



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA HIDRÁULICA E AMBIENTAL
DOUTORADO EM SANEAMENTO AMBIENTAL

LEONARDO DA CUNHA MARQUES

**OTIMIZAÇÃO DA LOCALIZAÇÃO DE ECOPONTOS EM CIDADES
BRASILEIRAS: UMA ABORDAGEM BASEADA EM ANÁLISE GEOESPACIAL E
MODELAGEM PREDITIVA**

FORTALEZA

2024

LEONARDO DA CUNHA MARQUES

OTIMIZAÇÃO DA LOCALIZAÇÃO DE ECOPONTOS EM CIDADES BRASILEIRAS:
UMA ABORDAGEM BASEADA EM ANÁLISE GEOESPACIAL E MODELAGEM
PREDITIVA

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal do Ceará, como requisito parcial para obtenção do título de Doutor em Engenharia Civil. Área de concentração: Saneamento Ambiental.
Orientador: Prof. Dr. Ronaldo Stefanutti.

FORTALEZA

2024

LEONARDO DA CUNHA MARQUES

OTIMIZAÇÃO DA LOCALIZAÇÃO DE ECOPONTOS EM CIDADES BRASILEIRAS:
UMA ABORDAGEM BASEADA EM ANÁLISE GEOESPACIAL E MODELAGEM
PREDITIVA

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal do Ceará, como requisito parcial para obtenção do título de Doutor em Engenharia Civil. Área de concentração: Saneamento Ambiental.

Aprovado em: 10/07/2024.

BANCA EXAMINADORA

Prof. Dr. Ronaldo Stefanutti (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Francisco Suetônio Bastos Mota
Universidade Federal do Ceará (UFC)

Prof. Dra. Marisete Dantas Aquino
Universidade Federal do Ceará (UFC)

Profa. Dra. Ana Bárbara de Araújo Nunes
Universidade Federal do Ceará (UFC)

Prof. Dr. Raphael Tobias de Vasconcelos Barros
Universidade Federal de Minas Gerais (UFMG)

Profa. Dra. Taiana Cestonaro
Universidade Estadual do Maranhão (UEMA)

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

M319o Marques, Leonardo da Cunha.

Otimização da localização de ecopontos em cidades brasileiras : uma abordagem baseada em análise geoespacial e modelagem preditiva / Leonardo da Cunha Marques. – 2024.

171 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil: Saneamento Ambiental, Fortaleza, 2024.

Orientação: Prof. Dr. Ronaldo Stefanutti.

1. Gestão de resíduos sólidos. 2. Sistema de informação geográfica. 3. Modelagem preditiva. I. Título.

CDD 628

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Ao meu orientador Prof. Dr. Ronaldo Stefanutti, pelo apoio, encorajamento, disposição, gentileza e atenção durante toda minha vida acadêmica.

Às Prefeituras de Belo Horizonte, Guarulhos e Fortaleza pela disponibilização de dados que possibilitaram o desenvolvimento deste trabalho.

Aos meus colegas, pelo companheirismo e pelas palavras de apoio nos momentos de dúvida, assim como pelos momentos felizes e descontraídos, que jamais serão esquecidos.

Aos meus pais, por todo o apoio e por terem me ensinado desde cedo a importância do estudo.

À minha esposa Aline, que foi minha maior apoiadora e meu porto seguro nos momentos desafiadores. Este trabalho não teria sido possível sem sua presença na minha vida.

À minha filha Catarina, que foi minha principal motivação para concluir esta tese.

Por fim, agradeço a Deus, que está comigo em todos os momentos, concedendo-me inúmeras graças e permitindo-me alcançar todos os objetivos traçados.

RESUMO

No Brasil, a gestão de resíduos sólidos urbanos é um desafio crescente devido ao aumento populacional e à expansão urbana. Uma das estratégias utilizadas pelo poder público para reduzir o descarte irregular de resíduos é a instalação de ecopontos, que são equipamentos públicos designados para receber diversos tipos de resíduos descartados de forma voluntária. No entanto, não existe uma metodologia para escolha de locais para sua instalação. Esta pesquisa propõe o desenvolvimento de um modelo para identificar áreas otimizadas para instalação de ecopontos em cidades brasileiras, utilizando análise geoespacial e modelagem preditiva. Foram analisados os dados de peso coletado por ano em cada ecoponto das cidades de Belo Horizonte, Fortaleza e Guarulhos, cruzando-os com variáveis socioeconômicas, ambientais e infraestruturais. Os resultados indicam que a densidade demográfica é a variável com maior influência na eficiência dos ecopontos. Dois modelos foram desenvolvidos e avaliados, sendo o primeiro baseado em análise determinística e o segundo em regressão linear. O modelo determinístico utilizou as variáveis densidade demográfica, proximidade de vias principais e Índice de Desenvolvimento Humano Municipal (IDHM) e mostrou-se adequado em classificar áreas em notas de 0 a 10 para a adequabilidade de instalação de ecopontos, baseando-se em cenários de contorno que podem ser definidos pelo gestor, permitindo que características locais da cidade em questão possam ser incorporadas no processo de decisão. O modelo de regressão linear obteve um coeficiente de determinação de 58% e utilizou as variáveis densidade demográfica, declividade, densidade de vias e densidade de unidades de saúde em sua fórmula final para estimar o peso a ser coletado em uma determinada área. Os modelos desenvolvidos demonstraram serem eficazes como uma ferramenta de apoio para a tomada de decisão na localização dos ecopontos, contribuindo para uma gestão mais eficiente e sustentável dos resíduos sólidos urbanos.

Palavras-chave: Ecopontos, SIG, regressão linear.

ABSTRACT

In Brazil, the management of urban solid waste is a growing challenge due to population increase and urban expansion. One of the strategies used by the public authorities to reduce irregular waste disposal is the installation of ecopoints, which are public facilities designated to receive various types of voluntarily discarded waste. However, there is no methodology for choosing their locations. This research proposes the development of a model that identifies optimized areas for the installation of ecopoints in Brazilian cities using geospatial analysis and predictive modeling. Data on the weight collected per year at each ecopoint in the cities of Belo Horizonte, Fortaleza, and Guarulhos were analyzed, cross-referencing them with socioeconomic, environmental, and infrastructural variables. The results indicate that population density is the variable with the greatest influence on the efficiency of the ecopoints. Two models were developed and evaluated, with the first based on deterministic analysis and the second on linear regression. The deterministic model used the variables of population density, proximity to main roads, and Municipal Human Development Index (MHDI) and was found to be suitable for classifying areas with scores from 0 to 10 for the suitability of installing ecopoints, based on contour scenarios that can be defined by the manager, allowing local characteristics of the city in question to be incorporated into the decision-making process. The linear regression model obtained a determination coefficient of 58% and used the variables of population density, slope, road density, and health unit density in its final formula to estimate the weight to be collected in a given area. The developed models proved to be effective as decision-support tools for locating ecopoints, contributing to more efficient and sustainable management of urban solid waste.

Keywords: Ecopoints, GIS, linear regression.

LISTA DE ILUSTRAÇÕES

Figura 1 - Disposição final adequada e inadequada de resíduos sólidos urbanos no Brasil em toneladas por ano e porcentagem.....	25
Figura 2 - Local de Entrega Voluntária de Resíduos Recicláveis em São Paulo/SP.	34
Figura 3 - Exemplo de Ponto de Entrega Voluntária ou Ecoponto em Fortaleza/CE.	35
Figura 4 - Desenho esquemático de um ecoponto.....	36
Figura 5 - Geração de RCD (Mt significa milhões de toneladas) nos principais aglomerados urbanos brasileiros.	38
Figura 6 - Componentes de SIG.....	42
Figura 7 - Comparação da forma de representação entre dados vetoriais e raster. .	43
Figura 8 - Mapa desenhado pelo Dr. John Snow representando as mortes durante o surto de cólera em Londres no século XIX.....	44
Figura 9 – Exemplo de Interpolação Inversa da Distância para uma variável qualquer em um plano cartesiano.	49
Figura 10 – Exemplo de Regressão Linear	51
Figura 11 – Visualização gráfica dos pressupostos da regressão linear.....	53
Figura 12 - Distribuição espacial dos ecopontos ao longo do território do município de Belo Horizonte.....	60
Figura 13 - Distribuição espacial dos ecopontos ao longo do território do município de Fortaleza.	62
Figura 14 - Distribuição espacial dos ecopontos ao longo do território do município de Guarulhos.....	64
Figura 15 - Exemplo de gráficos de diagnóstico de ajuste de modelo linear.....	83
Figura 16 - Mapa representativo da quantidade de ecopontos em grandes centros urbanos brasileiros.....	87
Figura 17 - Distribuição do peso de resíduos coletado por cidade.....	90
Figura 18 - Mapa da área de cobertura de cada ecoponto em Guarulhos/SP através de análise de isócronas de 5 minutos via carro.....	92
Figura 19 - Mapa da área de cobertura de cada ecoponto em Fortaleza/CE através de análise de isócronas de 5 minutos via carro.....	92
Figura 20 - Mapa da área de cobertura de cada ecoponto em Belo Horizonte/MG através de análise de isócronas de 5 minutos via carro.....	93

Figura 21 - Mapa da área de cobertura de cada ecoponto em Guarulhos/SP através de análise de polígonos de Voronoi.	94
Figura 22 - Mapa da área de cobertura de cada ecoponto em Fortaleza/CE através de análise de polígonos de Voronoi.	94
Figura 23 - Mapa da área de cobertura de cada ecoponto em Belo Horizonte/MG através de análise de polígonos de Voronoi.....	95
Figura 24 - Mapa do cruzamento de pesos coletados por ecopontos com a variável área dos polígonos de Voronoi em Guarulhos/SP.	96
Figura 25 - Mapa do cruzamento de pesos coletados por ecopontos com a variável área dos polígonos de Voronoi em Fortaleza/CE.....	96
Figura 26 - Mapa do cruzamento de pesos coletados por ecopontos com a variável área dos polígonos de Voronoi em Belo Horizonte/MG.	97
Figura 27 - Mapa LISA de clusters para a variável peso coletado de resíduos na cidade de Fortaleza.	98
Figura 28 - Mapa LISA de clusters para a variável peso coletado de resíduos na cidade de Guarulhos.....	99
Figura 29 - Mapa LISA de clusters para a variável peso coletado de resíduos na cidade de Belo Horizonte.....	99
Figura 30 – Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica por setor censitário em Guarulhos/SP.....	101
Figura 31 - Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica por setor censitário em Fortaleza/CE.	101
Figura 32 - Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica por setor censitário em Belo Horizonte/MG.....	102
Figura 33 - Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica nos polígonos de Voronoi em Guarulhos/SP.	103
Figura 34 - Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica nos polígonos de Voronoi em Fortaleza/CE.....	104
Figura 35 - Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica nos polígonos de Voronoi em Belo Horizonte/MG.	104
Figura 36 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM por setor censitário em Guarulhos/SP.....	106

Figura 37 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM por setor censitário em Fortaleza/CE.....	106
Figura 38 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM por setor censitário em Belo Horizonte/MG.....	107
Figura 39 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM nos polígonos de Voronoi em Guarulhos/SP.	108
Figura 40 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM nos polígonos de Voronoi em Fortaleza/CE.....	108
Figura 41 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM nos polígonos de Voronoi em Belo Horizonte/MG.	109
Figura 42 - Gráfico de densidade da variável proximidade de vias principais para as três cidades estudadas.	110
Figura 43 - Gráfico de densidade da variável proximidade de vias principais para as três cidades estudadas.	111
Figura 44 - Matriz de correlação entre as variáveis estudadas para a cidade de Fortaleza.	113
Figura 45 - Matriz de correlação entre as variáveis estudadas para a cidade de Guarulhos.....	114
Figura 46 - Matriz de correlação entre as variáveis estudadas para a cidade de Belo Horizonte.....	115
Figura 47 - Representação da variável densidade demográfica para o modelo determinístico.....	117
Figura 48 - Representação da variável proximidade de vias para o modelo determinístico.....	117
Figura 49 - Representação da variável IDH-M para o modelo determinístico.....	118
Figura 50 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 0,01. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.....	119
Figura 51 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 0,1. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.....	120

Figura 52 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 1. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.....	121
Figura 53 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 2. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.	121
Figura 54 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 5. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.....	122
Figura 55 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 10. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.....	123
Figura 56 - Mapa de classificação de áreas para instalação de ecopontos em Fortaleza baseado na nota atribuída pelo modelo determinístico.	124
Figura 57 - Mapa de classificação de áreas com nota acima de sete para instalação de ecopontos em Fortaleza baseado na nota atribuída pelo modelo determinístico.	125
Figura 58 - Mapa de classificação de áreas adequadas para instalação de ecopontos em Belo Horizonte baseado na nota atribuída pelo modelo determinístico.....	126
Figura 59 - Mapa de classificação de áreas com nota acima de sete para instalação de ecopontos em Belo Horizonte baseado na nota atribuída pelo modelo determinístico.....	127
Figura 60 - Mapa de classificação de áreas adequadas para instalação de ecopontos em Guarulhos baseado na nota atribuída pelo modelo determinístico.....	128
Figura 61 - Mapa de classificação de áreas com nota acima de sete para instalação de ecopontos em Guarulhos baseado na nota atribuída pelo modelo determinístico.	129
Figura 62 - Gráfico Q-Q para a variável dependente peso coletado por área.....	130
Figura 63 - Gráficos Q-Q com as transformações realizadas na variável dependente para normalização dos dados.	131
Figura 64 - Gráficos de dispersão entre a variável dependente e as variáveis densidade demográfica (A), densidade de vias (B), densidade de unidades de saúde (C) e declividade (D).	133

Figura 65 - Gráficos de diagnóstico de ajuste do modelo linear final.	135
Figura 66 - Mapa representativo das formas de estimativa de peso de resíduos coletado com o modelo de regressão linear. À esquerda, a saída direta do modelo, com valores em toneladas por ano por área. À direita, somatória dos valores internos dos polígonos de Voronoi, em toneladas por ano.	137
Figura 67 - Gráfico de dispersão entre os valores observados e estimados de peso coletado por Voronoi nas três cidades estudadas.	138
Figura 68 - Mapa comparativo entre valores observados e estimados de peso de resíduos coletados nos ecopontos de São Paulo, agrupados por subprefeitura.	140
Figura 69 - Gráfico de dispersão entre os valores observados e estimados de peso coletado, em toneladas por ano, por subprefeitura na cidade de São Paulo.	141
Figura 70 - Mapa comparativo entre valores observados e estimados de peso de resíduos coletados em relação à mediana para a cidade de Guarulhos/SP.	142
Figura 71 - Mapa comparativo entre valores observados e estimados de peso de resíduos coletados em relação à mediana para a cidade de Fortaleza/CE.	143
Figura 72 - Mapa comparativo entre valores observados e estimados de peso de resíduos coletados em relação à mediana para a cidade de Belo Horizonte/MG. ...	144
Figura 73 - Mapa preditivo gerado com o uso da equação de regressão linear múltipla utilizando setores censitários na cidade de Belo Horizonte/MG e a respectiva localização de ecopontos.	145
Figura 74 - Mapa preditivo gerado com o uso da equação de regressão linear múltipla utilizando setores censitários na cidade de Fortaleza/CE e a respectiva localização de ecopontos.	146
Figura 75 - Mapa preditivo gerado com o uso da equação de regressão linear múltipla utilizando setores censitários na cidade de Guarulhos/SP e a respectiva localização de ecopontos.	147
Figura 76 - Mapa preditivo gerado com o uso da equação de regressão linear múltipla utilizando setores censitários na cidade de São Luís/MA.	148
Figura 77 - Mapa preditivo gerado com o uso da equação de regressão linear múltipla utilizando setores censitários na cidade de Recife/PE.	149

LISTA DE TABELAS

Tabela 1 - Classificação de resíduos em relação à origem.	22
Tabela 2 – Disposição final de RSU nas regiões do Brasil, por tipo de destinação (megatoneladas por ano, porcentagem e número de municípios).	26
Tabela 3 - Lista de municípios brasileiros com mais de um milhão de habitantes e/ou que são capitais federais ou estaduais.	57
Tabela 4 - Descrição dos dados georreferenciados de entrada para o estudo.	68
Tabela 5 - Lista de municípios brasileiros que possuem ecopontos, ordenados por quantidade.....	85
Tabela 6 - Estatística descritiva da variável peso coletado de resíduos em cada ecoponto nas cidades de Belo Horizonte, Fortaleza e Guarulhos, em toneladas por ano, para o período de 2021 a 2023.	88
Tabela 7 - Análises de distância entre ecopontos e parâmetros relativos dos pesos de resíduos coletados por ecoponto nas cidades selecionadas.	89
Tabela 8 - Cenários de contorno do modelo determinístico com três variáveis para a cidade de Fortaleza/CE.....	118

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ABRECON	Associação Brasileira para Reciclagem de Resíduos da Construção Civil e Demolição
ABRELPE	Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais
AEDE	Análise Exploratória de Dados Espaciais
DBMS	Sistema de Gerenciamento de Banco de Dados (<i>Database Management System</i>)
GUI	Interface Gráfica de Usuário (<i>Graphical User Interface</i>)
IBGE	Instituto Brasileiro de Geografia e Estatística
IDH	Índice de Desenvolvimento Humano
IDHM	Índice de Desenvolvimento Humano Municipal
IDW	Interpolação Inversa da Distância (<i>Inverse Distance Weighting</i>)
ISWA	<i>International Solid Waste Association</i>
IPEA	Instituto De Pesquisa Econômica Aplicada
LEV	Local de Entrega Voluntária de Resíduos Recicláveis
LISA	Indicadores Locais de Associação Espacial (<i>Local Indicators of Spatial Association</i>)
MDE	Modelo Digital de Elevação
MMA	Ministério do Meio Ambiente
NASA	<i>National Aeronautics and Space Administration</i>
ONG	Organização Não Governamental
ONU	Organização das Nações Unidas
PEV	Ponto de Entrega Voluntária
PGRS	Plano de Gerenciamento de Resíduos Sólidos
PIB	Produto Interno Bruto
PMRCC	Plano Municipal de Gerenciamento Integrado de Resíduos da Construção Civil e Resíduos Volumosos
PMGIRS	Plano Municipal de Gerenciamento Integrado de Resíduos Sólidos

PNRS	Política Nacional de Resíduos Sólidos
PNUD	Programa das Nações Unidas para o Desenvolvimento
Q-Q	<i>Quantile-Quantile</i>
RCC	Resíduo da Construção Civil
RCD	Resíduos da Construção e Demolição
RSS	Resíduos de Serviços de Saúde
RSU	Resíduos Sólidos Urbanos
SCSP	Secretaria Municipal da Conservação e Serviços Públicos
SELURB	Sindicato das Empresas de Limpeza Urbana
SGRCC	Sistema de Gestão Sustentável de Resíduos da Construção Civil e Resíduos Volumosos
SIG	Sistema de Informação Geográfica
SIRGAS 2000	Sistema de Referência Geocêntrico para a América do Sul do ano 2000
UDH	Unidade de Desenvolvimento Humano
URPV	Unidades de Recebimento de Pequenos Volumes
USGS	<i>United States Geological Survey</i>
VIF	Fator de Inflação da Variância (<i>Variance Inflation Factor</i>)
UTM	Universal Transversa de Mercator

SUMÁRIO

1	INTRODUÇÃO	18
2	OBJETIVOS	20
2.1	Objetivo Geral	20
2.2	Objetivos Específicos	20
3	REVISÃO BIBLIOGRÁFICA	21
3.1	Resíduos Sólidos Urbanos	21
3.1.1	<i>Definição e classificação</i>	21
3.1.2	<i>Problemática dos resíduos sólidos</i>	23
3.1.3	<i>Gestão de RSU no Brasil</i>	24
3.1.4	<i>Legislação brasileira</i>	27
3.1.5	<i>Variáveis influenciadoras na geração de resíduos</i>	29
3.1.6	<i>Reciclagem</i>	31
3.2	Ecopontos	33
3.2.1	<i>Definição de ecoponto</i>	33
3.2.2	<i>Variáveis que influenciam o volume coletado</i>	39
3.3	Sistemas de Informações Geográficas.....	40
3.3.1	<i>Definição</i>	40
3.3.2	<i>Tipos de dados em um SIG</i>	42
3.3.3	<i>Aplicações SIG</i>	44
3.3.4	<i>Aplicações SIG na Gestão de Resíduos Sólidos</i>	45
3.4	Modelagem preditiva.....	47
3.4.1	<i>Interpolação Inversa da Distância</i>	48
3.4.1.1	<i>Definição</i>	48
3.4.2	<i>Regressão Linear</i>	50
3.4.2.1	<i>Definição</i>	50
3.4.2.2	<i>Pressupostos e testes para Regressão Linear</i>	52

3.4.2.3	<i>Aplicações de Regressão Linear</i>	53
4	METODOLOGIA	56
4.1	Programas utilizados	56
4.2	Panorama da quantidade de ecopontos no Brasil	57
4.3	Delimitação da área de estudo	58
4.4	Caracterização das cidades selecionadas	59
4.4.1	<i>Belo Horizonte</i>	59
4.4.2	<i>Fortaleza</i>	61
4.4.3	<i>Guarulhos</i>	63
4.5	Determinação de variáveis e organização da base de dados	64
4.6	Operações de geoprocessamento	68
4.9.1	<i>Modelo determinístico</i>	77
4.9.2	<i>Modelo baseado em regressão linear</i>	80
5	RESULTADOS E DISCUSSÃO	85
5.1	Panorama dos Ecopontos no Brasil.....	85
5.2	Análise de ecopontos nas cidades selecionadas.....	88
5.3	Área de cobertura dos ecopontos	91
5.4	Análise exploratória da variável dependente.....	97
5.5	Análise de variáveis independentes	100
5.5.1	<i>Densidade demográfica</i>	100
5.5.2	<i>IDHM</i>	105
5.5.3	<i>Proximidade de vias principais</i>	109
5.6	Análise de correlações	111
5.7	Modelo determinístico	116
5.8	Modelo de regressão linear	130
5.9	Validação do modelo de regressão linear.....	139

5.10	Aplicação do modelo de regressão linear.....	142
6	CONSIDERAÇÕES FINAIS	150
6.1	Conclusões	150
6.2	Sugestões para trabalhos futuros	151
	REFERÊNCIAS	152

1 INTRODUÇÃO

O crescimento urbano acelerado no Brasil tem acarretado uma série de desafios socioambientais, dentre os quais pode-se destacar o manejo inadequado de resíduos sólidos. O descarte irregular desses materiais não apenas agrava a poluição ambiental, mas também representa um sério risco à saúde pública e à qualidade dos espaços urbanos (Sen, 2022; Tohit *et al.*, 2019).

