	Maioria 1 andar, casas pequenas e maioria das casas são feitas com materiais simples (madeira etc.).		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água e coleta de lixo (raramente). Não há sistema de drenagem e esgoto.		
	Taxa de área verde	Muito baixa		
	Renda	Muito baixa		
	Tamanho do lote	< 150 m <sup>2</sup>		
	Descrição	Materiais simples de construção. Área muito pobre.		
Densidade alta (RH4)	Residências	Maioria 1 andar, casas pequenas.		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Muito baixa		
	Renda	Baixa		
	Tamanho do lote	150 - 250 m <sup>2</sup>		
	Descrição	Área homogênea com alta densidade de urbanização. A maioria das casas têm telhado de amianto.		

UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Densidade média (RH5)	Residências	1 a 2 andares. Poucas casas com piscinas e pequenos jardins.		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Baixa		
	Renda	Baixa - média		
	Tamanho do lote	250 -500 m <sup>2</sup>		
	Descrição	Casas heterogêneas com poucas piscinas e pequenos jardins.		
Área de padrão alto (RH6)	Residências	A maioria com 2 andares e com piscinas.		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Média		
	Renda	Média - alta		
	Tamanho do lote	500 -1000 m <sup>2</sup>		
	Descrição	Casas de padrão elevado, unifamiliar.		







UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Área de padrão muito alto RH7	Residências	A maioria 2 andares. Praticamente 1 piscina por residência.		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Média		
	Renda	Alta – muito alta		
	Tamanho do lote	1000 -2000 m <sup>2</sup>		
	Descrição	Casa com padrão muito elevado. Mansões.		
Prédios baixos RB1	Residências	Prédios com altura máxima de até 6 andares.		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Baixa		
	Renda	Média		
	Tamanho do lote	Não se aplica		
	Descrição	Prédios de até 6 andares em áreas designadas para esse uso.		





UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Área nobre, prédios baixos RB2	Residências	Prédios de até 6 andares. Área nobre.		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Alta – muito alta		
	Renda	Média - alta		
	Tamanho do lote	Não se aplica		
	Descrição	Prédios de até 6 andares em áreas designadas para esse uso. Área nobre.		
Prédios altos RB3	Residências	Prédios de até 35 andares.		
	Comércio	Alguns prédios com comércio no piso térreo.		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Baixa		
	Renda	Média		
	Tamanho do lote	Não se aplica		
	Descrição	Prédios de até 35 andares. Condomínios com estrutura que fornecem piscinas, quadras de esporte etc. Algumas lojas no piso do térreo.		





UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Transporte (T)	Residências	Não se aplica		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Não se aplica		
	Taxa de área verde	Muito baixa		
	Renda	Não se aplica		
	Tamanho do lote	Não se aplica		
	Descrição	Vias de tráfego de veículos.		
Prédios públicos (PB)	Residências	Não se aplica		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Baixa		
	Renda	Não se aplica		
	Tamanho do lote	Variável		
	Descrição	Prédios públicos e centros de serviços, tais como: escolas, hospitais, igrejas etc.		

UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Área de recreação (RA)	Residências	Não se aplica		
	Comércio	Não se aplica		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Não se aplica		
	Taxa de área verde	Média		
	Renda	Não se aplica		
	Tamanho do lote	Não se aplica		
	Descrição	Infraestrutura de esporte, como: quadras, campos, piscinas etc.		
Área comercial (C1)	Residências	Não se aplica		
	Comércio	Prédios de até 6 andares.		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Muito baixa		
	Renda	Não se aplica		
	Tamanho do lote	Variável		
	Descrição	Prédios comerciais com padrão médio a alto. Áreas designadas exclusivamente para essa atividade.		



UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Área industrial (I1)	Residências	Não se aplica		
	Comércio	Não se aplica		
	Indústrias	Prédios com até 4 andares.		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Não se aplica		
	Renda	Não se aplica		
	Tamanho do lote	Maioria > 2000 m <sup>2</sup>		
	Descrição	Área designada especificamente para indústria e abastecimento. No entanto, há desenvolvimento de atividades comerciais, tais como: venda de carros e materiais de construção.		
Área comercial / residencial (C2)	Residências	Não se aplica		
	Comércio	Prédios com até 5 andares.		
	Indústrias	Não se aplica		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Muito baixa		
	Renda	Variável		
	Tamanho do lote	Variável		
	Descrição	Área comercial com área residencial. Área residencial a partir do primeiro andar.		

UST	Parâmetro	Caracterização	Imagem de satélite (exemplo)	Detalhe do local (exemplo)
Área industrial, comercial, residencial (I2)	Residências	Não se aplica		
	Comércio	Não se aplica		
	Indústrias	Prédios com até 5 andares.		
	Infraestrutura urbana	Água, coleta de lixo, drenagem urbana e coleta de esgoto.		
	Taxa de área verde	Muito baixa		
	Renda	Variável		
	Tamanho do lote	Variável		
	Descrição	Áreas industriais misturadas com áreas comerciais. Em alguns casos com residências a partir do primeiro andar.		

Fonte do Apêndice F: Imagem de satélite (Google Maps); Detalhe do local (Google street view images).