Além disso, a problemática se agrava quando se considera que a geração de resíduos sólidos municipais sofreu um aumento significativo em decorrência de fatores como crescimento populacional, urbanização, crescimento econômico e melhoria dos padrões de vida nos países em desenvolvimento (Abdel-Shafy; Mansour, 2018).

Ecopontos, também conhecidos como papa-entulhos, unidades de recebimento de pequenos volumes, pontos de entrega voluntária de resíduos, entre outros nomes, são equipamentos urbanos públicos designados para receber diversos tipos de resíduos sólidos urbanos descartados pela população de forma voluntária, com destaque para Resíduos da Construção Civil (RCC) e resíduos volumosos. Estas instalações emergem como uma alternativa viável para mitigar o impacto ambiental do descarte irregular de resíduos ao incentivar o descarte correto e a reciclagem de materiais. (Silva; Teixeira, 2020; Lima *et al.*, 2022).

No entanto, apesar de sua importância, observa-se uma variação considerável no peso de resíduos coletados entre diferentes ecopontos dentro de uma mesma cidade (Alexandre, 2021), o que indica a existência de variáveis independentes que influenciam diretamente na eficácia dessas instalações. A performance de um ecoponto pode ser impactada por diversos fatores sociais, ambientais e estruturais, que ainda não são completamente compreendidos ou adequadamente considerados nos processos de planejamento e gestão urbana.

Além disso, identifica-se uma lacuna no que se refere à metodologia para a escolha de locais para novos ecopontos. Atualmente, a decisão sobre onde implantar novos ecopontos muitas vezes é tomada de maneira subjetiva, baseada principalmente nos julgamentos dos gestores e na disponibilidade de terrenos para uso público, sem um embasamento metodológico que leve em conta os complexos fatores que afetam a performance dessas instalações.

Esta lacuna motivou o desenvolvimento do presente estudo, que busca integrar Sistemas de Informações Geográficas (SIG), estatísticas espaciais e algoritmos de aprendizado de máquina para otimizar a localização de ecopontos em cidades brasileiras.

A integração destas três áreas oferece um caminho promissor para abordar este problema de otimização espacial. Estudos bem-sucedidos recentes incluem aplicações como diferenciação espacial de áreas rurais (Wang, 2023), previsão de erosão (Bouguerra *et al.*, 2023), mapeamento de depósitos minerais (Houran *et al.*, 2023), avaliação da suscetibilidade a inundações em bacias hidrográficas (Saikh; Mondal, 2023) e modelagem da qualidade da água subterrânea para avaliação de potabilidade (Raheja; Goel; Pal, 2023).

Dada a complexidade e a novidade da temática em território nacional, este estudo se justifica por sua relevância ambiental e urbana, alinhando-se com as crescentes demandas por cidades mais sustentáveis e com menor impacto ambiental.

Desta forma, o presente estudo visa explorar e identificar os fatores socioeconômicos, ambientais e estruturais que influenciam a performance dos ecopontos nas cidades brasileiras. Além disso, propõe-se o desenvolvimento de uma metodologia analítica e preditiva, baseada em análise geoespacial, para otimizar a locação de novos ecopontos, considerando esses fatores, a fim de maximizar sua performance em termos de peso coletado de resíduos sólidos.

Espera-se que este modelo seja capaz de aprimorar e auxiliar o processo de tomada de decisão, auxiliando na escolha de locais futuros para ecopontos que maximizem sua acessibilidade e utilização pela população, contribuindo assim para o aumento na eficiência da reciclagem e, em última análise, tornando os ambientes urbanos mais sustentáveis.

2 OBJETIVOS

2.1 Objetivo Geral

Desenvolver um modelo preditivo geoespacial para identificar e classificar áreas mais adequadas para a instalação de novos ecopontos em cidades brasileiras, considerando variáveis ambientais, socioeconômicas e infraestruturais, com o intuito de otimizar a gestão de resíduos sólidos no contexto urbano.

2.2 Objetivos Específicos

- Compreender os padrões de distribuição espacial dos ecopontos existentes em cidades brasileiras e identificar variáveis independentes que influenciam sua localização e performance em termos de peso de resíduos coletados.
- Analisar a relação entre locais de ecopontos e variáveis espaciais independentes como densidade demográfica, renda e proximidade de características urbanas importantes.
- Verificar a consistência dos padrões e correlações identificados em diferentes cidades brasileiras, avaliando a aplicabilidade dos resultados.
- Desenvolver modelos preditivos usando análises geoespaciais e inferências estatísticas baseadas em regressão linear que possam prever a localização de áreas adequadas para instalação de futuros ecopontos;
- Avaliar o desempenho do modelo preditivo ao correlacionar o peso previsto de resíduos coletados com os valores observados em um conjunto de dados para validação de uma cidade selecionada.

3 REVISÃO BIBLIOGRÁFICA

3.1 Resíduos Sólidos Urbanos

3.1.1 Definição e classificação

Resíduos Sólidos Urbanos (RSU) referem-se aos subprodutos gerados pelas atividades humanas em áreas urbanas (Mayes-Ramírez *et al.*, 2023). O RSU normalmente compreende materiais orgânicos e inorgânicos produzidos por várias atividades sociais, com o crescimento populacional, a urbanização e a industrialização impactando sua quantidade e composição. Em geral, o termo se refere ao resíduo doméstico, comercial e de varejo, excluindo resíduos industriais, perigosos e de construção. (Karim; Wetterhan, 2020).

Em um contexto mais geral, resíduos sólidos podem ser definidos como materiais descartados que não são mais necessários pelo proprietário ou usuário (ONU, 2014).

No Brasil, pode-se destacar a definição criada pela Associação Brasileira de Normas Técnicas - ABNT, em sua norma 10.004/2004, assim como a definição descrita na Política Nacional de Resíduos Sólidos - PNRS, instituída pela Lei Federal nº 12.305, de 2 de agosto de 2010.

De acordo com estas definições, o conceito adotado de resíduo sólido é:

Resíduos nos estados sólido e semi-sólido, que resultam de atividades de origem industrial, doméstica, hospitalar, comercial, agrícola, de serviços e de varrição. Ficam incluídos nesta definição os lodos provenientes de sistemas de tratamento de água, aqueles gerados em equipamentos e instalações de controle de poluição, bem como determinados líquidos cujas particularidades tornem inviável o seu lançamento na rede pública de esgotos ou corpos de água, ou exijam para isso soluções técnica e economicamente inviáveis em face à melhor tecnologia disponível (ABNT, 2004).

Material, substância, objeto ou bem descartado resultante de atividades humanas em sociedade, a cuja destinação final se procede, se propõe proceder ou se está obrigado a proceder, nos estados sólido ou semissólido, bem como gases contidos em recipientes e líquidos cujas particularidades tornem inviável o seu lançamento na rede pública de esgotos ou em corpos d'água, ou exijam para isso soluções técnica ou economicamente inviáveis em face da melhor tecnologia disponível (Brasil, 2010).

Definições anteriores sobre resíduos sólidos geralmente os caracterizava como algo sem valor comercial ou utilizado. Entretanto, estes conceitos já não são mais aceitos, tendo em vista que a maior parte dos materiais pode ser utilizada para

alguma outra finalidade, adquirindo até mesmo valor econômico. Processos como pirólise lenta e incorporação em materiais de construção podem ser citados como usos de resíduos sólidos que incorporam valor econômico agregado ao resíduo em questão (Das; Tiwari, 2018; Tang, 2022).

Já em relação à classificação quanto à origem dos resíduos, existem várias possibilidades de classificação a depender da realidade local. No Brasil, a classificação de resíduos segue a PNRS, em seu Art. 13, Inciso I. A Tabela 1 apresenta esta classificação com uma breve descrição e exemplos de cada classe de resíduo sólido.

Tabela 1 - Classificação de resíduos em relação à origem.

Classe	Descrição	Exemplos
Resíduos domiciliares	Resíduos resultantes de atividades domésticas nas residências.	Papel, papelão, plástico, vidro, metais não ferrosos, fraldas descartáveis, restos de alimentos.
Resíduos de limpeza urbana	Resíduos provenientes de locais públicos.	Resíduos de ruas, praças, parques, varrição pública, capina.
Resíduos sólidos urbanos	Nome utilizado para se referir a todos os tipos de resíduos gerados nas cidades e coletados pelo serviço municipal.	Resíduos domésticos, resíduos de varrição, resíduos de pequenos comércios e prestadores de serviços e, em alguns casos, entulhos.
Resíduos de estabelecimentos comerciais e prestadores de serviços	Resíduos gerados nas áreas urbanas e/ou rurais, originários de atividades comerciais e de serviços.	Resíduos de supermercados, restaurantes, praças e outros serviços.
Resíduos de serviços públicos de saneamento básico	Resíduos provenientes da drenagem pluvial e limpeza de bueiros.	Lodo de estações de tratamento de esgotos, vidros, sacos, animais em decomposição, entre outros.
Resíduos industriais	Resíduos gerados em processos produtivos e instalações industriais.	Resíduos perigosos como produtos fora de especificação, tintas, matérias-primas, EPIs contaminados.
Resíduos de serviços de saúde	Resíduos de hospitais, farmácias, consultórios, laboratórios de análises clínicas entre outros.	Seringas, agulhas, curativos e outros materiais que podem apresentar algum tipo de contaminação por agentes patogênicos.
Resíduos da construção civil	Materiais de construção e demolição, pavimentação e	Componentes cerâmicos (tijolos, blocos, telhas, placas

Classe	Descrição	Exemplos
	reformas e reparos de edificações.	de revestimento, entre outros), argamassa e concreto.
Resíduos Agrossilvopastoris	Incluem todos os resíduos que podem ser gerados em atividades agrícolas e pecuárias, florestais, incluindo aqueles relacionados aos insumos utilizados.	Óleos residuais, embalagens de produtos fitossanitários, embalagens e rótulos de medicamentos veterinários, embalagens de pesticidas e plásticos.
Resíduos de serviços de transportes	Resíduos de serviços de transporte que se originam em portos, aeroportos, alfândegas, terminais rodoviários e ferroviários.	Tratados como “resíduos sépticos”, pois podem conter agentes causadores de doenças trazidos de outros países, principalmente através de restos de alimentos, produtos alimentícios e de uso pessoal.
Resíduos de mineração	Resíduos gerados na atividade de perfuração.	Rejeitos gerados a partir de ferro, calcário, titânio.

Fonte: Adaptado de Silva *et al.* (2022) e Brasil (2010).

3.1.2 Problemática dos resíduos sólidos

A gestão de resíduos sólidos é um desafio a nível global, em especial em países em desenvolvimento. (Ferronato; Torretta, 2019). Este desafio tende a crescer em conjunto com o crescimento urbano. O crescimento urbano acelerado, observado nas últimas décadas, contribuiu para o aumento da densidade populacional, que por sua vez levou à ocorrência cada vez mais comum de problemas socioambientais. Congestionamento do tráfego, poluição do ar e da água, aumento da geração per capita de resíduos sólidos e seu descarte irregular são alguns exemplos destes problemas. Em grandes centros, é comum se observar volumes elevados de resíduos que a sociedade descarta (Babayemi; Dauda, 2010; Hamad; Hanafiah; Abdullah, 2017; Karim; Wetterhan, 2020).

O descarte irregular de resíduos sólidos acarreta diversas consequências negativas. Impactos imediatos no ambiente e na saúde, contribuição para mudanças climáticas, contaminação de rios e lençóis freáticos, proliferação de doenças, poluição visual, odores indesejados, perda de biodiversidade, contaminação do solo, e riscos à saúde pública são algumas das ramificações desse problema (Araújo; Pimentel,

2015; Coelho; Costa; Iwata, 2016; Ferreira; Anjos, 2001; Gomes; Rocha, 2021; Gouveia, 2012; Manica; Johann, 2019).

Estima-se um aumento na geração de resíduos municipais de 2,3 bilhões de toneladas em 2023 para 3,8 bilhões de toneladas até 2050, impactando especialmente os países em desenvolvimento. Os custos diretos da gestão de resíduos alcançaram 252,3 bilhões de dólares em 2020, podendo escalar para 361 bilhões de dólares até 2050 ao considerar a poluição, impactos na saúde e mudanças climáticas (ISWA, 2024).

A geração de resíduos é bastante variável e influenciada, dentre outros fatores, pelo grau de desenvolvimento econômico da região. Países com um maior poder econômico tendem a gerar um volume significativo maior de resíduos. Os Estados Unidos, por exemplo, geraram em 2015 cerca de 2,03 kg de resíduos sólidos por habitante por dia. Por outro lado, foi observado que países da América do Sul geram em média 1,07 kg por habitante por dia, enquanto na Ásia este valor varia entre 0,4 a 1,62. Na África, a média é de 0,49 kg por habitante por dia. A fração de matéria orgânica nestes países em desenvolvimento representa entre 50 a 80% do total gerado. (Adhikari, 2022; Karim; Wetterhan, 2020; Roy; Tarafdar, 2022).

Cenários futuros para o ano de 2050, onde as práticas atuais são mantidas, resultariam em um custo líquido de 640,3 bilhões de dólares. Além disso, estima-se que o custo da inércia na gestão de resíduos é de três a cinco vezes maior do montante necessário para investimento e custeio das soluções adequadas (ISWA, 2024).

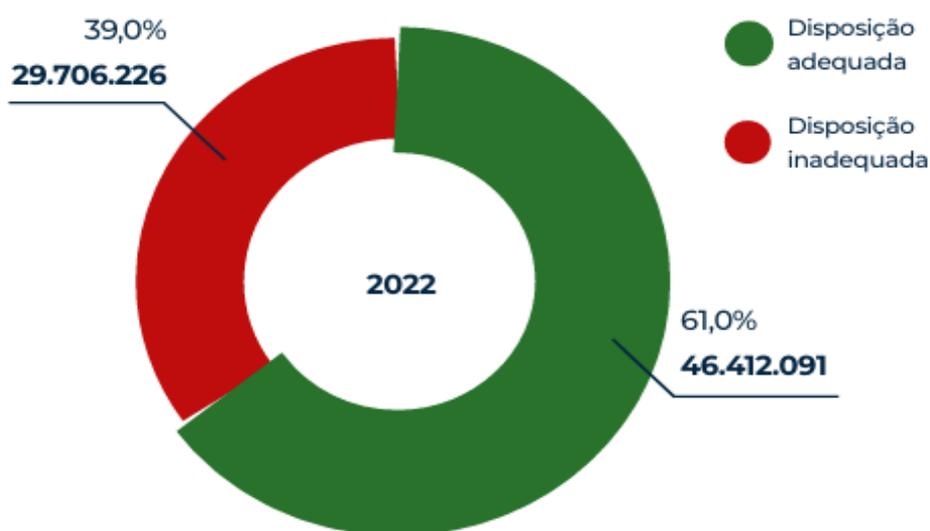
Em resumo, observa-se que a gestão de resíduos sólidos urbanos está diretamente associada à saúde pública e à degradação ambiental, o que destaca a importância da conscientização, educação ambiental e práticas de gestão adequadas são essenciais para mitigar esses impactos e promover um manejo sustentável dos resíduos sólidos (Lisboa *et al.*, 2022; Sakanyi, 2022; Souza *et al.*, 2022).

3.1.3 Gestão de RSU no Brasil

Em relação ao cenário no Brasil, segundo a Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais - ABRELPE, no ano de 2022 foram gerados cerca de 81,8 milhões de toneladas, o que corresponde a 224 mil

toneladas por dia. Este valor representa uma geração per capita média de 1,043 kg de resíduos por dia. Entretanto, apenas 61% destes resíduos possuem uma destinação adequada em aterros sanitários, enquanto os 39% restantes são destinados em lixões e aterros controlados. (ABRELPE, 2022).

Figura 1 - Disposição final adequada e inadequada de resíduos sólidos urbanos no Brasil em toneladas por ano e porcentagem.



Fonte: Adaptado de ABRELPE (2022)

Em relação às disparidades regionais, as regiões Sul e Sudeste apresentam os maiores índices de disposição adequada, com 71,6% e 74,3% respectivamente. As regiões Norte e Nordeste, por outro lado, são as que apresentam os menores índices, com 36,6% e 37,2% respectivamente (ABRELPE, 2022). A Tabela 2 apresenta esta proporção entre regiões por tipo de destinação em relação ao número de municípios, peso total e porcentagem.

Ainda segundo a ABRELPE (2022), a disposição inadequada de resíduos em lixões e aterros controlados causam impactos diretos na saúde da população em um raio de abrangência que pode chegar até 60 km e custaram, entre 2016 e 2021, um total estimado de 1,85 bilhão de dólares na saúde no Brasil para tratamento dos problemas ocasionados pela da destinação inadequada.

Tabela 2 – Disposição final de RSU nas regiões do Brasil, por tipo de destinação (megatoneladas por ano, porcentagem e número de municípios).

Região	Disposição adequada			Disposição inadequada		
	Mt/ano	%	Número de municípios	Mt/ano	%	Número de municípios
Norte	1,816	35,9	96	3,242	64,1	354
Nordeste	6,128	36,7	515	10,570	63,3	1279
Centro-Oeste	2,501	42,8	175	3,343	57,2	292
Sudeste	29,754	73,8	887	10,563	26,2	781
Sul	6,097	71,2	1071	2,466	28,8	120
Brasil	46,298	60,5	2774	30,186	39,5	2826

Fonte: Adaptado de ABRELPE (2022).

Após 12 anos de PNRS, em 2022, cerca de 50% das cidades continuam a destinar os resíduos de forma inadequada, mesmo com o prazo inicial para a erradicação dos lixões ter expirado em 2014. O prazo atual é até agosto de 2024 (Brasil, 2020). Em relação às capitais, o descarte irregular ainda ocorre em Cuiabá (MT), Porto Velho (RO) e Boa Vista (RR) (SELURB, 2023).

Em relação aos estados, Santa Catarina é o que apresentava, em 2022, melhor índice de destinação adequada de RSU, com cerca de 84%. Por outro lado, Roraima apresentou 0% de destinação correta, tendo em vista que todo resíduo produzido pela população é descartado inadequadamente. Além disso, cerca de 25% dos domicílios no Brasil não possuíam coleta domiciliar (SELURB, 2023).

Por fim, em 2012, as cidades brasileiras investiam cerca de cinco vezes menos na gestão de RSU do que cidades em países desenvolvidos. Estima-se que o investimento das cidades do Rio de Janeiro, São Paulo e Brasília foi de cerca de 48, 32 e 35 dólares por habitante por ano, respectivamente. Em contrapartida, este investimento nas cidades de Tóquio, Barcelona, Paris e Nova York foram de 386, 172, 140 e 80, respectivamente (Alfaia; Costa; Campos, 2017).

Deve-se ressaltar que a destinação inadequada de resíduos sólidos é considerada crime ambiental desde 1998 no Brasil, conforme estabelece a Lei Federal nº 9.605/1998 (Brasil, 1998).

Entretanto, para tentar solucionar esta problemática, os órgãos de controle ambiental dos estados e municípios devem agir por meio de fiscalização, exigindo manejo, armazenamento, transporte e disposição final adequada destes resíduos. Além disso, a gestão da limpeza urbana nas cidades pode ocorrer de três maneiras: diretamente pelo município, por empresa pública específica ou ainda por empresa de economia mista criada para esse fim. (Silva *et al.*, 2022).

3.1.4 Legislação brasileira

Enquanto países desenvolvidos, como os EUA, implementaram legislações relacionadas à gestão de resíduos sólidos na década de 1970, o Brasil somente estabeleceu uma legislação específica sobre o tema em 2010.

A Política Nacional de Resíduos Sólidos foi instituída pela Lei Federal nº. 12.305/2010, sendo considerada um marco para a gestão de resíduos no Brasil. Os principais objetivos definidos por esta legislação são:

- a) Não geração, redução, reutilização, reciclagem e tratamento de resíduos sólidos;
- b) Destinação final adequada dos resíduos;
- c) Racionalização de recursos naturais na produção de novos itens;
- d) Intensificação das ações de educação ambiental;
- e) Incentivos para a indústria de reciclagem;
- f) Articulação entre as diferentes classes de governo e entre estas e o setor empresarial, visando a cooperação técnica e financeira;
- g) Promoção da inclusão social;
- h) Capacitação técnica.

A lei proíbe a disposição de RSU em lixões a céu aberto e estipula que todos os estados e cidades devem ter encerrado os seus lixões a céu aberto até 2014. Além disso, os municípios devem elaborar um Plano Municipal de Gerenciamento Integrado de Resíduos Sólidos (PMGIRS) para os próximos 20 anos, devendo ser revisado a cada 4 anos (Brasil, 2010).

Assim, conceitos pouco praticados no Brasil até então foram estabelecidos pela PNRS, podendo se destacar: a coleta de materiais recicláveis; a disposição final

adequada; gestão integrada através de contratos entre o setor público e empresas privadas; e a aplicação da logística reversa (Brasil, 2010).

Além da PNRS, a gestão de resíduos sólidos no Brasil é regulamentada por outras normas que detalham e complementam a legislação principal. O Decreto nº 10.936, de 12 de janeiro de 2022 regulamenta a PNRS, estabelecendo medidas de planejamento, implementação e controle dos serviços públicos de limpeza urbana e manejo de resíduos sólidos, além de dispor sobre a responsabilidade compartilhada pelo ciclo de vida dos produtos e a logística reversa (Brasil, 2022). A Lei nº 9.605/1998, conhecida como Lei de Crimes Ambientais, definiu sanções penais e administrativas para condutas e atividades que causem danos ao meio ambiente (Brasil, 1998).

Além dessas legislações, a Resolução CONAMA nº 307/2002 estabeleceu diretrizes, critérios e procedimentos específicos para a gestão dos resíduos da construção civil. Esta resolução classifica os resíduos da construção civil e atribui aos geradores a responsabilidade pela sua destinação adequada (Brasil, 2002). A Resolução CONAMA nº 358/2005 regulamenta sobre o tratamento e a disposição final dos resíduos dos serviços de saúde, definindo responsabilidades para o gerenciamento adequado dos resíduos de saúde, desde a sua geração até a disposição final (Brasil, 2005).

Além das legislações federais, a gestão de resíduos sólidos no Brasil também é regulamentada por normas estaduais e municipais. Cada estado e município pode estabelecer suas próprias diretrizes para atender às características locais e promover a gestão adequada dos resíduos.

No âmbito estadual, podemos citar o Estado de São Paulo, que possui a Lei Estadual nº 12.300/2006, que institui a Política Estadual de Resíduos Sólidos, abordando a gestão integrada e o gerenciamento dos resíduos sólidos, o Rio de Janeiro, que possui a Lei Estadual nº 4.191/2003, que estabelece diretrizes para a gestão dos resíduos sólidos no estado, priorizando a minimização da geração de resíduos e a reciclagem, e o estado do Ceará, que possui a Lei Estadual nº 16.032/2016, que institui a Política Estadual de Resíduos Sólidos no âmbito do Estado do Ceará (São Paulo, 2006; Rio de Janeiro, 2003; Ceará, 2016).

3.1.5 Variáveis influenciadoras na geração de resíduos

A geração de RSU é influenciada por uma vasta gama de variáveis, com fatores socioeconômicos desempenhando um papel relevante.

Lu *et al.* (2022) observaram que a escala linear do RSU com o tamanho da cidade indica que a quantidade de lixo produzida é diretamente proporcional à população, sugerindo que os padrões de consumo individuais impulsionam a geração de resíduos independentemente da densidade ou tamanho da cidade. Essa observação implica que, à medida que a população de uma cidade dobra, sua geração de RSU também dobra.

Além disso, também foi observado que a atividade econômica é uma variável relevante na geração de RSU. Cidades com maior PIB per capita tendem a produzir mais RSU, pois o aumento da riqueza se correlaciona com maior consumo e produção de resíduos. No estudo, cidades mais ricas como Seattle geram mais RSU em comparação com cidades menos ricas, mesmo quando estas possuem uma população maior, o que destaca o papel da riqueza econômica na geração de resíduos, onde níveis mais altos de renda levam a um maior consumo de bens e serviços, aumentando assim a produção de resíduos (Lu *et al.*, 2022). Estes achados vão ao encontro dos resultados observados por Ghanbari, Kamalan e Sarraf (2021), onde a geração de RSU em Teerã foi estimada usando parâmetros socioeconômicos de 1991 a 2013, selecionando variáveis-chave como renda, população, PIB e mês por meio da análise de correlação de Pearson.

O estudo desenvolvido por Zambrano-Monserrate, Ruano e Ormeño-Candelario (2021) investigou as variáveis determinantes da geração de RSU em 173 países, onde os resultados indicaram que o aumento do PIB, o aumento da população, a urbanização e o turismo contribuem de forma significativa no aumento dos RSU, especialmente em países de alta renda. Em países de alta renda, o estudo constatou que a geração de RSU aumentou com os incrementos do PIB, indicando uma correlação direta entre prosperidade econômica e produção de resíduos.

Alzamora *et al.* (2022) realizaram uma revisão de literatura para explorar a relação entre a geração de RSU e diversos fatores socioeconômicos. O estudo identificou mais de 300 fatores que influenciam na geração, sendo os mais recorrentes PIB, população, renda, tamanho da família, consumo de energia e água. Destacou-se

a necessidade de uma investigação mais aprofundada sobre fatores como educação e densidade populacional para aprimorar as estratégias de previsão e gestão de resíduos sólidos.

O estudo também observou que a incorporação de variáveis que mudam com o tempo (taxas de crescimento econômico, padrões de migração e mudanças no comportamento de consumo, por exemplo), assim como variáveis ambientais e relacionadas a políticas (taxas de reciclagem, políticas de gestão de resíduos e campanhas de conscientização pública, por exemplo) podem influenciar de maneira relevante na geração de RSU e devem ser integrados aos modelos de previsão (Alzamora *et al.*, 2022).

Outro estudo, desenvolvido por Chu *et al.* (2016), utilizou um modelo de regressão múltipla para investigação das variáveis, destacando que a geração de RSU apresenta correlação positiva com a população urbana, PIB, número de veículos de transporte de resíduos sólidos, área de coleta e renda per capita, enquanto está negativamente correlacionada com a taxa de inflação e taxa de tratamento de resíduos sólidos.

Por fim, o estudo desenvolvido em Bangkok, Tailândia, por Sukholthaman, Chanvarasuth e Sharp (2017) identificou sete variáveis-chave que influenciam a geração de resíduos sólidos. Essas variáveis foram determinadas por meio de análises estatísticas abrangentes, incluindo análise descritiva, teste de hipóteses e correlação de Pearson. As variáveis, apresentadas em ordem de importância e com suas respectivas justificativas, foram as seguintes:

- a) Densidade populacional: áreas com maiores densidades populacionais tendem a gerar mais resíduos devido ao aumento do número de residentes e suas atividades.
- b) Nível de renda: níveis de renda mais altos frequentemente se correlacionando com maior geração de resíduos devido ao aumento do consumo e descarte de bens.
- c) Taxa de urbanização: a rápida urbanização normalmente leva ao aumento da produção de resíduos devido ao influxo de pessoas e à expansão das atividades comerciais.
- d) Atividades industriais: zonas industriais produzindo grandes quantidades de resíduos.

- e) Atividades turísticas: áreas turísticas tendem a gerar quantidades substanciais de resíduos devido à alta rotatividade de visitantes e aos padrões de consumo associados.
- f) Consciência pública: comunidades com maior conscientização e atitudes positivas em relação às práticas de gestão de resíduos tendem a gerar menos resíduos e a participar mais de iniciativas de reciclagem e redução de resíduos.
- g) Eficiência dos sistemas de coleta e descarte de resíduos: sistemas mais eficientes levam a melhores resultados de gerenciamento de resíduos e taxas potencialmente mais baixas de geração de resíduos.

Portanto, ao analisar o conjunto dos estudos relacionados ao tema, observa-se que políticas de gestão de resíduos devem levar em consideração variáveis econômicas, demográficas, ambientais e de infraestrutura, adaptando-se às especificidades locais.

3.1.6 Reciclagem

A reciclagem é uma das estratégias principais para resolver problemas de resíduos sólidos devido às suas vantagens econômicas e ambientais. No entanto, persistem desafios, como a crescente geração de resíduos associada à cultura de consumo, particularmente em áreas urbanas (Subedi *et al.*, 2023).

Os esforços para aumentar a eficácia da gestão de resíduos, como a redução da geração de resíduos e a melhoria da reciclagem, são essenciais para práticas sustentáveis, como evidenciado por estudos que analisam a gestão de resíduos em vários países como a Indonésia (Gutama; Iresha, 2023).

As práticas de reciclagem do Brasil apresentam contrastes quando comparadas a outros países, principalmente desenvolvidos, principalmente devido à falta de incentivos econômicos e investimentos em infraestrutura, que são mais prevalentes nos países desenvolvidos (Souza, R., 2020).

No Brasil, em 2022, o índice médio de reciclagem não passava de 3,5%, com grandes variações regionais. Enquanto a região Sul apresentava índices de reciclagem de 8,0%, as regiões Norte e Nordeste possuem índices de 1,1 e 0,8%, respectivamente (SELURB, 2023). Em 2007, a coleta de material reciclável cobria

menos da metade do território nacional, fazendo com que o Brasil desperdiçasse cerca de 2,5 bilhões de dólares por ano ao descartar resíduos recicláveis em aterros sanitários (Alfaia; Costa; Campos, 2017).

Além disso, a pandemia da COVID-19 destacou as deficiências no sistema de gestão de resíduos do Brasil, enfatizando a necessidade de maior investimento em infraestrutura de reciclagem e apoio a iniciativas locais (Almeida; De Souza; Campos, 2021).

A natureza informal do mercado de reciclagem, especialmente entre os catadores, representa outra barreira significativa, pois complica a integração desses trabalhadores em cadeias formais de reciclagem e limita o potencial de uma economia circular (Pisano; Demajorovic; Besen, 2022). Além disso, o baixo valor de mercado de certos materiais recicláveis e a falta de programas contínuos de coleta seletiva exacerbam o problema (Rutkowski, J.; Rutkowski, E., 2017).

Apesar de ser um dos maiores produtores de lixo eletrônico da América Latina, o Brasil recicla apenas cerca de 3,6% deste tipo de resíduo por ano, com a maioria das instalações de reciclagem sendo pequenas e operadas manualmente. A falta de dados confiáveis sobre as taxas de coleta e reciclagem, particularmente para lixo eletrônico, dificulta a capacidade de medir a eficácia das regulamentações e iniciativas existentes (Dias *et al.*, 2022).

O país também enfrenta desafios no gerenciamento de resíduos de pneus, com regulamentações em vigor desde 2009, mas não cumprindo as metas de descarte de forma consistente (Thives; Ghisi; Thives Junior, 2022).

Para incentivar a reciclagem e o descarte adequado de resíduos sólidos, o poder público brasileiro implementou diversas iniciativas. Entre elas, destacam-se a criação de programas de coleta seletiva, a promoção de acordos setoriais para incluir catadores de materiais recicláveis, a implementação de logística reversa para resíduos específicos, como embalagens, e a elaboração de políticas públicas voltadas para a gestão adequada dos resíduos (Alfaia; Costa; Campos, 2017; Guarnieri *et al.*, 2020; Vieira *et al.*, 2020).

Incentivos fiscais, como o certificado verde do ICMS, têm sido eficazes em algumas regiões, mas uma aplicação mais ampla e incentivos mais bem projetados são necessários para ampliar o mercado de reciclagem (Holanda, 2022).

Além disso, a conscientização da população por meio de campanhas educativas e ações de educação ambiental têm sido fundamentais para fomentar práticas sustentáveis de descarte e reciclagem (Ibiapina *et al.*, 2021). A busca por parcerias e cooperação entre municípios também tem sido uma estratégia adotada para otimizar a gestão de resíduos sólidos e reduzir impactos ambientais (Deus; Battistelle; Silva, 2016; Macedo *et al.*, 2023).

Em regiões como a Amazônia brasileira, a escassez de agregados naturais impulsionou a reciclagem de resíduos da construção civil, com estudos mostrando a viabilidade de estabelecer usinas de reciclagem para gerenciar esses resíduos de forma eficaz (Souza *et al.*, 2022).

Iniciativas do setor privado também desempenharam um papel importante na coordenação da cadeia de reciclagem de embalagens e no fornecimento de certificados de reciclagem, promovendo a inclusão social por meio de parcerias com cooperativas de catadores (Vincenzi *et al.*, 2021).

A indústria têxtil também apresenta oportunidades relevantes de reciclagem, com iniciativas em estados como São Paulo e Rio de Janeiro com foco na redução e reutilização de resíduos, gerando renda e consciência ambiental (Baruque-Ramos, 2017).

Apesar desses esforços, a eficácia geral das práticas de reciclagem do Brasil é limitada por incentivos econômicos inadequados e infraestrutura insuficiente, destacando a necessidade de programas abrangentes e contínuos para aumentar as taxas de reciclagem e promover uma economia circular.

3.2 Ecopontos

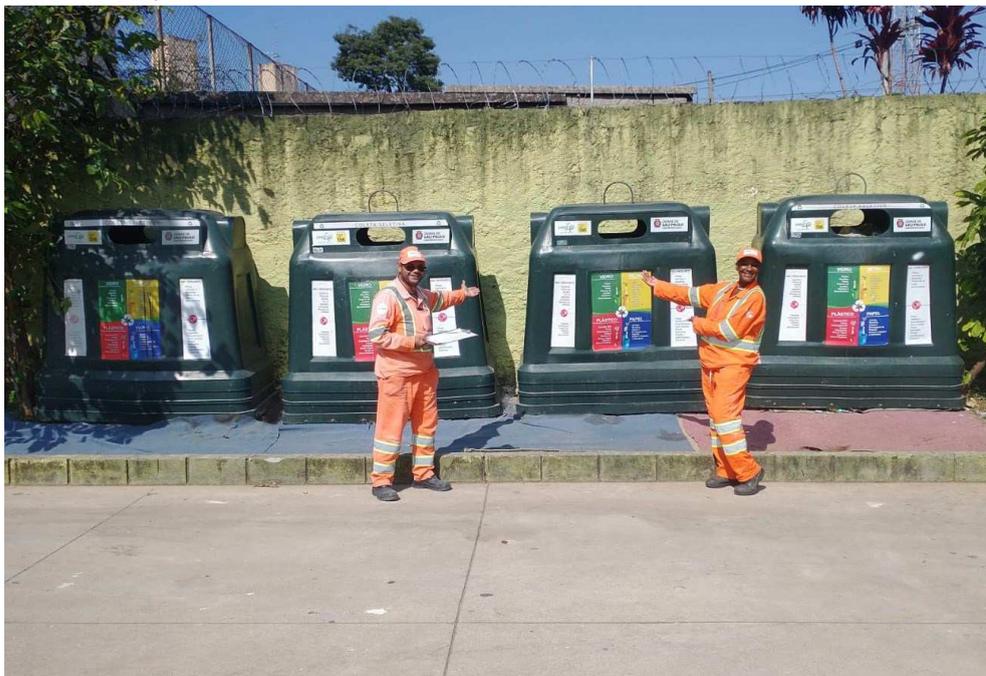
3.2.1 Definição de ecoponto

Dentre as estratégias utilizadas pelo poder público para estimular o descarte adequado de resíduos sólidos e aumentar os índices de reciclagem, podemos citar a instalação de Pontos de Entrega Voluntária (PEVs) e Locais de Entrega Voluntária de Resíduos Recicláveis (LEVs).

Os LEVs são estruturas disponibilizadas pelas prefeituras ou empresas responsáveis pela gestão dos resíduos, onde os cidadãos podem levar materiais recicláveis, como papel, plástico, metal e vidro. São contêineres, sacos ou outros

dispositivos e que geralmente estão localizados em áreas de fácil acesso para a população, como supermercados, escolas, farmácias, praças públicas e até calçadas, incentivando a prática da coleta seletiva (MMA, 2012). A Figura 2 apresenta um exemplo de LEV na cidade de São Paulo, no estado de São Paulo.

Figura 2 - Local de Entrega Voluntária de Resíduos Recicláveis em São Paulo/SP.



Fonte: São Paulo (2023).

Por sua vez, os PEVs, também conhecidos como ecoPontos, são instalações determinadas pelas prefeituras que contêm equipamentos destinados para a acumulação temporária de resíduos da construção civil, de resíduos volumosos, da coleta seletiva e resíduos com logística reversa (MMA, 2012). A Figura 3 apresenta um exemplo real de ecoPonto na cidade de Fortaleza, no estado do Ceará, enquanto a Figura 4 apresenta um desenho esquemático da estrutura geral deste tipo de instalação.

De maneira geral, o principal objetivo dos ecoPontos é facilitar o descarte correto de materiais, promover a reciclagem e contribuir para a redução do impacto ambiental causado pelo descarte inadequado de resíduos (Ito; Colombo, 2019).

Segundo o Manual de Orientação do Ministério do Meio Ambiente para Planos de Gestão de Resíduos Sólidos (2012), há uma complementação sobre a instalação de PEVs e sua função:

Essas instalações são, na prática, a oferta de endereços físicos para a atração e concentração de diversos tipos de resíduos. Os PEVs (Ecopontos) são os pontos iniciais das redes que precisam ser definidas. Alocados nos bairros, com base em vários critérios, permitem transformar resíduos difusos em resíduos concentrados, propiciando a definição da logística de transporte, com equipamentos adequados e custos suportáveis (MMA, 2012).

Figura 3 - Exemplo de Ponto de Entrega Voluntária ou Ecoponto em Fortaleza/CE.



Fonte: Fortaleza (2023a).

Entretanto, em nenhum momento são definidos ou descritos quais seriam estes critérios para alocação destes pontos, evidenciando a importância da presente pesquisa.

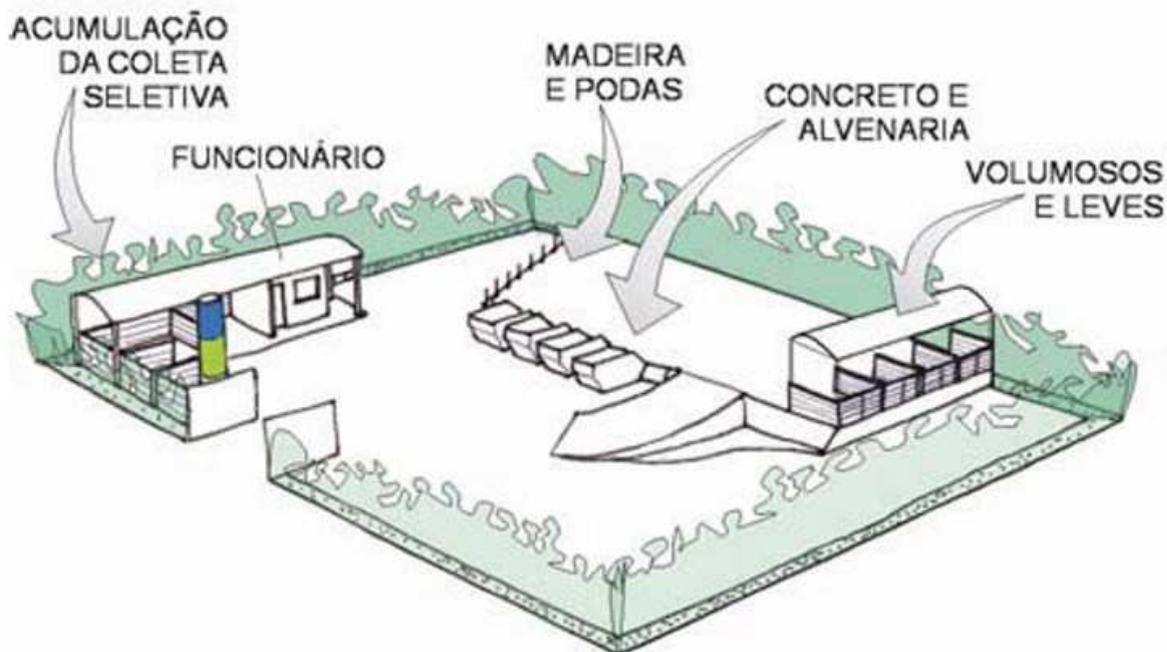
Em geral, estes locais são amplos e com espaços estabelecidos para cada tipo de resíduo que pode ser descartado no local. A instalação de ecopontos exige um planejamento mais detalhado, envolvendo projetos de arquitetura e engenharia.

A principal diferença entre os dois tipos é o porte, onde os PEVs recebem resíduos volumosos e que fazem parte da logística reversa, enquanto os LEVs são equipamentos menores, mas também aptos a armazenarem resíduos da coleta seletiva.

A seleção de um PEV ou LEV pelo gestor municipal serve para promover a adesão da população às práticas adequadas de coleta e descarte de resíduos, reduzindo a destinação inadequada de materiais recicláveis que, idealmente, deveriam ser direcionados às cooperativas de catadores de materiais recicláveis. Tais

estratégias foram implementadas em vários municípios para garantir o cumprimento dos objetivos descritos na PNRS (MMA, 2012).

Figura 4 - Desenho esquemático de um ecoponto.



Fonte: MMA (2012).

A presente pesquisa focou no estudo de localizações ideais de PEVs/Ecopontos, devido sua instalação ser mais complexa, demandar maiores áreas e exigir maiores investimentos.

Importante destacar que estas nomenclaturas (PEVs, LEVs e ecopontos) muitas vezes se confundem, sendo possível encontrar definições levemente diferentes entre municípios, com destaque para os tipos de resíduos aceitos.

Para exemplificar estas diferenças, foram listadas abaixo as definições de ecopontos em quatro cidades do mesmo estado (São Paulo): São Paulo, Ribeirão Preto, Jundiaí e Guarulhos:

Os ecopontos são locais destinados à entrega voluntária de resíduos pela população, como resíduos da construção civil, recicláveis, inservíveis e eletroeletrônicos. O serviço é gratuito e permite o descarte de até 1m³ de cada tipo de material (Ribeirão Preto, 2024).

Os Ecopontos são locais de entrega voluntária de pequenos volumes de entulho (até 1 m³), grandes objetos (móveis, poda de árvores etc.) e resíduos recicláveis. Nos Ecopontos, o município poderá dispor o material gratuitamente em caçambas distintas para cada tipo de resíduo. (São Paulo, 2023b).

Ecopontos são locais onde os cidadãos jundiaenses podem realizar o descarte gratuito de seus resíduos sólidos, gerados por conta de uma reforma (pequenos volumes de entulho), da troca de móveis velhos por novos, de restos de madeira ou materiais verdes (resultantes de podas em áreas particulares e da roçada de mato e grama), de equipamentos eletrônicos (computadores, CPUs e teclados, impressoras e demais hardwares), eletrodomésticos, baterias e pilhas. (Jundiá, 2023).

[...] os ECOPONTOS que são locais adequados para recebimento de entulhos, madeiras, podas e móveis velhos. [...] Os materiais deverão ser separados por tipo e depositados conforme indicação (Guarulhos, 2023).

Observa-se que, apesar das diferenças entre alguns tipos de resíduos aceitos nos ecopontos das diferentes cidades, os RCC e os resíduos volumosos são aceitos em todos. Esse padrão se repete também em praticamente todas as cidades que possuem estes equipamentos urbanos, o que é importante dado a relevância e o impacto ambiental destes tipos de resíduos.

Segundo a Associação Brasileira para Reciclagem de Resíduos da Construção Civil e Demolição (ABRECON), a construção civil representava cerca de 10% do PIB brasileiro e era responsável por 15% dos empregos formais criados no país no ano de 2019, sendo também a maior consumidora de recursos naturais, com uma participação entre 15 e 20%. (Angulo; Oliveira; Machado, 2022; Souza *et al.*, 2021).

Estudos indicam que aproximadamente 50% a 70% dos resíduos sólidos urbanos no Brasil são provenientes da construção civil, o que demonstra a grande contribuição desse setor para a geração de resíduos. A estimativa aponta para cerca de 100 milhões de toneladas de RCC gerados por ano, com um indicador mediano de geração de 500 kg por habitante por ano (Vieira *et al.*, 2022; Angulo; Oliveira; Machado, 2022).

Nos grandes centros urbanos, é comum a existência de “pontos viciados”, que são locais que mesmo limpos pelo poder público, voltam a receber o descarte indevido por parte da população.

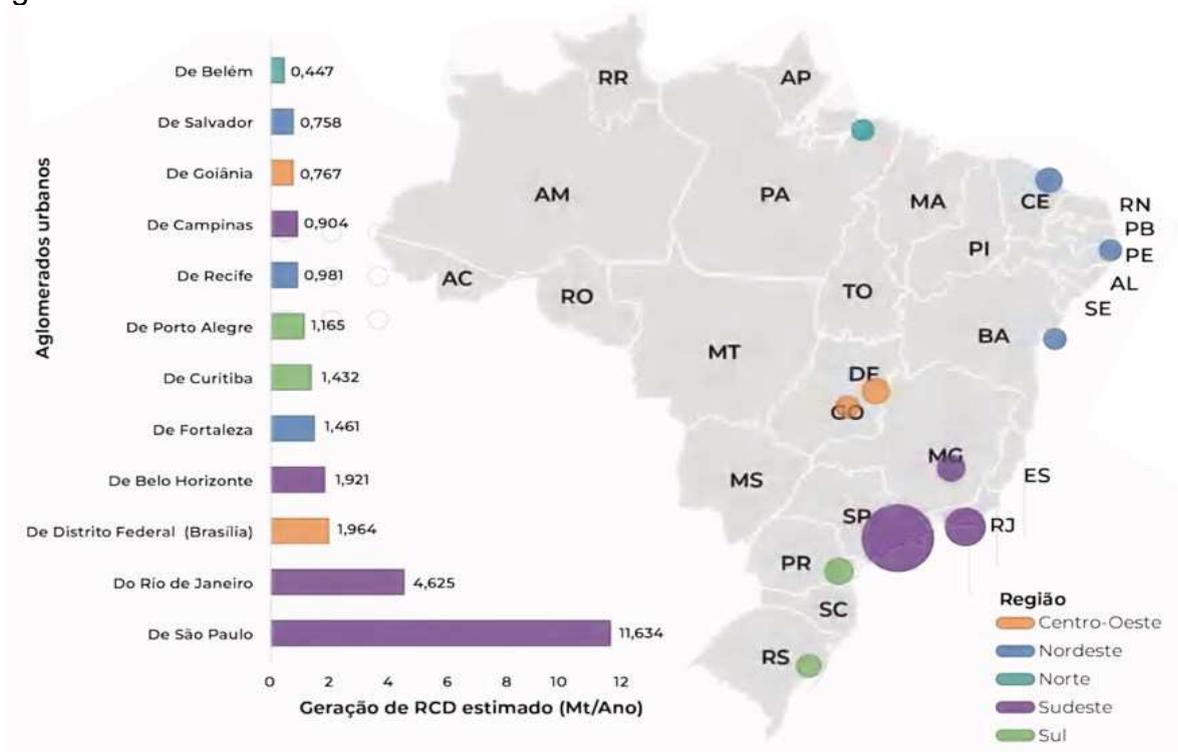
A Região Metropolitana de São Paulo, com aproximadamente 23 milhões de habitantes (12% da população brasileira), é um dos principais centros de geração de RCD. Além disso, a Região Metropolitana do Rio de Janeiro, com 12 milhões de habitantes (5% da população), e a Grande Belo Horizonte, com cerca de 5 milhões de habitantes (2,5% da população), também são áreas de destaque.

Outros aglomerados importantes incluem Recife, Salvador, Fortaleza, Brasília, Curitiba e Porto Alegre, que juntos somam 18 milhões de habitantes (10% da população brasileira). Esses aglomerados urbanos representam cerca de 30% da população brasileira e concentram uma parcela significativa da geração total de resíduos, destacando a necessidade de uma gestão eficiente nestes grandes centros urbanos. A Figura 5 apresenta a geração estimada de Resíduos da Construção e Demolição (RCD) em milhões de toneladas por ano nos maiores aglomerados urbanos brasileiros.

Apesar de toda esta geração, o Brasil possui um índice de reciclagem nacional de aproximadamente 15%, sendo comparável a países como Portugal e Espanha, mas ainda inferior aos índices de países mais desenvolvidos (Angulo; Oliveira; Machado, 2022).

Todo este cenário reforça a importância de ações que possam refletir no aumento de resíduos coletados nos ecopontos espalhados nos grandes centros urbanos no Brasil.

Figura 5 - Geração de RCD (Mt significa milhões de toneladas) nos principais aglomerados urbanos brasileiros.



Fonte: Angulo, Oliveira e Machado (2022).

3.2.2 Variáveis que influenciam o volume coletado

Além dos fatores que impactam na geração total de resíduos sólidos em uma determinada região, também se faz necessário estudar os fatores que influenciam na adesão da população à reciclagem e, conseqüentemente, no volume descartado pela população nos Pontos de Entrega Voluntária disponíveis. Foram analisados estudos nacionais e internacionais, com diferentes tipos de resíduos, para identificar estas variáveis-chave.

Kerber *et al.* (2020) observaram que a conscientização e o compromisso da população com a reciclagem é uma variável significativa, tendo em vista que níveis mais altos de conhecimento e comprometimento se correlacionam com o aumento da participação na reciclagem e descarte adequado de resíduos. Além disso, o estudo destacou a importância de identificar locais com alto tráfego de veículos, o que permite que indivíduos que usam veículos particulares para viagens diárias deixem seus resíduos nos pontos de entrega de forma conveniente enquanto viajam para o trabalho ou outros destinos.

Estudo desenvolvido por Hornik, Cherian e Madansky (1995) concluiu que facilitadores internos e incentivos externos podem influenciar no comportamento de reciclagem e descarte adequado de resíduos. Os mais importantes facilitadores internos observados foram o conhecimento e o comprometimento do consumidor, enquanto os incentivos externos foram as recompensas monetárias e a influência social.

Briguglio, Denaley e Wood (2016) descobriram que o voto político influencia significativamente na participação, refletindo valores e crenças sobre responsabilidade ambiental. Famílias que apoiavam partidos com fortes agendas ambientais estavam mais inclinadas a reciclar, pois viam isso como parte de seus compromissos políticos e ambientais.

Timlett e Williams (2009) observaram que, apesar de uma taxa de reciclagem estável de 78% na cidade de Portsmouth, Inglaterra, áreas densamente povoadas apresentaram mudanças significativas, com 10% das famílias começando a reciclar e 10% deixando de fazê-lo devido a mudanças físicas, como mudança de residência. O estudo destacou a dificuldade em alterar hábitos estabelecidos de reciclagem e sugeriu que políticas que aumentam a densidade populacional urbana

podem conflitar com esforços para aumentar as taxas de reciclagem. Além disso, a densidade urbana e a transitoriedade populacional, como em cidades universitárias, fazem com que os volumes coletados nos PEVs sejam inconsistentes.

Angeli e Zorpas (2019) investigaram o papel do voluntariado na melhoria das estratégias de gestão de resíduos em Chipre, destacando as contribuições de ONGs e iniciativas comunitárias para combater o descarte ilegal de resíduos.

D'Amato, Mazzanti e Nicolli (2011), ao realizarem análise econométrica das províncias italianas, observaram que áreas com maiores taxas de criminalidade apresentam níveis mais baixos de coleta seletiva de resíduos e métodos adequados de descarte, sugerindo que o crime afeta negativamente a gestão e o descarte legal de resíduos.

Por fim, Laeequddin *et al.* (2022) identificaram vários determinantes importantes que influenciam as intenções dos consumidores de descartar adequadamente lixo eletrônico. A conscientização da população, a facilidade de acesso às instalações e a percepção de expectativas sociais aumentam a probabilidade de descarte adequado. Por outro lado, o estudo constatou que as regulamentações, mesmo estabelecendo padrões e penalidades, não influenciam diretamente o comportamento de descarte.

Desta forma, pode-se observar que existe uma vasta gama de variáveis que influenciam o volume de resíduos coletados, onde se pode destacar a predominância de fatores sociais como a conscientização da população, iniciativas comunitárias, criminalidade, preferência política e expectativa social.

3.3 Sistemas de Informações Geográficas

3.3.1 Definição

Sistema de Informação Geográfica (SIG), do inglês *Geographic Information System*, é uma tecnologia que se destaca pela utilização de dados espaciais para a produção de mapas, realização de análises e avaliação de problemas do mundo real. Este sistema é fundamental para diversas áreas do conhecimento, pois permite a coleta, armazenamento, processamento e análise de dados georreferenciados.

De acordo com Teixeira *et al.* (1995), o SIG é definido como um conjunto integrado de programas, ferramentas, desenvolvimentos, metodologias, dados e

pessoas, que, de forma coesa, possibilita a execução de diversas funções relacionadas à gestão de informações espaciais.

Conjunto de programas, ferramentas, equipamentos, metodologias, dados e pessoas (usuário), perfeitamente integrados, de forma a tornar possível a coleta, o armazenamento, o processamento e análise de dados georreferenciados, bem como a produção derivada de sua aplicação. (Teixeira *et al.*, 1995)

O USGS, Serviço Geológico dos Estados Unidos, complementa esta definição ao caracterizar SIG como um sistema computacional que reúne, armazena, manipula e exibe informações geográficas georreferenciadas.

No sentido mais estrito, um SIG é um sistema computacional capaz de reunir, armazenar, manipular e exibir informações geograficamente referenciadas, ou seja, dados identificados de acordo com sua localização. Os profissionais também consideram que o SIG total inclui o pessoal operacional e os dados que entram no sistema. (USGS, 2023)

A NASA, por sua vez, descreve SIG da seguinte maneira:

SIG é uma coleção de ferramentas baseadas em computador para organizar informações de uma variedade de fontes de dados para mapear e examinar mudanças na Terra. Ele foi projetado para capturar, armazenar, gerenciar, analisar e visualizar todos os tipos de dados geográficos. (NASA, 2023).

Apesar de ser um erro comum, é importante salientar que o SIG não se restringe a programas computacionais como QGIS ou ArcGIS. Embora os *softwares* sejam componentes essenciais de um SIG, eles são apenas uma parte do todo.

Os principais componentes de um SIG incluem *hardware*, *software*, dados, métodos e usuários. *Hardware* se refere aos dispositivos físicos necessários para executar o *software* SIG, como computadores e dispositivos periféricos tais como dispositivos GPS, teclados e scanners (Arias; Roldan; Vélez, 2019; Chang, 2017).

O *software* engloba os programas e aplicativos que fornecem as ferramentas necessárias para entrada, armazenamento, processamento e visualização de dados, incluindo sistemas de gerenciamento de banco de dados (DBMS) e interfaces gráficas de usuário (GUI) (Merry *et al.*, 2023).

Dados, por sua vez, são o núcleo de um SIG, consistindo em dados espaciais que podem estar em formatos vetoriais ou rasterizados. Os métodos envolvem os procedimentos e técnicas usados para coletar, processar e analisar os dados, garantindo que o sistema opere da forma esperada e produza resultados úteis

e de acordo com os objetivos iniciais (Singhal; Gupta, 2010). Por fim, os usuários são os indivíduos que interagem com o SIG, desde coletores de dados e analistas até tomadores de decisão que utilizam as informações para as mais variadas aplicações. A Figura 6 abaixo apresenta um resumo destes componentes de um SIG.

Figura 6 - Componentes de SIG.



Fonte: Elaborado pelo autor (2023).

3.3.2 Tipos de dados em um SIG

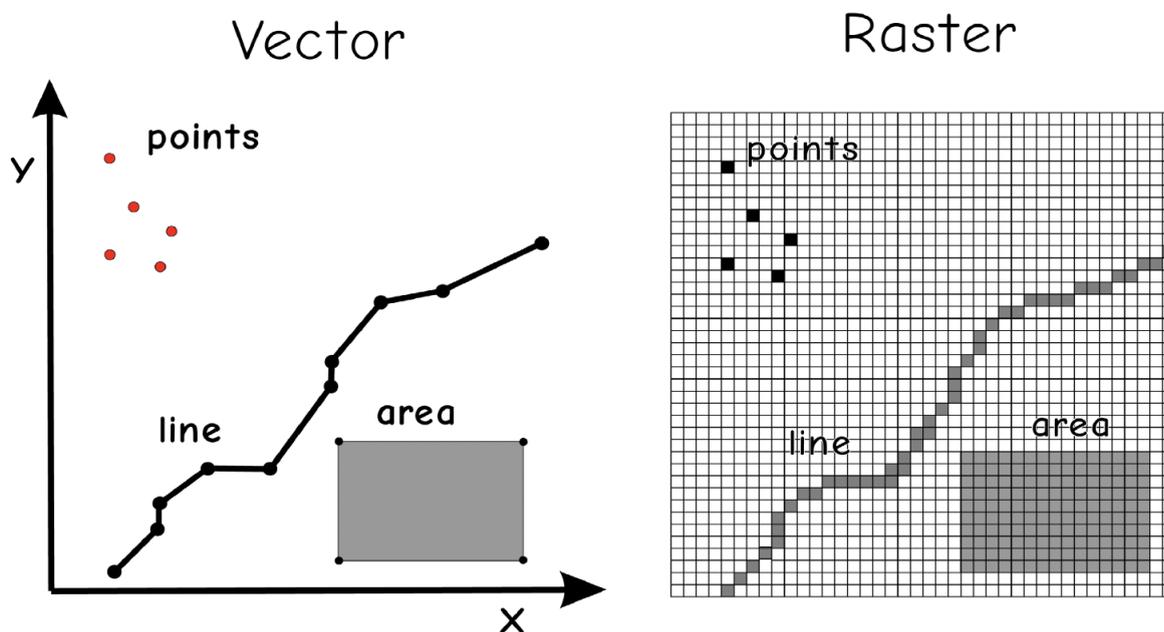
No contexto de dados e informações, é essencial distinguir entre ambos. Dados são elementos ou quantidades conhecidas que servem de base para a resolução de problemas, enquanto informação é um conjunto de dados relacionados que, quando analisados e interpretados, transmitem conhecimento significativo. Em outras palavras, dados são a matéria-prima, enquanto informações são o resultado do processamento e interpretação dos dados (Lynham, 2022). Esta distinção é fundamental para entender o papel do SIG na transformação de dados em informações que apoiam a tomada de decisões.

Os dados espaciais são aqueles que podem ser representados de forma espacial. Estes podem ter uma estrutura vetorial ou matricial, sendo estes últimos também conhecidos como dados raster (Fitz, 2008).

Dados vetoriais são representados por figuras geométricas básicas como pontos, linhas e polígonos, onde cada camada vetorial é composta por um único tipo de dado. Cada feição possui informações atribuídas a ela e que estão dispostas em uma tabela de atributos. Este tipo de dado é ideal para representar elementos como limites de cidades, estradas, rios etc.

Por outro lado, dados raster são representados como matrizes multidimensionais de células ou pixels, onde cada pixel representa a característica dominante de uma célula. Exemplos de dados raster incluem imagens de satélite e modelos digitais de elevação (MDE). Esse tipo de dados é vantajoso para visualizar paisagens amplas e realizar manipulações matemáticas, como álgebra de mapas e cálculos de declividade (Villarroya *et al.*, 2022). A Figura 7 apresenta uma representação visual destes dois tipos de dados espaciais.

Figura 7 - Comparação da forma de representação entre dados vetoriais e raster.



Fonte: Bolstad (2019).

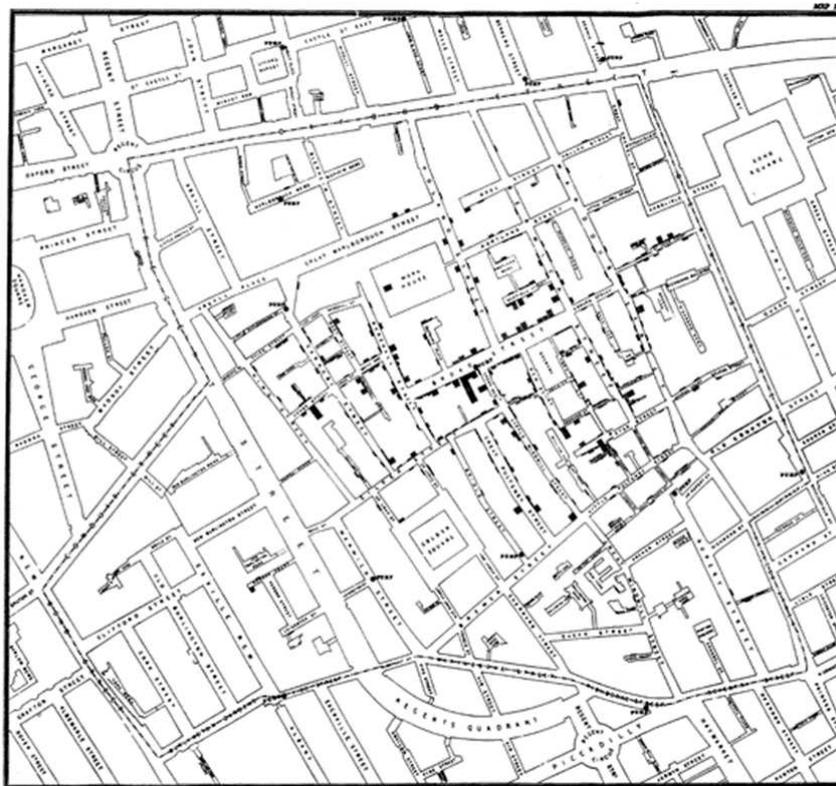
Destaca-se que não há um tipo de dado que seja superior ao outro; ambos possuem capacidades e limitações específicas. Em alguns casos, é preferível manter os dados no formato raster, e em outros no formato vetorial. A maioria dos dados pode

ser representada em ambos, além de ser possível a conversão entre si (Bolstad, 2019). A escolha entre dados vetoriais e raster depende do tipo de análise a ser realizada. A combinação de ambos os formatos pode proporcionar análises mais robustas e detalhadas, otimizando os resultados.

3.3.3 Aplicações SIG

Um exemplo histórico significativo do uso de SIG é o trabalho do Dr. John Snow no século XIX, que utilizou a análise espacial para identificar a fonte de um surto de cólera em Londres, demonstrando a eficácia do sistema na resolução de problemas de saúde pública. A Figura 8 apresenta o mapa de mortes por cólera em Londres, desenhado pelo pesquisador por volta de 1854.

Figura 8 - Mapa desenhado pelo Dr. John Snow representando as mortes durante o surto de cólera em Londres no século XIX.



Fonte: Stamp (1964).

As aplicações do SIG podem ser realizadas em vários campos, demonstrando sua versatilidade e importância. Na agricultura, o SIG auxilia no

monitoramento de safras, otimizando o uso da terra, o manejo integrado de pragas e melhorando a produtividade das culturas por meio de práticas de manejo direcionadas através da Agricultura de Precisão (Pierce; Clay, 2007).

O monitoramento ambiental e a avaliação de riscos também se beneficiam significativamente, através do monitoramento de sistemas de abastecimento de água, concentrações de metais pesados no solo e qualidade do ar, assim como avaliar os riscos ambientais da água, do solo e da atmosfera (Chen; Mao; Zhao, 2022).

Além disso, o GIS é usado no planejamento urbano e regional, planejamento de localização de lojas, gerenciamento do uso da terra e projeto de sistemas de transporte, tornando-o uma ferramenta valiosa para empresas públicas e privadas (Sadoun, 2006).

Outros exemplos que podem ser citados são a criação de rotas logísticas, exploração de recursos naturais, modelagem espacial, análises topográficas e demográficas, seleção de locais para instalação de equipamentos e análise hidrográfica.

3.3.4 Aplicações SIG na Gestão de Resíduos Sólidos

Aplicações em SIG fornecem uma ferramenta poderosa para avaliar e analisar dados espaciais relacionados à gestão de resíduos, permitindo uma avaliação abrangente da eficácia das práticas de gestão de resíduos e auxiliando os tomadores de decisão. Ao utilizar SIG, os usuários podem obter informações valiosas sobre os padrões espaciais, tendências e áreas potenciais para melhoria nas práticas de gestão de resíduos (Gutama; Iresha, 2023).

Utilizando SIG, a pesquisa desenvolvida por Das *et al.* (2023) visou identificar condições existentes de gerenciamento de resíduos, a realocação de caixas de coleta de resíduos e a proposição de rotas otimizadas de coleta de por meio da análise de rede.

Gahramanov, Gahramanov e Bagalova (2023) desenvolveram uma ferramenta de apoio à decisão utilizando SIG para o Distrito de Nizami, na República do Azerbaijão, visando aumentar a eficiência do sistema de coleta de resíduos, fornecendo informações detalhadas sobre a quantidade total de resíduos coletados, o sistema de coleta atual e os horários diários de coleta na área de estudo.

Estudo desenvolvido por Randazzo *et al.* (2018) visou identificar áreas adequadas para instalação de aterros sanitários no oeste da Sicília utilizando uma metodologia que integra Análise Multicritério e SIG. O processo envolveu uma exclusão inicial de locais inadequados com base na legislação italiana, seguida por uma avaliação detalhada das áreas restantes usando o Processo de Hierarquia Analítica (AHP) para classificar os sites em uma escala de adequabilidade de 0 a 10.

Diversos outros estudos similares foram realizados ao redor do mundo, combinando SIG com outras ferramentas de apoio à tomada de decisão (Adewumi *et al.*, 2019; Chabuk *et al.*, 2017; Deepak, 2022; Elkhachy, 2022; Oyedele *et al.*, 2022; Sumathi; Natesan; Sarkar, 2008).

Aremu, Adeleke e Sule (2011) desenvolveram estudo para determinar a localização ideal de lixeiras em Ilorin, Nigéria, incorporando restrições ambientais e rotas de trânsito para melhorar a cobertura e acessibilidade do serviço. Os resultados indicaram que os locais otimizados através de SIG foram mais acessíveis em comparação com os posicionamentos empíricos, o que potencialmente melhora a satisfação do público.

O artigo de Paz, Lafayette e Sobral (2018) desenvolve um sistema de planejamento baseado em SIG para gerenciar RCC em Recife, Brasil. Este sistema mapeia pontos de descarte ilegal, identifica áreas adequadas para pontos de entrega voluntária para pequenos geradores de resíduos e propõe áreas de transbordo e triagem de resíduos para grandes geradores.

Zhou, Zhu e Mao (2014) propuseram um sistema de rede de reciclagem de lixo eletrônico baseado em SIG para aumentar a eficiência da reciclagem. O sistema prevê quantidades de resíduos eletrônicos e identifica os principais locais de operação, como locais de reciclagem, centros de desmontagem e fábricas de descarte.

Por fim, Silva e Santos Neto (2020) propuseram um modelo otimizado para localizar pontos de entrega voluntária para melhorar a coleta de óleos e gorduras residuais, integrando SIG com um modelo de localização de instalações através de um modelo de p-medianas.

Esses exemplos ressaltam o papel crítico do SIG no aumento da eficiência e sustentabilidade dos sistemas de gerenciamento de resíduos sólidos em todo o mundo.

3.4 Modelagem preditiva

A modelagem preditiva é uma metodologia amplamente usada para prever resultados futuros com base em dados pré-existentes. A modelagem preditiva é aplicada em uma ampla gama de áreas, incluindo finanças, marketing, saúde, manufatura, segurança, entre outras.

Em SIG, a modelagem preditiva desempenha um papel relevante no mapeamento espacial, possibilitando a previsão de características ambientais além dos locais amostrados. Esta metodologia envolve o desenvolvimento de modelos preditivos ideais usando técnicas de aprendizado de máquina, geoestatística e estatísticas modernas para gerar previsões espaciais, avaliar a precisão e visualizar resultados (Meyer; Pebesma, 2021).

Esse processo envolve várias etapas, desde a coleta e preparação dos dados até a criação e validação do modelo. Várias técnicas, como regressão linear, árvores de decisão, redes neurais, entre outras, são usadas para desenvolver modelos preditivos. O objetivo final é prever valores ou classificações futuras, como vendas futuras, comportamento do cliente, demanda por produtos, riscos financeiros, etc. A validação do modelo ocorre usando um conjunto de dados de teste para garantir que ele faça previsões precisas e que possam ser generalizados (Starbuck, 2023).

Conforme mencionado anteriormente, este trabalho visa desenvolver modelos preditivos usando dados históricos de peso coletado de resíduos em ecopontos para ajudar no planejamento e otimização de estratégias de gerenciamento de resíduos, garantindo que os ecopontos estejam instalados em locais adequados, com acessibilidade e conveniência, para maximizar o peso coletado nestes PEVs. A seguir, discutimos algumas opções de modelos preditivos que foram utilizados na pesquisa.

3.4.1 Interpolação Inversa da Distância

3.4.1.1 Definição

A Interpolação Inversa da Distância (IDW) é uma técnica amplamente utilizada em análises espaciais devido à sua simplicidade e fácil aplicação na previsão de valores desconhecidos em uma superfície contínua. Este método baseia-se na premissa de que pontos próximos no espaço são mais similares do que pontos mais distantes e foi proposto inicialmente Shepard (1968).

A IDW é frequentemente empregada para preencher lacunas em dados espaciais, permitindo a criação de superfícies contínuas a partir de amostras pontuais. Esta metodologia é particularmente útil em estudos geoespaciais onde a coleta de dados em todos os pontos de interesse é inviável. Os principais motivos para utilizar a interpolação IDW são:

- a) Estimativa simples de valores desconhecidos, tendo em vista que é possível estimar valores em locais onde os dados não foram coletados, com base nos valores de pontos conhecidos nas proximidades;
- b) Análise de padrões espaciais, permitindo identificar e analisar padrões espaciais ao criar superfícies interpoladas que revelam variações espaciais de fenômenos;
- c) Apoio à tomada de decisão, facilitando a decisão em diversas áreas de estudo.

Para aplicar a IDW, é necessário um conjunto de dados georreferenciados que incluam os valores amostrais de interesse. A IDW calcula a estimativa de um ponto desconhecido como uma média ponderada dos valores de pontos conhecidos, onde os pesos são inversamente proporcionais à distância do ponto desconhecido aos pontos conhecidos. A fórmula básica da IDW é:

$$Z(x_0) = \frac{\sum_{i=1}^N \frac{Z(x_i)}{d(x_i, x_0)^p}}{\sum_{i=1}^N \frac{1}{d(x_i, x_0)^p}} \quad (1)$$

Onde:

$Z(x_0)$ é o valor interpolado no ponto x_0 ;

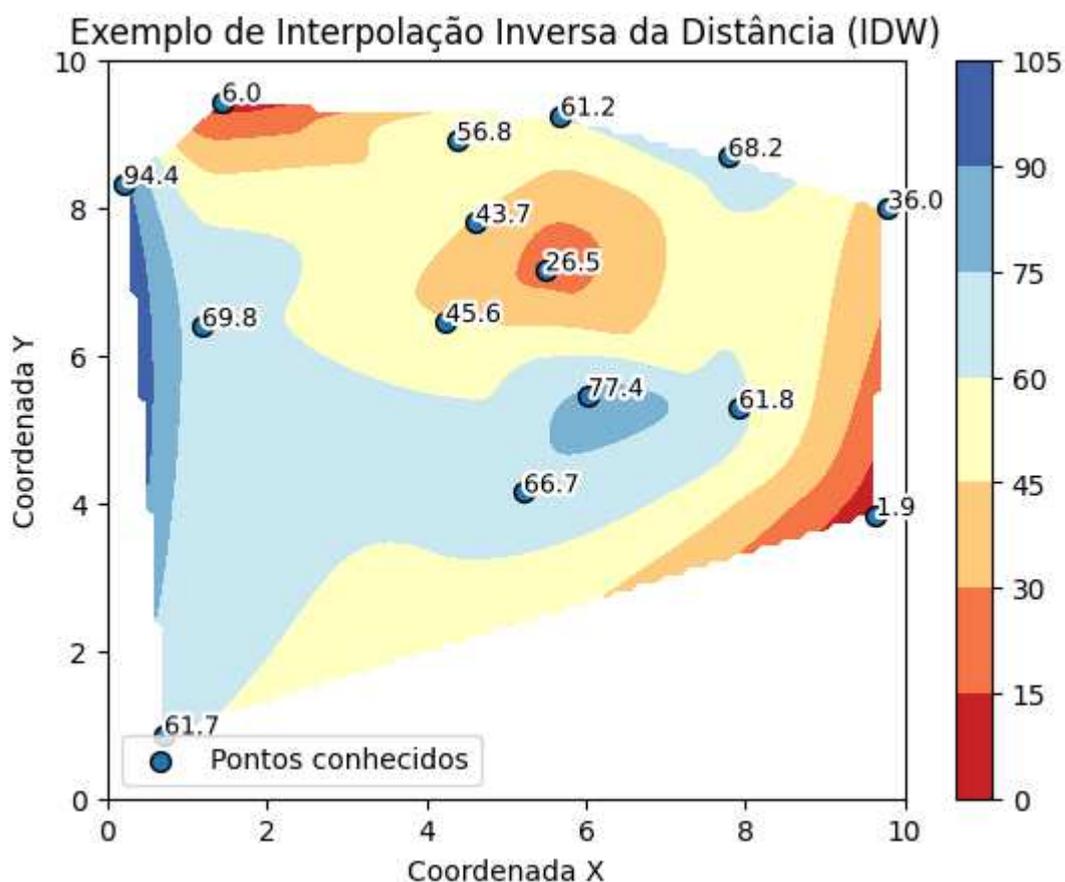
$Z(x_i)$ são os valores conhecidos nos pontos x_i ;

$d(x_i, x_0)$ é a distância entre o ponto x_i e o ponto x_0 ;

p é a potência que controla a influência da distância. Um valor maior de p dá mais peso aos pontos mais próximos.

A Figura 9 abaixo ilustra o conceito de IDW, onde os pontos conhecidos são usados para estimar valores em locais desconhecidos. Os círculos representam os pontos conhecidos, e as linhas de contorno representam a superfície interpolada.

Figura 9 – Exemplo de Interpolação Inversa da Distância para uma variável qualquer em um plano cartesiano.



Fonte: Elaborado pelo autor (2024).

Em relação às suas aplicações, um dos usos mais comuns da interpolação IDW é na estimativa de valores de precipitação a partir de pontos conhecidos (estações meteorológicas) em uma rede de monitoramento (Gutiérrez; Carrascal; Ortega, 2021; Chen; Liu, 2012; Rodrigues, M.; Rodrigues, B.; Monte, 2012).

Outras aplicações de destaque são a estimativa de níveis de contaminação de metais pesados no solo (Jasim & Walli, 2023; Qiao *et al.*, 2021) e níveis de poluentes atmosféricos e índices de qualidade do ar (Jumaah *et al.*, 2019; Rojas-

Avellaneda, 2007). Estudos que envolvam IDW e gestão de resíduos sólidos não foram encontrados na revisão de literatura realizada.

3.4.2 Regressão Linear

3.4.2.1 Definição

A regressão linear é um método estatístico amplamente utilizado em pesquisas por sua simplicidade, fácil interpretação de resultados e eficácia na modelagem de relações entre variáveis. Este método é usado para entender, modelar, prever ou explicar fenômenos complexos, que podem ter vários fatores (ou variáveis) que influenciam seu comportamento ou resultados (Gujarati, 2019).

Alguns tipos de estatísticas espaciais identificam onde um fenômeno está acontecendo e quantificam a frequência dos eventos. No entanto, a análise de regressão ajuda a abordar a razão de um fenômeno estar ocorrendo, possibilitando esta metodologia ser utilizada como uma ferramenta de apoio à tomada de decisões.

Além do apoio à tomada de decisões, as principais razões para realizar uma análise de regressão linear são:

- a) Explorar hipóteses que analisem variáveis que podem estar relacionadas;
- b) Melhorar a compreensão de um fenômeno ao identificar variáveis que ajudam a explicar a ocorrência de um fenômeno;
- c) Prever valores em outros locais ou em outros momentos.

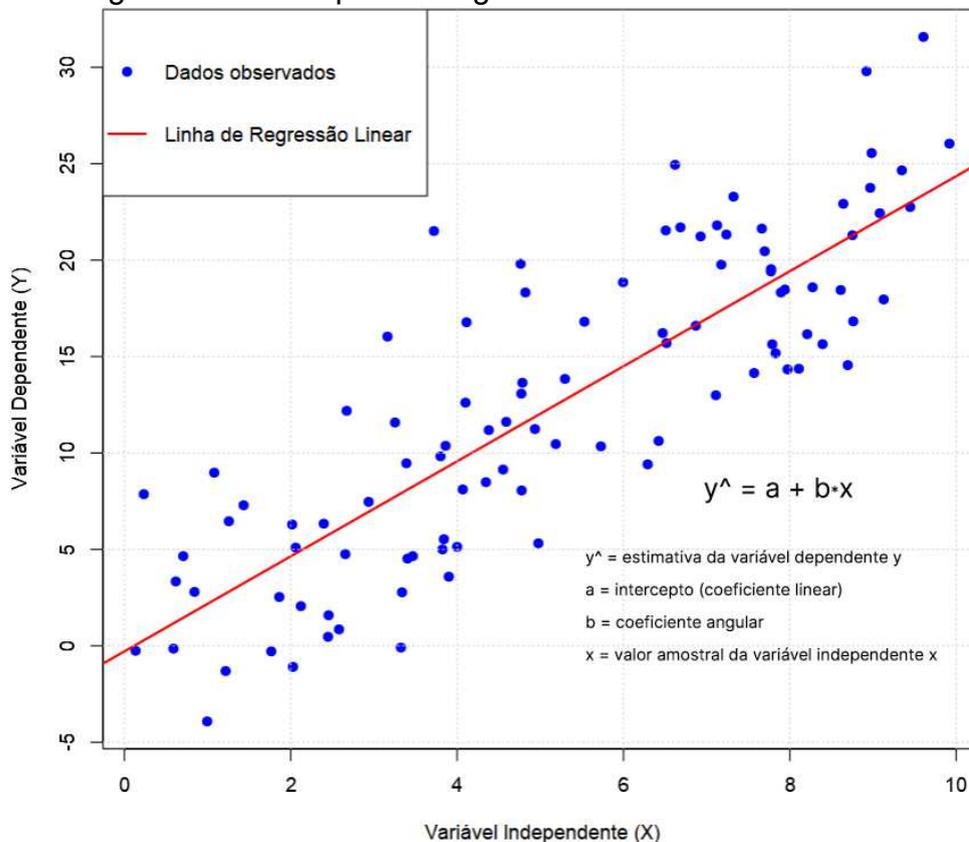
Para a realização da regressão, é necessário verificar a existência de um conjunto de dados que suporte o resultado desejado que incluía valores para o fenômeno modelado e variáveis que possam estar relacionadas ao fenômeno.

Com base nestes conjuntos de dados, as ferramentas de análise de regressão constroem uma ou mais equações que são usadas para estimar o valor de um fenômeno (variável dependente) com base na influência das variáveis relacionadas (variáveis explicativas ou independentes).

A Figura 10 exemplifica o conceito de regressão linear com os pontos azuis representando os dados observados. A linha vermelha representa a linha de regressão linear, que é o melhor ajuste linear para os dados observados. Esta linha é

determinada de forma a minimizar a soma dos quadrados das diferenças (resíduos) entre os valores observados e os valores previstos pela linha.

Figura 10 – Exemplo de Regressão Linear



Fonte: Elaborado pelo autor (2024).

Além disso, a regressão linear possibilita a interpretação de coeficientes, que representam a magnitude e a direção da relação entre as variáveis, o que é uma característica relevante para tomadores de decisão que desejam se basear em dados e a torna uma ferramenta versátil em vários campos de pesquisa, incluindo estudos ambientais, economia, ciências de alimentos e saúde (Xie, 2020).

Por fim, o desempenho do modelo é avaliado pelo valor do coeficiente de determinação (R^2), que deve ser próximo de 1 e preferencialmente acima de 0,5. O R^2 representa a porcentagem de variação na variável dependente que é explicada pela variação nas variáveis explicativas. Um valor de R^2 próximo de 1 indica que a variável dependente é bem explicada pelo modelo, enquanto um valor próximo de 0 sugere que a variável dependente não é adequadamente explicada pelas variáveis explicativas do modelo.

3.4.2.2 **Pressupostos e testes para Regressão Linear**

Para trabalhar com regressão linear, é fundamental que os dados sigam certos pressupostos. Estes pressupostos garantem a validade e a confiabilidade dos resultados. Um dos requisitos essenciais é que os resíduos do modelo de regressão sejam não correlacionados, tenham uma distribuição normal e apresentem variância constante (Berry, 1993; Choueiry; Salameh, 2021). Além disso, é importante que haja independência entre as amostras (Lederer *et al.*, 2020).

A normalidade dos erros é uma suposição essencial da regressão linear, pois garante que os estimadores não sejam tendenciosos e tenham a menor variância possível (Schmidt; Finan, 2018). Além disso, a linearidade, independência dos erros, não multicolinearidade e homoscedasticidade são pressupostos fundamentais para sua aplicação correta (Wahid; Setyono, 2022).

Desta forma, verificações estatísticas devem ser realizadas após a execução de uma regressão para garantir que os pressupostos são atendidos e que a equação de regressão resultante produz resultados que expliquem de forma adequada a variável dependente. Os pressupostos são:

- a) Linearidade;
- b) Homoscedasticidade;
- c) Normalidade dos resíduos;
- d) Independência;
- e) Ausência de Multicolinearidade.

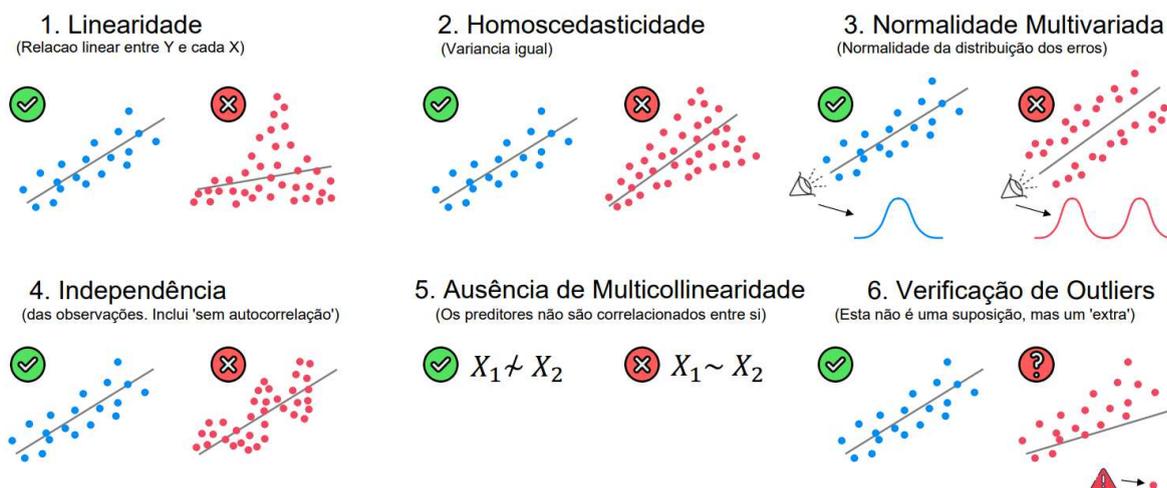
O pressuposto da linearidade postula que a relação entre a variável dependente e as variáveis independentes é linear. Isso significa que não deve haver efeito curvilíneo e que a mudança na variável dependente é proporcional à mudança nas variáveis independentes (Berry, 1993).

O pressuposto da homoscedasticidade afirma que a variância dos termos residuais deve ser constante. Já o pressuposto da normalidade estabelece que os resíduos sejam normalmente distribuídos (Berry, 1993).

O pressuposto da independência exige que as observações sejam independentes umas das outras. Por fim, o pressuposto da ausência de multicolinearidade garante que as variáveis independentes não sejam altamente correlacionadas (Berry, 1993).

Violações destes pressupostos podem levar a estimativas tendenciosas, inconsistentes e ineficientes, diminuindo a confiabilidade das previsões do modelo. A Figura 11 abaixo mostra como estes pressupostos são visualizados de forma gráfica.

Figura 11 – Visualização gráfica dos pressupostos da regressão linear.



Fonte: Adaptado de Super Data Science (2022).

3.4.2.3 Aplicações de Regressão Linear

Nesta seção, foram analisados estudos que envolveram a combinação de regressão linear com SIG e com gestão de resíduos sólidos. Em relação à combinação com SIG, um dos primeiros estudos foi o desenvolvido por Mattson e Godfrey (1994), onde os pesquisadores desenvolveram um modelo de regressão múltipla combinado com dados SIG para prever as concentrações de sódio em riachos em Massachusetts, Estados Unidos. O modelo explica 68% da variação na concentração de sódio e destaca que o sal das rodovias interestaduais e principais estaduais é a principal fonte de contaminação.

Em 2003, Suzuki utilizou análise de regressão múltipla combinada com SIG para identificar áreas promissoras para depósitos de kuroko, um tipo depósito de sulfeto maciço de origem vulcânica, em um distrito no Japão. Os resultados mostraram que 80% dos corpos de minério podem estar localizados dentro de 27,3% da área de estudo, destacando a eficiência do método em comparação com modelos tradicionais de sobreposição de índices.

Pan *et al.* (2007) empregaram análise de regressão múltipla para prever deslizamentos de terra no distrito de Himi, Japão, avaliando variáveis independentes como geologia, declividade, uso da terra e solo. Cada fator foi classificado em grupos, e pesos estatísticos são atribuídos para determinar os coeficientes de regressão linear para áreas propensas a deslizamentos, aplicados a toda a região para criar um mapa de avaliação de risco. A geologia e o aspecto da inclinação foram os fatores mais relevantes para a suscetibilidade a deslizamentos.

Jiang *et al.* (2019) analisaram a contaminação por mercúrio em solos agrícolas no sudeste da China, utilizando 104 amostras de solo de campos de vegetais, arrozais e pomares. A modelagem de regressão linear múltipla em conjunto com SIG e análise espacial revelou que os campos de vegetais e arrozais têm maiores concentrações médias de Hg em comparação com os pomares e que emissões industriais, escoamento superficial e tráfego foram identificados como principais fontes de contaminação.

Farhan e Adi (2023) desenvolveram modelo que fornecia previsões da vulnerabilidade às inundações em Pontianak, Indonésia, para identificar áreas propensas a inundações. Foram gerados mapas que mostram pontuações de vulnerabilidade para cada subdistrito da cidade, tornando as atividades de mitigação mais direcionadas e eficazes.

Já em relação à aplicação desta metodologia na gestão de resíduos sólidos, diversos estudos podem ser citados. Giel e Dąbrowska (2021) desenvolveram um modelo de regressão múltipla para estimar o tempo que um caminhão de lixo passa em um ponto de coleta, considerando fatores como tipo de construção e número de contêineres.

Wikurendra, Syafiuddin e Herdiani (2023) desenvolveram um modelo para prever a geração de resíduos e a frota de transporte necessária em uma cidade da Indonésia. Para tal objetivo, pesquisas de campo foram conduzidas para coletar dados sobre a população, a geração de resíduos e as condições da frota de resíduos, que foram então analisados para projetar as necessidades futuras e otimizar as estratégias de gestão de resíduos.

Khanal (2023) desenvolveu um estudo que empregou análise de regressão linear para prever a geração de RSU em Katmandu, Nepal, utilizando dados históricos da população e números de geração de resíduos. A análise revelou uma forte

correlação entre crescimento populacional e geração de resíduos, com um coeficiente de 0,956 e um valor de coeficiente de determinação (R^2) de 0,913, indicando um modelo preditivo robusto.

Sharma e Jailia (2022) investigaram a eficiência dos sistemas de gestão de resíduos em 26 cidades indianas e identificaram relações entre variáveis como população, resíduos, casas, área, veículos e trabalhadores. O estudo encontrou altos valores de R^2 e demonstrou que o modelo pode prever com eficácia a produção de lixo, além da força de trabalho e dos veículos necessários para o gerenciamento eficiente de resíduos.

4 METODOLOGIA

Este capítulo descreve as metodologias utilizadas para otimizar a localização de ecopontos em cidades brasileiras em termos de peso total coletado por ano. Inicialmente, é detalhado a metodologia de seleção das cidades de estudo e a coleta e organização dos dados socioeconômicos, ambientais e infraestruturais necessários.

Em seguida, operações de geoprocessamento e ferramentas estatísticas são descritas, as quais foram utilizadas para realizar, respectivamente, análises espaciais e estatísticas para identificação de padrões e correlações entre a variável dependente (peso coletado) e as demais variáveis estudadas.

Por fim, foi apresentado o desenvolvimento de dois modelos preditivos, incluindo um modelo determinístico e um baseado em regressão linear, para identificação de áreas ideais para a instalação de novos ecopontos, baseando-se em variáveis relevantes analisadas.

4.1 Programas utilizados

Para o desenvolvimento deste estudo, foram utilizados os seguintes programas: Excel, QGIS e RStudio.

O Excel é um programa de planilha eletrônica desenvolvido pela Microsoft, no qual foi realizada a organização de dados tabulares utilizados neste estudo. A versão utilizada foi a versão 2019.

O QGIS é um software livre e de código aberto para SIG que permite a visualização, edição e análise de dados geoespaciais (QGIS, 2024b). O programa foi utilizado para geração de mapas e análises espaciais envolvendo dados vetoriais e raster. A versão utilizada foi a versão 3.34, denominada *Prizren*.

O RStudio é um ambiente de desenvolvimento integrado para a linguagem de programação R, que é especializada em estatística e análise de dados (Posit, 2024). A interface foi utilizada para compilação de códigos em R, realização de análises estatísticas, geração de gráficos e desenvolvimento do script final para o modelo. A versão utilizada foi a versão 2023.12.1.402, denominada *Ocean Storm*.

4.2 Panorama da quantidade de ecopontos no Brasil

Para delimitação da área do estudo, foi realizado inicialmente um levantamento sobre a quantidade de ecopontos em grandes centros urbanos no Brasil, a fim de compreender o panorama nacional. Para atingir este objetivo, foi feita uma seleção de municípios brasileiros que atendam pelo menos um dos seguintes requisitos:

- a) População acima de um milhão de habitantes segundo o Censo de 2022;
- b) Ser uma capital estadual ou federal.

Após esta filtragem inicial, foram selecionados 29 municípios, sendo 26 capitais estaduais, uma capital federal (Brasília) e dois municípios com mais de um milhão de habitantes (Guarulhos e Campinas, ambas no estado de São Paulo). A lista de municípios é apresentada na Tabela 3 abaixo.

Tabela 3 - Lista de municípios brasileiros com mais de um milhão de habitantes e/ou que são capitais federais ou estaduais.

Ordem	Código ¹	Cidade	Estado	População ² (hab.)
1	3550308	São Paulo	São Paulo	11.451.999
2	3304557	Rio de Janeiro	Rio de Janeiro	6.211.223
3	5300108	Brasília	Distrito Federal	2.817.381
4	2304400	Fortaleza	Ceará	2.428.708
5	2927408	Salvador	Bahia	2.417.678
6	3106200	Belo Horizonte	Minas Gerais	2 315 560
7	1302603	Manaus	Amazonas	2.063 689
8	4106902	Curitiba	Paraná	1.773.718
9	2611606	Recife	Pernambuco	1.488.920
10	5208707	Goiânia	Goiás	1.437.366
11	4314902	Porto Alegre	Rio Grande do Sul	1.332.845
12	1501402	Belém	Pará	1.303.403
13	3518800	Guarulhos	São Paulo	1.291.771
14	3509502	Campinas	São Paulo	1.139.047
15	2111300	São Luís	Maranhão	1.037.775
16	2704302	Maceió	Alagoas	957.916
17	5002704	Campo Grande	Mato Grosso do Sul	898.100
18	2211001	Teresina	Piauí	866.300
19	507507	João Pessoa	Paraíba	833.932
20	2408102	Natal	Rio Grande do Norte	751.300

Ordem	Código¹	Cidade	Estado	População² (hab.)
21	5103403	Cuiabá	Mato Grosso	650 877
22	2800308	Aracaju	Sergipe	602.757
23	4205407	Florianópolis	Santa Catarina	537.211
24	1100205	Porto Velho	Rondônia	460.434
25	1600303	Macapá	Amapá	442.933
26	1400100	Boa Vista	Roraima	413.486
27	1200401	Rio Branco	Acre	364.756
28	3205309	Vitória	Espírito Santo	322.869
29	1721000	Palmas	Tocantins	302.692

Fonte: Adaptado de IBGE (2023).

Observações:

¹ Código do IBGE de identificação do município.

² População segundo Censo 2022 do IBGE.

Após a seleção dos municípios, foi feita uma extensa pesquisa na Internet, em fontes oficiais de cada Prefeitura, para obtenção de informações relacionadas aos ecopontos (quantidade, endereços, peso coletado anualmente, início da operação e como estes equipamentos são conhecidos).

4.3 Delimitação da área de estudo

A área alvo do estudo foi determinada a partir das cidades que atenderam aos seguintes critérios:

- a) Quantidade acima de 20 ecopontos e com uma boa distribuição espacial no território do município;
- b) Disponibilidade de dados espaciais georreferenciados para o desenvolvimento de análises exploratórias.

Considerando apenas o critério de quantidade de ecopontos, temos sete cidades que poderiam ter sido utilizadas para o estudo:

- a) São Paulo/SP (124 ecopontos);
- b) Fortaleza/CE (95 ecopontos);
- c) Rio de Janeiro/RJ (82 ecopontos);
- d) Belo Horizonte/MG (34 ecopontos);
- e) Guarulhos/SP (33 ecopontos);

f) São Luís/MA (25 ecopontos);

g) Brasília/DF (21 ecopontos).

Rio de Janeiro e São Paulo, embora tenham uma quantidade considerável de ecopontos, não possuem dados disponíveis de peso coletado por ecoponto, o que é fundamental para a sua utilização como entrada neste estudo.

No entanto, São Paulo possui dados de peso coletado de RSU agrupados a nível de subprefeitura (subdivisões administrativas). Em outras palavras, os pesos coletados nos 124 ecopontos, distribuídos nas 32 subprefeituras que compõem o município, são somados de acordo com a sua localização à nível de subprefeitura. Estes dados foram utilizados para validação do modelo preditivo baseado em regressão linear e permitiram testar a robustez e a aplicabilidade do modelo em diferentes contextos urbanos e escalas administrativas.

Em relação à São Luís, o município não possui dados espaciais organizados e disponibilizados publicamente em portais que pudessem ser úteis para o desenvolvimento deste estudo.

Por fim, embora Brasília tenha dados espaciais disponíveis e um número considerável de ecopontos, ela não foi utilizada por conta de ser uma cidade planejada, o que fez com seu crescimento urbano tenha características únicas e distintas dos demais centros urbanos brasileiros. Ao utilizá-la como dado de entrada em nosso modelo, poderíamos comprometer a qualidade do resultado final.

Dessa forma, Guarulhos/SP, Fortaleza/CE e Belo Horizonte/MG foram as cidades selecionadas para a área de estudo, enquanto dados de São Paulo/SP foram utilizados para validação.

4.4 Caracterização das cidades selecionadas

4.4.1 Belo Horizonte

A cidade de Belo Horizonte representa o sexto maior núcleo urbano do Brasil. Com uma população de 2,315 milhões de habitantes segundo o último censo (IBGE, 2023), a cidade está geograficamente localizada nas coordenadas 19° 55' 15" de latitude Sul e 43° 56' 16" de longitude oeste. Sua área total é de 331,354 km², ocupando a posição 3219^a de extensão territorial no Brasil (IBGE, 2024a).

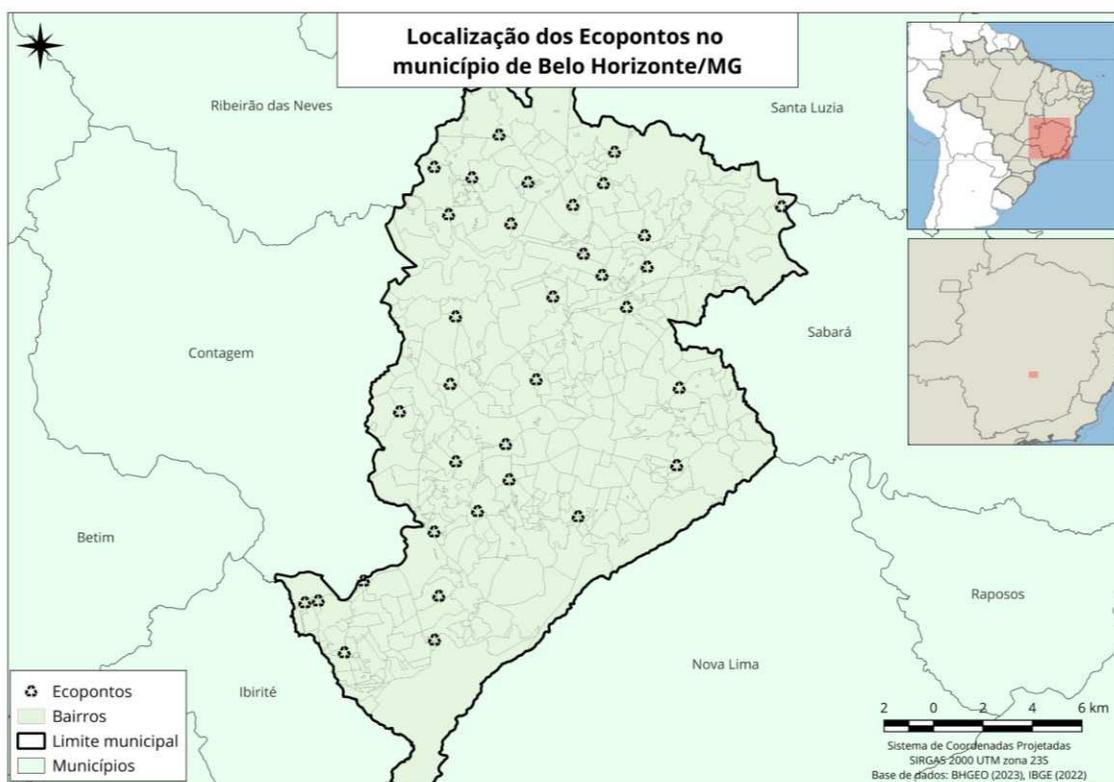
O município apresenta um Produto Interno Bruto (PIB) de R\$ 105,829 bilhões, sendo o 4º maior do Brasil. Em relação ao Índice de Desenvolvimento Humano (IDH), Belo Horizonte apresenta um índice de 0,810. (IBGE, 2024a).

No que tange à gestão de resíduos sólidos, a principal lei municipal relacionada ao tema de gestão de resíduos sólidos é a Lei nº 10.522, de 24 de agosto de 2012, institui o Sistema de Gestão Sustentável de Resíduos da Construção Civil e Resíduos Volumosos - SGRCC - e o Plano Municipal de Gerenciamento Integrado de Resíduos da Construção Civil e Resíduos Volumosos - PMRCC, e dá outras providências. (Belo Horizonte, 2012).

Em 2023, foram coletadas aproximadamente 138.710 toneladas de resíduos nos 34 ecopontos disponíveis na cidade (Belo Horizonte, 2024b).

Por fim, o portal oficial de arquivos georreferenciados de Belo Horizonte se chama “BHGEO MAP” e permite o download de mais de 200 camadas temáticas para o município (Belo Horizonte, 2024a). A Figura 12 apresenta um mapa com a distribuição espacial dos ecopontos no município de Belo Horizonte.

Figura 12 - Distribuição espacial dos ecopontos ao longo do território do município de Belo Horizonte.



Fonte: Elaborado pelo autor (2024).

4.4.2 Fortaleza

A cidade de Fortaleza representa o quarto maior núcleo urbano do Brasil. Com uma população de 2,428 milhões de habitantes segundo o último censo (IBGE, 2023), a cidade está geograficamente localizada nas coordenadas 3° 43' 6" de latitude Sul e 38° 32' 35" de longitude oeste. Sua área total é de 312,353 km², ocupando a posição 3353^a de extensão territorial no Brasil (IBGE, 2024b).

O município apresenta um Produto Interno Bruto (PIB) de R\$ 73,436 bilhões, sendo o 11º maior do Brasil. Em relação ao Índice de Desenvolvimento Humano (IDH), Fortaleza apresenta um índice de 0,754. (IBGE, 2024b).

No que tange à gestão de resíduos sólidos, o órgão responsável pela coordenação da gestão dos ecopontos em Fortaleza é a Secretaria Municipal da Conservação e Serviços Públicos (SCSP).

Em relação à legislação municipal, a principal lei relacionada ao tema de gestão de resíduos sólidos é a Lei nº 10.340, de 28 de abril de 2015, conhecida popularmente como a “lei do lixo” (Fortaleza, 2015). A legislação responsabiliza grandes geradores pelo gerenciamento de seus resíduos sólidos, exigindo planos de gerenciamento (PGRS) para emissão de licenças, além de estabelecer que apenas entidades credenciadas podem realizar a coleta e transporte de resíduos e definir penalidades para infrações.

Além disso, diferentemente das demais cidades selecionadas para este estudo, Fortaleza possui dois programas baseados em estímulos financeiros para aumentar o descarte de resíduos nos ecopontos: “Recicla Fortaleza” e “E-carroceiro”.

O programa Recicla Fortaleza foi instituído em 2016 com o objetivo de estimular o descarte de materiais recicláveis ao recompensar o munícipe com descontos na conta de energia elétrica. Segundo a Prefeitura, o munícipe pode conferir no ecoponto a tabela de valores dos resíduos recicláveis, onde o crédito será calculado de acordo com o peso e o tipo do material, levando em consideração o mercado (Fortaleza, 2023c).

O programa E-carroceiro, por sua vez, foi instituído em 2017 e tem como objetivo reduzir o descarte irregular de RCC e resíduos volumosos e inserir os carroceiros na gestão de resíduos da cidade. Os carroceiros cadastrados no programa

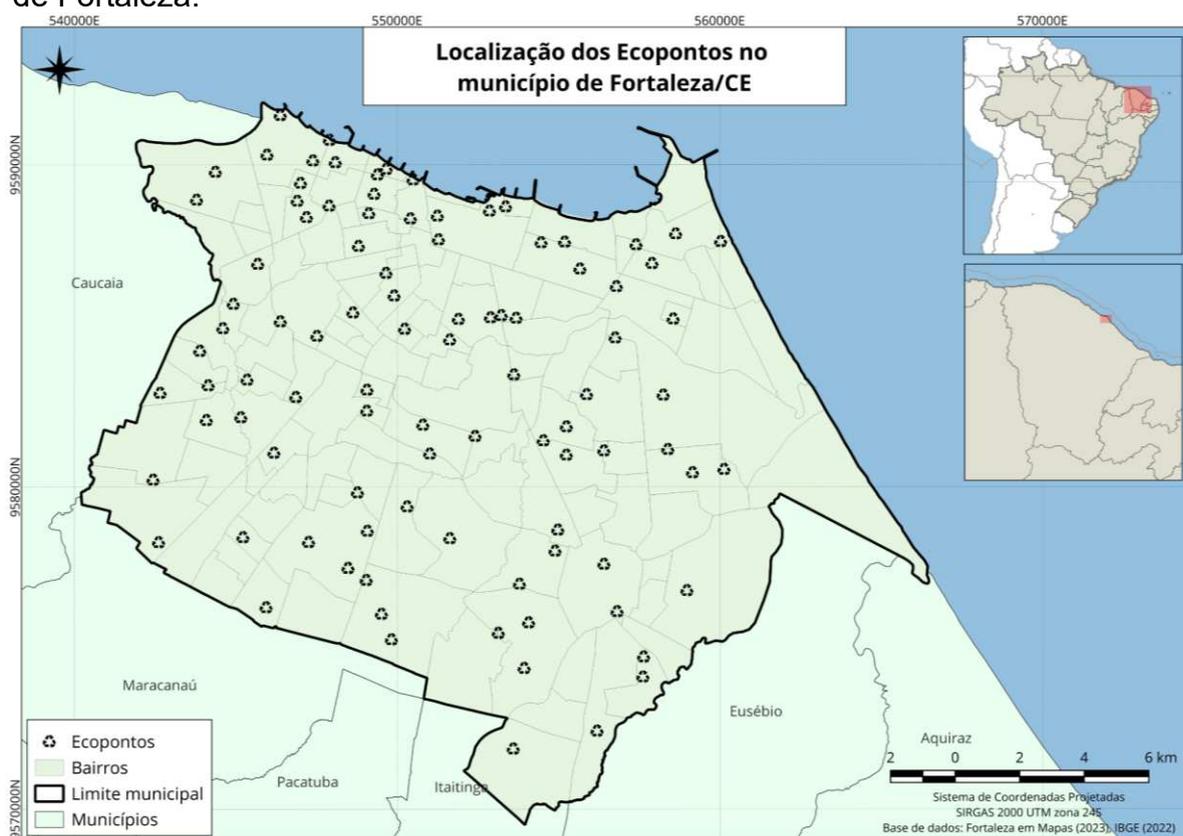
podem levar estes materiais e receber créditos para adquirir produtos nos estabelecimentos comerciais cadastrados de cada região. (Alexandre, 2021).

Entre 2016 e 2020, ambos os programas geraram um benefício total de mais de 5,6 milhões de reais e que foram distribuídos para mais de 30.000 usuários e 1.600 carroceiros cadastrados no sistema (Eco Nordeste, 2020).

Em 2023, foram coletadas aproximadamente 118.986 toneladas de resíduos nos 95 ecopontos disponíveis na cidade (Fortaleza, 2024b).

Por fim, o portal oficial de arquivos georreferenciados de Fortaleza se chama “Fortaleza em Mapas” e permite o download de mais de 500 camadas temáticas para o município (Fortaleza, 2024a). A Figura 13 apresenta um mapa com a distribuição espacial dos ecopontos no município de Fortaleza.

Figura 13 - Distribuição espacial dos ecopontos ao longo do território do município de Fortaleza.



Fonte: Elaborado pelo autor (2024).

4.4.3 Guarulhos

A cidade de Guarulhos representa o segundo maior núcleo urbano e econômico do estado de São Paulo, atrás apenas da capital. Com uma população de 1,291 milhões de habitantes segundo o último censo (IBGE, 2023), a cidade está geograficamente localizada nas coordenadas 23° 27' 46" de latitude Sul e 46° 31' 58" de longitude Oeste. Sua área total é de 318,675 km², sendo a 3219^a maior em extensão do Brasil (IBGE, 2024c).

O município apresenta um Produto Interno Bruto (PIB) de R\$ 71,156 bilhões. Em relação ao Índice de Desenvolvimento Humano (IDH), Guarulhos apresenta um índice de 0,763 (IBGE, 2024c).

No que tange à gestão de resíduos sólidos, a legislação municipal que trata da temática dos ecopontos é a lei nº 8.271, de 29 de abril de 2024, que dispõe sobre a implantação de Ecopontos no Município de Guarulhos (Guarulhos, 2024b).

A legislação determina quais tipos de resíduos podem ser descartados nos ecopontos do município, assim como permite parcerias público-privadas para operação dos mesmos. Em relação a localização destes equipamentos, sua redação é relativamente vaga e não define uma metodologia clara de definição de locais de instalação, conforme observado nos Art. 3º e 4º:

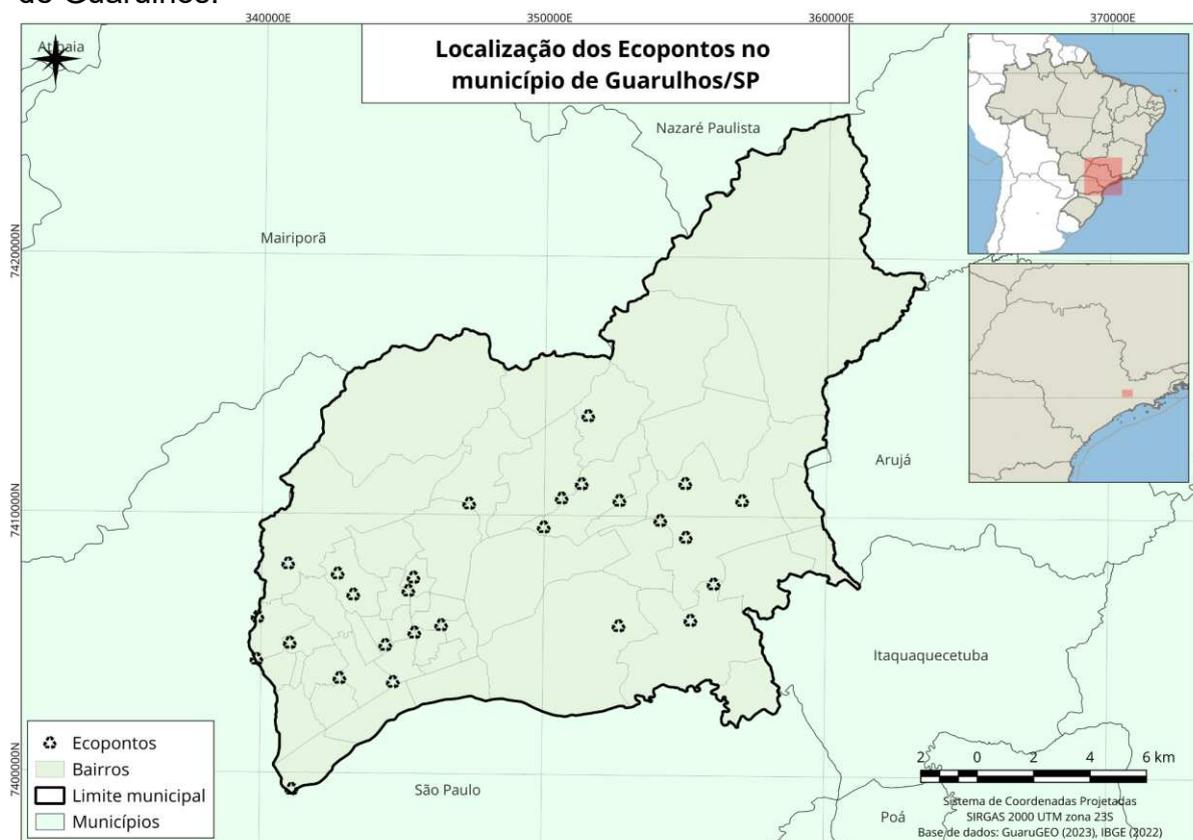
Art. 3º Os Ecopontos ocuparão áreas públicas ou terrenos com espaço adequado para a instalação de recipientes coletores dos materiais, viabilizados pela administração pública, observando a legislação de uso e ocupação do solo e de acordo com o adequado planejamento logístico e sustentabilidade técnica, ambiental e econômica.

Art. 4º Os Ecopontos deverão ser instalados, preferencialmente, nas áreas de limpeza urbana instituídas, e conter dizeres educativos a fim de alertar e despertar a conscientização do usuário sobre a importância e necessidade do correto fim dos produtos e os riscos que representam à saúde e ao meio ambiente quando não tratados com a devida destinação.
(Guarulhos, 2024b).

Em 2023, foram coletadas 64.486 toneladas de resíduos nos 33 ecopontos disponíveis na cidade (Guarulhos, 2024c).

Por fim, o portal oficial de arquivos georreferenciados de Guarulhos se chama GuarugEO. O portal permite o download de mais de 60 camadas temáticas para o município (Guarulhos, 2024a). A Figura 14 apresenta um mapa com a distribuição espacial dos ecopontos no município de Guarulhos.

Figura 14 - Distribuição espacial dos ecopontos ao longo do território do município de Guarulhos.



Fonte: Elaborado pelo autor (2024).

4.5 Determinação de variáveis e organização da base de dados

Após a seleção da área de estudo, se fez necessário levantar possíveis variáveis para realizar análises estatísticas e exploratórias para identificar padrões, tendências e correlações ao cruzá-las com dados de localização e peso coletado nos ecopontos de cada cidade. Esta abordagem visou assegurar que as correlações observadas possam ser interpretadas com confiança, estabelecendo uma base sólida para inferências e conclusões.

Como requisito para garantir a validade e a robustez das análises e do desenvolvimento do modelo, estas variáveis teriam que possuir a componente espacial e estarem disponíveis para os três municípios estudados.

Além destas variáveis, também foram necessárias outras camadas adicionais que serviram de apoio nas análises espaciais, tais como os limites dos municípios.

Desta forma, foi realizada uma extensa exploração dos dados georreferenciados disponíveis nos portais das cidades selecionadas: BHGEO (Belo Horizonte), Fortaleza em Mapas (Fortaleza) e GuarugEO (Guarulhos).

Após exploração para seleção destas variáveis que constam nas três cidades e das camadas de apoio, as seguintes camadas foram descarregadas e utilizadas no estudo:

- **Ecopontos atuais:**

Camada vetorial com geometria do tipo ponto com a localização de todos os ecopontos do município. Na tabela de atributos constam informações como o nome do ecoponto, seu endereço, tipo de material recebido e horário de funcionamento.

- **Limites do município:**

Camada vetorial com geometria do tipo polígono representando os limites do município.

- **Bairros:**

Camada vetorial com geometria do tipo polígono representando os limites de cada bairro do município. Na tabela de atributos, constam informações como o nome do bairro, área total e população estimada.

- **Setores censitários:**

Camada vetorial do tipo polígono que delimita os setores censitários, unidades territoriais para fins de controle cadastral definidos pelo IBGE.

- **Unidades de saúde:**

Camada vetorial com geometria do tipo ponto que localiza unidades de saúde como hospitais, clínicas e postos de saúde.

- **Estabelecimentos de educação:**

Camada vetorial com geometria do tipo ponto que localiza escolas, universidades, creches e outras instituições de ensino, em todos os níveis da educação.

- **Eixo viário:**

Camada vetorial com geometria do tipo linha que representa toda a malha viária do município. Na tabela de atributos, é possível observar informações como

nome da via, tipologia (rua, avenida, travessa etc.) e classificação (arterial, coletora, local etc.).

- **Corpos hídricos:**

Camadas vetoriais com geometria do tipo linha ou polígono que representam rios, lagoas, córregos e outras massas de água dentro do ambiente urbano.

Além das camadas mencionadas acima, foi realizado o download do modelo digital de elevação NASADEM (NASA JPL, 2021) para realização de análise da declividade da região em que os ecopontos estão instalados. Esta camada é do tipo matricial (raster), abrange toda a extensão dos municípios estudados e possui uma resolução espacial de 30 metros.

Durante o processo de exploração dos dados baixados, constatou-se a ausência de dados sobre o peso de resíduos coletados nos ecopontos. Tendo em vista que este dado é fundamental para avaliação da performance dos ecopontos, foi necessário solicitar essas informações aos municípios por meio de solicitações via protocolo aos órgãos responsáveis municipais, embasado pela Lei de Acesso à Informação, que regulamenta o direito constitucional de acesso às informações públicas (Brasil, 2011).

Após o recebimento dos dados, procedeu-se com o cálculo da média dos pesos coletados nos anos 2021, 2022 e 2023 para cada ecoponto, excluindo-se os anos para os quais não havia dados disponíveis (ecopontos que inauguraram durante o ano, fecharam temporariamente para reforma etc.). Os valores calculados foram associados às camadas dos ecopontos de cada município.

Além disso, foi identificada a ausência nos portais dos municípios de dados socioeconômicos e demográficos a nível de setor censitário. Variáveis como densidade demográfica, renda per capita e taxa de alfabetização são de grande interesse para este estudo quando analisadas ao nível de setores censitários, o que permite um maior nível de detalhamento no resultado final, tendo em vista que esta é uma unidade territorial menor que um bairro.

A importância destas variáveis citadas acima é descrita em diversos estudos realizados no mundo todo e que relacionam fatores econômicos e sociais com a geração de resíduos sólidos (Alzamora *et al.*, 2022; Velis *et al.*, 2023; Van Fan *et al.*, 2021).

Desta forma, é apresentado abaixo o detalhamento das camadas para estas variáveis supracitadas e como elas foram obtidas:

- **Densidade demográfica:**

Camada vetorial do tipo polígono, a nível de setor censitário, que mostra a densidade de habitantes por quilômetro quadrado. Este dado foi obtido ao dividir a população residente do setor censitário (obtido nas tabelas do Censo Demográfico do IBGE de 2022) pela área, em quilômetro quadrado, deste mesmo setor.

- **Taxa de alfabetização:**

Camada vetorial do tipo polígono que representa a porcentagem de pessoas alfabetizadas em cada setor censitário. Este dado foi obtido ao dividir o número de pessoas alfabetizadas com 5 ou mais anos de idade pela população total do setor. Ambas as informações foram obtidas nas tabelas do Censo de 2010.

- **Renda per capita:**

Camada vetorial do tipo polígono que mostra a renda média per capita por setor censitário do município em reais. Este dado foi obtido ao dividir a renda total do setor pela população total do setor. Ambas as informações foram obtidas nas tabelas do Censo de 2010.

Por fim, temos o Índice de Desenvolvimento Humano Municipal (IDHM). Este índice é uma adaptação do Índice de Desenvolvimento Humano (IDH) global para avaliar o desenvolvimento humano em níveis municipais no Brasil (PNUD, 2013).

O cálculo do IDHM segue a mesma estrutura tridimensional do IDH global, considerando as seguintes três dimensões:

- a) Longevidade: Medida pela expectativa de vida ao nascer.
- b) Educação: Composta por dois indicadores: taxa de frequência escolar para jovens e proporção de adultos com ensino fundamental completo.
- c) Renda: Avaliada pela renda per capita do município.

Essas dimensões são calculadas utilizando dados do Censo Demográfico do IBGE de 2010 e sintetizadas em um índice que varia de 0 a 1, onde valores mais próximos de 1 indicam um nível mais alto de desenvolvimento.

A camada com os dados de IDHM foi obtida junto ao portal Atlas Brasil, desenvolvido pelo Programa das Nações Unidas para o Desenvolvimento (PNUD), e estão divididos espacialmente em Unidades de Desenvolvimento Humano (UDH),

unidades de análise com características socioeconômicas relativamente homogêneas (PNUD, 2024).

Por fim, foi possível dividir todas as variáveis elencadas em quatro categorias: infraestrutura urbana, socioeconômico, cadastral e meio ambiente. A Tabela 4 abaixo traz um resumo destas variáveis.

Tabela 4 - Descrição dos dados georreferenciados de entrada para o estudo.

Variável	Geometria	Categoria
Ecopontos	Pontos	Infraestrutura urbana
Unidades de saúde	Pontos	Infraestrutura urbana
Estabelecimentos de educação	Pontos	Infraestrutura urbana
Eixo viário	Linhas	Infraestrutura urbana
Limites municipais	Polígonos	Cadastral
Bairros	Polígonos	Cadastral
Setores censitários	Polígonos	Cadastral
Corpos hídricos	Linhas e polígonos	Meio ambiente
Declividade	Raster	Meio ambiente
Densidade demográfica	Polígonos	Socioeconômico
IDHM	Polígonos	Socioeconômico
Renda per capita	Polígonos	Socioeconômico
Taxa de alfabetização	Polígonos	Socioeconômico

Fonte: Elaborado pelo autor (2024).

4.6 Operações de geoprocessamento

Para manipulação e análise de dados vetoriais e raster citados no tópico anterior, foi utilizado o software QGIS. As operações são descritas no manual do software (QGIS, 2024a) e podem ser resumidas da seguinte forma:

- **Reprojeção:**

Esse algoritmo foi projetado para transformar uma camada vetorial criando uma nova camada que retém os elementos originais, mas com geometrias ajustadas a um Sistema de Referência de Coordenadas (SRC) diferente. É importante destacar que os atributos da camada permanecem inalterados durante esse processo.

Esta operação foi executada em todas as camadas de forma a padronizar o SRC das camadas de cada cidade. Para Belo Horizonte e Guarulhos, as camadas foram reprojctadas para o sistema SIRGAS 2000 UTM zona 23S, enquanto para Fortaleza o sistema foi o SIRGAS 2000 UTM zona 24S. Ambos são sistemas projetados e os cálculos são realizados em unidades métricas.

- **Polígonos de Voronoi:**

Esta operação gera uma camada do tipo polígono a partir de uma camada de pontos de entrada, onde cada ponto tem uma área associada e qualquer par de coordenadas dentro desse polígono está mais próximo do ponto de entrada do que de qualquer outro.

Os limites destes polígonos de Voronoi são calculados considerando as distâncias entre os pontos de entrada. Esta camada com os polígonos de Voronoi é útil para análise de proximidade, área de cobertura e distribuição espacial.

- **Associar por localização:**

Esta operação recebe uma camada vetorial como entrada e gera uma nova camada vetorial que é uma versão estendida da original, incorporando atributos adicionais em sua tabela de atributos. Os atributos adicionais e seus valores são obtidos de uma segunda camada vetorial, através de análise de sobreposição.

A operação de “associar por localização” foi realizada para enriquecer a tabela de atributos das camadas utilizadas nas etapas subsequentes (ecopontos e setores censitários, por exemplo) com destaque para camadas de entrada que possuíssem sobreposição com estas camadas. Por exemplo, a camada de setores censitários recebe valores da camada de IDHM, onde cada setor recebe um valor de índice de acordo com sua localização em relação à camada de IDHM.

- **Unir atributos pelo mais próximo:**

Assim como o “associar por localização”, este algoritmo usa uma camada vetorial de entrada e cria uma nova camada que é uma versão estendida da entrada, com atributos adicionais em sua tabela de atributos.

Entretanto, diferentemente do algoritmo anterior, a associação de atributos da segunda camada não ocorre por sobreposição, mas sim por proximidade.

Esta operação foi realizada para enriquecer a camada de ecopontos com dados de camadas com geometria do tipo pontos e linhas, permitindo, por exemplo,

determinar qual a via mais próxima de um ecoponto, a distância em linha reta e a classificação desta via.

- **Unir atributos pelo valor do campo:**

Esta operação une camadas vetoriais adicionando atributos de uma camada à outra com base na seleção de um campo em comum na tabela de atributos.

É utilizada para associar dados específicos, como índices socioeconômicos de setores censitários a outras camadas geográficas, possibilitando as análises estatísticas subsequentes.

- **Estatísticas por categoria:**

Este algoritmo calcula estatísticas descritivas de campo da tabela de atributos a partir da seleção de uma categoria a ser analisada. Por exemplo, ao selecionar o campo de densidade demográfica, esta operação irá gerar uma planilha com estatísticas básicas (soma, média, máximo, mínimo etc.) deste campo.

Esta operação foi realizada para sumarizar informações estatísticas de diversas camadas de entrada, como, por exemplo, calcular a densidade populacional média nos setores censitários.

- **Contagem de pontos em polígono:**

Esta operação calcula o número de pontos que estão localizados dentro de cada polígono de uma camada vetorial de entrada.

Esta operação foi realizada para determinar a quantidade de ecopontos, unidades de saúde e estabelecimentos de saúde em cada bairro, voronoi ou setor censitário. Após esta quantificação, foi possível calcular indicadores relativos tais como a densidade de unidades de saúde em cada bairro através da divisão desta quantidade pela área do bairro em quilômetros quadrados.

- **Geração de isócronas:**

Esta função, não-nativa do QGIS e disponível no complemento *ORS Tools*, calcula áreas de alcance, considerando a malha viária local, em função do tempo ou distância a partir de uma camada de pontos. É possível selecionar em qual modal de transporte o cálculo será realizado: a pé, bicicleta, carro, ônibus etc.

Esta operação foi utilizada para avaliar a área de cobertura dos ecopontos em cada cidade, determinando quão acessível é esta instalação em termos de tempo de viagem até o local.

- **Soma de comprimentos de linha:**

Essa função usa uma camada de polígono e uma camada de linha e calcula o comprimento total das linhas e o número total delas que cruzam cada polígono.

A camada resultante possui os mesmos recursos que a camada de entrada do tipo polígono, mas com dois campos adicionais que contêm o comprimento e a contagem das linhas em cada polígono.

Esta função foi utilizada para calcular a densidade de vias em cada bairro ou polígono de Voronoi, onde a unidade deste indicador é quilômetro por quilômetro quadrado.

- **Matriz de distância:**

Essa ferramenta calcula a distância entre cada par de pontos em duas camadas vetoriais, ou dentro da mesma camada, e gera uma matriz de distâncias.

Esta operação foi executada para determinar as mínimas e máximas distâncias entre ecopontos vizinhos, permitindo analisar a rede e a cobertura deste tipo de instalação em cada cidade.

- **Calculadora de campo:**

Essa ferramenta permite a criação de novos campos ou a atualização de campos existentes em uma tabela de atributos de uma camada vetorial através de expressões matemáticas e funções pré-definidas.

Essa operação foi utilizada majoritariamente para criar novos campos que auxiliam na análise e visualização dos dados. Entre os diversos usos desta ferramenta neste estudo, pode-se destacar a normalização de dados e o cálculo de áreas, taxas e indicadores. Como exemplo, temos a taxa de alfabetização de cada setor censitário, que foi obtida dividindo o campo que possui os valores de população alfabetizada pelo campo que possui os valores de população total em cada setor.

- **Normalização de dados:**

Realizada com a ferramenta calculadora de campo, este processo ajusta os valores dos dados para uma escala comum, o que facilita a comparação entre diferentes conjuntos de dados.

A normalização de dados foi aplicada para padronizar as variáveis utilizadas nos modelos preditivos, garantindo que todas as variáveis tenham a mesma influência na análise, independentemente de suas unidades originais (toneladas por ano, habitantes por quilômetro quadrado etc.).

Foi utilizado o método mín.-máx. para reescalar os valores de variáveis para um intervalo específico entre 0 e 1. A fórmula para normalizar um valor x usando o método mín.-máx. é a seguinte:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

Onde:

x' é o valor normalizado;

x é o valor original;

x_{min} é o valor mínimo no conjunto de dados;

x_{max} é o valor máximo no conjunto de dados.

- **Declividade:**

Este algoritmo calcula o ângulo de inclinação do terreno a partir de uma camada raster de entrada. A inclinação pode ser expressa em graus ou em porcentagem.

- **Interpolação IDW:**

A Interpolação por Ponderação Inversa da Distância é uma técnica de interpolação que estima os valores de pontos não amostrados com base nos valores de pontos conhecidos. Os valores dos pontos mais próximos têm uma influência maior na estimativa, decrescendo à medida que aumenta a distância.

A fórmula para calcular o valor interpolado através do método IDW é apresentado no tópico 3.4.1.1 deste trabalho.

- **Reclassificação de raster:**

Essa operação recebe uma camada raster de entrada e cria uma nova camada raster com valores de categoria baseados em uma regra de reclassificação dos valores de cada célula. É uma operação útil para simplificar camadas raster, como reclassificar uma camada de declividade em categorias de declividade baixa (1), média (2) ou alta (3).

- **Proximidade (distância raster):**

Essa ferramenta calcula a distância de cada célula de uma camada raster até a célula mais próxima de uma ou mais feições de uma camada vetorial. O resultado é um raster de distância, onde o valor de cada célula representa a menor distância até a feição mais próxima do vetor de entrada.

Esta operação foi realizada para calcular a distância de todas as áreas de uma cidade até a camada de linhas com as vias principais. Desta forma, foi possível fazer uma análise de proximidade de vias arteriais.

- **Estatísticas Zonais:**

Este algoritmo calcula estatísticas de valores das células de um raster para cada polígono de uma camada vetorial de entrada.

Esta operação foi utilizada para calcular a média da declividade para cada bairro ou polígono de Voronoi.

Todas essas operações listadas foram utilizadas para enriquecer a tabela de atributos das camadas de ecopontos e a camada de polígonos de Voronoi de cada cidade estudada. A partir das camadas de entrada descarregadas nos portais de dados georreferenciados dos municípios e no portal de geociências do IBGE, foram criados ou acrescentados os seguintes campos nas tabelas de atributos:

a) Camada de Ecopontos:

- Número de identificação do ecoponto.
- Endereço.
- Peso coletado de resíduos, em toneladas.
- Distância em linha reta até a via principal mais próxima, em metros.
- Classificação da via mais próxima.
- Distância em linha reta até a unidade de saúde mais próxima, em metros.
- Distância em linha reta até o estabelecimento de educação mais próximo, em metros.
- Distância em linha reta até o corpo hídrico mais próximo, em metros.
- Densidade demográfica do Voronoi relacionado, em habitantes por quilômetros quadrados.
- IDHM médio do Voronoi relacionado.
- Taxa de alfabetização do Voronoi relacionado, em porcentagem.
- Renda per capita média do Voronoi relacionado, em reais.

b) Camada de Polígonos de Voronoi:

- Número de identificação do ecoponto relacionado.
- Área do polígono em quilômetros quadrados.
- Peso coletado de resíduos do ecoponto relacionado, em toneladas.

- Densidade demográfica, em habitantes por quilômetros quadrados.
- IDHM médio do polígono.
- Renda per capita média, em reais.
- Taxa de alfabetização, em porcentagem.
- Média da declividade, em porcentagem.
- Distância em linha reta partindo do ecoponto relacionado até a via principal mais próxima, em metros.
- Indicador de densidade de vias, em quilômetros por quilômetros quadrados.
- Indicador de densidade de unidades de saúde, em unidades por quilômetros quadrados.
- Indicador de densidade de estabelecimentos de educação, em unidades por quilômetros quadrados.

Essa compilação e concatenação de dados em apenas duas camadas, uma de pontos e uma de polígonos, permitiu a análise e a identificação de padrões e correlações para o desenvolvimento das etapas subsequentes do estudo.

Por fim, as variáveis foram classificadas em dependentes e independentes. A variável dependente é o peso coletado por ecoponto, ou seja, este é o resultado ou a saída que se deseja estudar e explicar, sendo influenciada pelas variáveis independentes. As variáveis independentes foram divididas em dois grupos: primárias e secundárias.

As variáveis independentes primárias são aquelas para as quais existe a hipótese de que estas influenciam, de alguma forma, o peso coletado por ecoponto. Elas são consideradas primárias porque há uma lógica ou evidência (item 3.2.2 desta pesquisa) que sugere ou confirma uma relação de causa e efeito com a variável dependente.

As variáveis densidade demográfica, IDHM, taxa de alfabetização, renda per capita e proximidade de vias, foram classificadas como variáveis independentes primárias.

As variáveis independentes secundárias são aquelas que estavam disponíveis para análise no formato de camadas geoespaciais e foram incluídas no estudo, mas não se espera, à primeira vista, que tenham uma correlação evidente

com o peso coletado por ecoponto. Elas foram incluídas para explorar possíveis associações adicionais.

A proximidade de corpos hídricos, densidade de unidades de saúde, densidade de estabelecimentos de educação, densidade de vias e declividade foram consideradas variáveis independentes secundárias.

4.7 Análise estatística descritiva

As análises estatísticas descritivas e de correlação foram efetuadas utilizando a linguagem de programação R, por meio do ambiente de desenvolvimento integrado RStudio.

A análise estatística foi aplicada aos pesos coletados nos ecopontos, resultando na obtenção de estatísticas descritivas como valores máximo, mínimo, média, amplitude e desvio padrão.

Além disso, foram realizadas análises estatísticas individuais das variáveis independentes. A geração de histogramas e gráficos de caixa facilitou a visualização da distribuição de frequências das variáveis independentes e a exploração de potenciais correlações entre essas variáveis independentes e a variável dependente, que é o peso coletado nos ecopontos.

Para uma análise mais aprofundada, foi realizada uma verificação de correlação utilizando o método Pearson. Este método foi escolhido principalmente devido à natureza dos dados. As variáveis analisadas são contínuas e se espera identificar uma relação linear entre elas, o que é bem capturado pelo coeficiente de Pearson. Além disso, o método Pearson é amplamente conhecido e sua interpretação é direta quando se trata de relações lineares, facilitando a comunicação dos resultados.

Para compreender essas inter-relações entre as variáveis selecionadas, calculamos a matriz de correlação de Pearson para cada cidade. O coeficiente de correlação de Pearson, denotado por r , varia entre -1 e 1.

Um coeficiente r igual a 1 indica uma correlação positiva perfeita, significando que, à medida que uma variável aumenta, a outra também aumenta proporcionalmente. De forma análoga, um r igual a -1 indica uma correlação negativa perfeita, onde, à medida que uma variável aumenta, a outra diminui

proporcionalmente. Quando se observa um r igual a 0, isso indica que não há nenhuma correlação linear, ou seja, não há relação linear entre as variáveis.

O cálculo deste coeficiente foi realizado utilizando a fórmula:

$$r = \frac{\Sigma(x_i - x_m)(y_i - y_m)}{\sqrt{\Sigma(x_i - x_m)^2 \Sigma(y_i - y_m)^2}} \quad (3)$$

Onde:

x_i e y_i são os valores individuais das variáveis x e y ,

x_m e y_m são as médias das variáveis x e y , respectivamente.

Para facilitar a interpretação dos resultados de correlação, foram utilizados mapas de calor (*heatmaps*) para representar visualmente as matrizes de correlação. Os mapas de calor são utilizados para identificar padrões e a intensidade das relações entre as variáveis.

As correlações são codificadas por cores, com tons mais escuros representando correlações mais fortes (positivas ou negativas) e tons mais claros indicando correlações mais fracas.

Tendo em vista que as relações entre as variáveis podem variar significativamente de uma cidade para outra devido a diferenças estruturais, culturais, ambientais e/ou socioeconômicas, foi gerada uma matriz de correlação para cada cidade, permitindo observar localmente como as variáveis independentes interagem entre si e com a variável dependente.

4.8 Análise exploratória de dados espaciais

A Análise Exploratória de Dados Espaciais (AEDE) foi realizada para investigar e visualizar padrões espaciais nos dados da variável dependente, que é o peso total coletado de resíduos por ecopontos. Esta análise possibilitou uma compreensão mais aprofundada da estrutura espacial dos dados antes da aplicação de modelos mais complexos.

A primeira técnica utilizada na AEDE foi o Índice de Moran, que mediu a autocorrelação global espacial dos dados. Este índice varia de -1 a 1, onde valores positivos indicam autocorrelação espacial positiva, ou seja, que valores similares estão próximos uns dos outros, enquanto valores negativos indicam autocorrelação

espacial negativa. Valores próximos de zero sugeriram uma distribuição aleatória ou ausência de autocorrelação espacial.

Além do Índice de Moran, a análise incluiu os Indicadores Locais de Associação Espacial (LISA), que identificaram *clusters* locais de autocorrelação espacial. Foram gerados mapas para cada cidade com as classes calculadas. As classes LISA são interpretadas da seguinte forma:

- a) "Alto-Alto" indica áreas com alta concentração de resíduos cercadas por áreas similares;
- b) "Baixo-Baixo" indica áreas com baixa concentração de resíduos cercadas por áreas similares;
- c) "Alto-Baixo" indica áreas com alta concentração de resíduos cercadas por áreas de baixa concentração;
- d) "Baixo-Alto" indica o contrário; e
- e) "Não significativa" representa áreas onde não há correlação espacial significativa.

Outra ferramenta na AEDE foi a utilização de mapas coropléticos, que facilitaram a visualização da distribuição espacial de uma variável através de cores. Esses mapas ajudaram a identificar padrões espaciais, mostrando como diferentes variáveis se comportam ao longo de uma região.

A Análise de Padrão de Pontos (*Point Pattern Analysis*) foi usada para avaliar a distribuição espacial dos ecopontos, verificando se os pontos estavam distribuídos de forma aleatória, regular ou agrupada. O p-valor foi calculado para testar a significância dos padrões observados em cada cidade. Um p-valor baixo, geralmente menor que 0,05 indica que a distribuição observada dos pontos é improvável de ocorrer ao acaso, sugerindo a presença de um padrão espacial significativo.

A combinação destas técnicas forneceu a base necessária para a interpretação e análise dos dados espaciais, permitindo avaliar a existência de padrões e correlações entre variáveis.

4.9 Desenvolvimento de modelos preditivos

4.9.1 Modelo determinístico

O modelo descrito para definir a nota de adequabilidade de uma área para instalação de um ecoponto utiliza uma metodologia que se enquadra como um modelo determinístico com fundamentos de álgebra linear. O modelo é determinístico porque, dados os mesmos dados de entrada, ele sempre produzirá os mesmos resultados, ou seja, não envolve aleatoriedade ou variabilidade estocástica.

O cálculo da nota N de uma área é realizado através de uma combinação linear ponderada de variáveis selecionadas na etapa de estatística descritiva das variáveis independentes primárias.

Cada variável contribui com um peso específico inversamente proporcional à distância de uma área a um cenário de referência. Para um número n de variáveis, é necessário definir $n+1$ cenários de referência, sempre incluindo o melhor e o pior cenário possível.

Considerando um modelo com três variáveis de entrada, os cenários de referência foram definidos da seguinte forma:

- a) Melhor cenário (áreas mais adequadas) com nota 10;
- b) Cenário bom com nota 7;
- c) Cenário ruim com nota 3;
- d) Cenário péssimo (áreas menos adequadas) com nota 0;

Em cada um desses cenários, são definidos também quais seriam os valores observados de cada variável para caracterizar tal cenário. Ou seja, qual valor (ou intervalo de valores) para a variável analisada poderia ser considerado como o melhor para a instalação de um ecoponto.

As variáveis de entrada, selecionadas a partir da estatística descritiva e AEDE, foram classificadas em cinco categorias, de 1 a 5, onde cada categoria possui o mesmo número de observações. Ou seja, as 20% menores observações do conjunto de dados da variável foram classificadas como 1 e as 20% maiores observações foram classificadas como 5.

A classificação foi realizada para assegurar que, com pesos iguais, as variáveis contribuem igualmente para o cálculo da nota final, sem ocorrerem influências de escala de valores de cada variável.

Dada uma área i , com as n entradas, são calculadas as distâncias da área i a cada cenário de referência definido. Esta distância é definida como a raiz da soma dos quadrados das diferenças entre os valores observados das variáveis de entrada

na área i e os valores definidos para as respectivas variáveis em cada cenário. Por fim, a nota do ponto é a média ponderada do inverso das distâncias pelas notas dos cenários.

A fórmula para calcular a nota de uma área é:

$$N_i = \frac{\sum_{j=1}^C w_j Z_j}{\sum_{j=1}^C w_j} \quad (4)$$

Onde:

N_i é a nota da área i ;

C é o número de cenários que definem as notas N_i ;

W_j é o peso do cenário j , caracterizado como inverso da distância d da área i elevada à potência p para o cenário j dado por $W_j = 1/d_{C_j}^p$;

Z_j é a nota atribuída ao cenário j ;

$d_{C_j}^p$ é a distância da área i ao cenário j elevada à potência p , calculada

como:

$$d_{C_j}^p = \sqrt{a(V1_i - V1_{C_j})^2 + b((V2_i - V2_{C_j})^2 + c(V3_i - V3_{C_j})^2)} \quad (5)$$

Onde $V1$, $V2$ e $V3$ são as variáveis de entrada considerando um modelo com três variáveis, os coeficientes a , b e c são pesos que podem ser atribuídos para cada variável no cálculo de distância e os índices p , i , C e j são os mesmos que foram referenciados acima. Para a versão inicial do modelo, adotou-se $a=b=c=0,333$.

Toda esta etapa foi realizada com o uso da linguagem R e o software RStudio. Os dados utilizados foram carregados e limpos para garantir a integridade e qualidade da análise. Foram eliminadas observações com valores de peso igual a zero e registros com dados ausentes.

Os resultados do modelo foram apresentados na forma de mapas, mostrando a distribuição espacial das notas de adequabilidade de áreas para instalação de ecopontos. Além dos mapas, foram gerados gráficos de dispersão das notas estimadas em relação aos pesos coletados por ano nos ecopontos existentes, permitindo analisar como a potência escolhida no modelo impacta na distribuição das notas.

4.9.2 Modelo baseado em regressão linear

Após o desenvolvimento do modelo determinístico, prosseguiu-se para o desenvolvimento de um modelo estatístico baseado em inferência através de regressão linear. A regressão linear é uma técnica estatística utilizada para modelar a relação entre uma variável dependente e uma ou mais variáveis independentes.

A regressão funciona ajustando uma linha reta, no caso de regressão linear simples, ou um hiperplano, no caso de regressão linear múltipla, aos dados, de forma a minimizar a soma dos quadrados das diferenças, denominados resíduos, entre os valores observados e os valores estimados pelo modelo.

Em sua essência, a regressão linear busca identificar a equação que melhor descreve como a variável dependente é influenciada pelas variáveis independentes, a fim de realizar previsões e inferências sobre essa relação.

Nesta etapa, a variável dependente foi definida como peso coletado por área do Voronoi associado ao ecoponto. A parametrização a partir da área foi realizada com foco no resultado final do modelo, onde a equação final será utilizada para calcular o valor estimado em cada célula do raster final com os resultados. Considerando que cada célula possui uma área associada, o peso final estimado será obtido ao multiplicar este fator de peso por área e a área de cada célula.

As variáveis independentes estudadas foram todas as primárias e secundárias, descritas anteriormente:

- a) Densidade demográfica, em habitantes por quilômetros quadrados.
- b) Índice de desenvolvimento humano municipal.
- c) Renda per capita média, em reais.
- d) Taxa de alfabetização, em porcentagem.
- e) Média da declividade, em porcentagem.
- f) Indicador de densidade de vias, em quilômetros por quilômetros quadrados.
- g) Indicador de densidade de unidades de saúde, em unidades por quilômetros quadrados.
- h) Indicador de densidade de estabelecimentos de educação, em unidades por quilômetros quadrados.

Considerando a quantidade de variáveis independentes, esta regressão foi do tipo linear múltipla, em que a fórmula básica é:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p \quad (6)$$

Onde:

y é a variável dependente;

x_1, x_2, \dots, x_p são as variáveis independentes;

β_0 é o intercepto;

$\beta_1, \beta_2, \dots, \beta_p$ são os coeficientes que representam a mudança em y

para uma unidade de mudança em cada variável.

O objetivo da regressão é encontrar os coeficientes que minimizem a soma dos quadrados dos erros (SSE), que é uma medida que calcula os resíduos, ou seja, as diferenças entre os valores observados e os valores preditos pelo modelo. A fórmula do SSE é:

$$SSE = \sum_{i=1}^n (y_i - y_i^p) \quad (7)$$

Onde:

SSE é a soma dos quadrados dos erros;

y_i são os valores reais;

y_i^p são os valores estimados pelo modelo;

n é o número de observações.

Toda esta etapa foi realizada com o uso da linguagem R e o software RStudio. Os dados utilizados foram carregados e limpos para garantir a integridade e qualidade da análise. Foram eliminadas observações com valores de peso igual a zero e registros com dados ausentes.

Para trabalhar com regressão linear, um dos requisitos é que os dados sigam uma distribuição normal. Foram aplicadas transformações para verificar qual função melhor normaliza os dados:

- a) Transformação logarítmica: $y' = \log(y)$
- b) Transformação raiz quadrada: $y' = \sqrt{y}$
- c) Transformação recíproca: $y' = \frac{1}{y}$
- d) Transformação recíproca da raiz quadrada: $y' = \frac{1}{\sqrt{y}}$
- e) Transformação quadrática: $y' = y^2$

f) Transformação Yeo-Johnson: $y' = \frac{(y+1)^\lambda - 1}{\lambda}$ se $\lambda \neq 0$ ou $y' = \log(y+1)$ se $\lambda = 0$.

Para assegurar a validade do modelo de regressão linear múltipla, verificamos os principais pressupostos estatísticos que garantem a confiabilidade e a precisão das inferências feitas a partir do modelo. Esta verificação ocorreu através de análise de gráficos de diagnósticos e de testes.

O gráfico de resíduos por valores ajustados teve o propósito de avaliar a linearidade e a homoscedasticidade. Espera-se que os resíduos estejam espalhados aleatoriamente como uma nuvem de pontos em torno da linha horizontal (em zero).

O gráfico Q-Q (*Quantile-Quantile*) normal foi utilizado para avaliar a normalidade dos resíduos. Se os resíduos forem normalmente distribuídos, os pontos deverão seguir aproximadamente a linha diagonal.

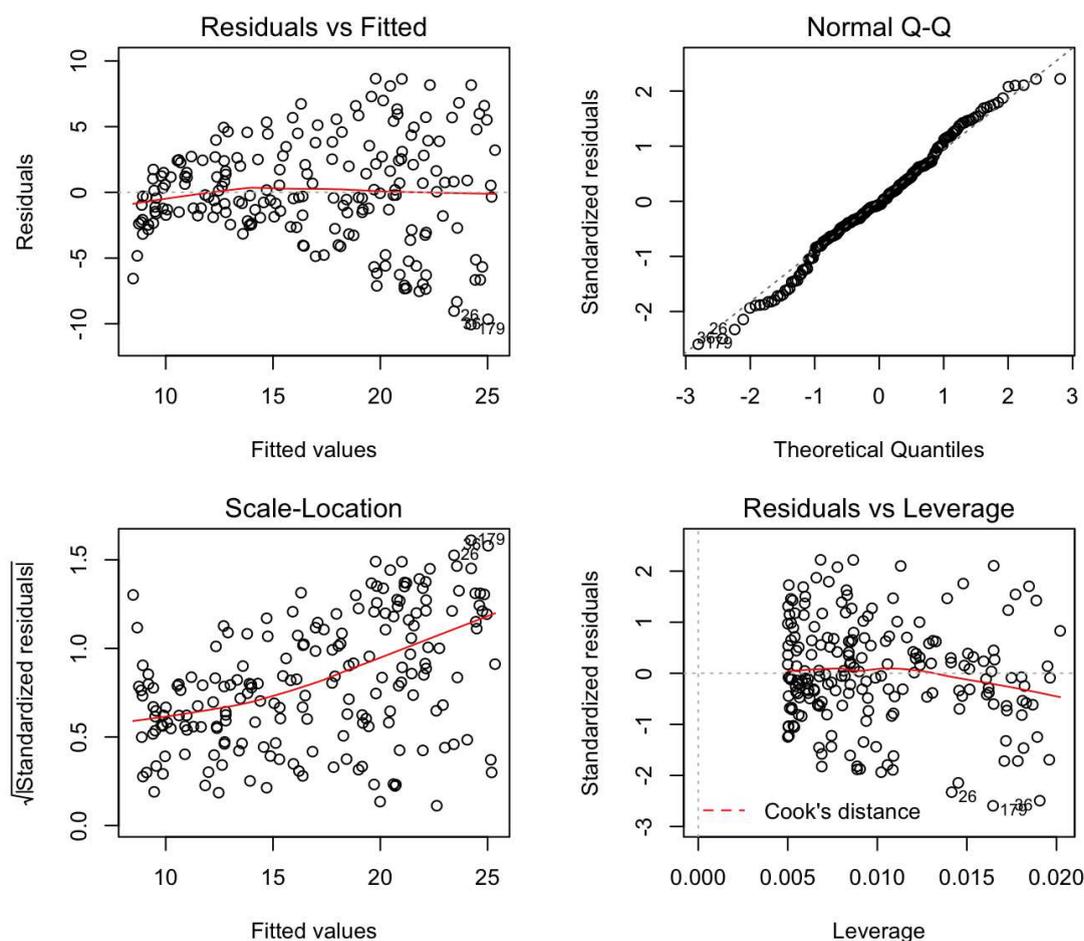
O gráfico de escala-local teve o propósito de avaliar a homoscedasticidade. Neste gráfico, espera-se que os pontos estejam espalhados aleatoriamente em torno de uma linha horizontal. Padrões cônicos ou em funil podem indicar heterocedasticidade.

O gráfico de resíduos por alavancagem teve o propósito de identificar pontos influentes. Pontos fora das bandas de *Cook's Distance* (linhas tracejadas) são influentes e podem ter um impacto desproporcional no ajuste do modelo. A Figura 15 apresenta um exemplo destes quatro gráficos descritos.

O pressuposto da normalidade dos resíduos verifica se os resíduos do modelo seguem uma distribuição normal. Foi utilizado o teste de Shapiro-Wilk, no qual um p-valor maior que 0,05 sugere que os resíduos seguem uma distribuição normal. Esta análise foi complementada pela inspeção visual de gráficos Q-Q.

A homoscedasticidade refere-se à constância da variância dos resíduos ao longo do domínio dos valores previstos. O teste de Breusch-Pagan foi utilizado para avaliar este pressuposto. Neste teste, um p-valor maior que 0,05 indica homoscedasticidade.

Figura 15 - Exemplo de gráficos de diagnóstico de ajuste de modelo linear.



Fonte: Kassambara (2018).

A ausência de multicolinearidade verifica se as variáveis independentes não estão altamente correlacionadas entre si, pois a presença de multicolinearidade pode inflacionar os erros padrão dos coeficientes e dificultar a determinação do efeito individual de cada variável. o Fator de Inflação da Variância (VIF) foi calculado para cada variável independente, e valores de VIF abaixo de 10 foram mantidos.

A independência dos resíduos é outro pressuposto para a validade das inferências do modelo. Ela verifica se os resíduos de uma observação não estão correlacionados com os resíduos de outra observação. Foi utilizado o teste de Durbin-Watson, no qual valores próximos de 2 indicam ausência de autocorrelação.

Por fim, os resíduos padronizados foram analisados para identificar outliers, considerando valores fora do intervalo de -3 a 3 como outliers significativos.

Após todos os testes de pressupostos, foi realizada uma seleção automática de variáveis através do método de *stepwise* com o objetivo de manter apenas as variáveis mais relevantes.

A equação final do modelo, com os respectivos coeficientes, foi então empregada para gerar um raster que estima o peso coletado por área ao longo de toda a extensão territorial das cidades.

Por fim, foi realizada a validação do modelo com um conjunto de dados de teste, avaliando a performance e a aplicabilidade do modelo. Os valores previstos de peso de RSU foram comparados com os valores reais observados e foram representados na forma de gráficos de dispersão e Q-Q.

5 RESULTADOS E DISCUSSÃO

5.1 Panorama dos Ecopontos no Brasil

Após o levantamento relacionado à temática dos ecopontos nas 29 cidades que atendem aos requisitos definidos neste estudo (população acima de um milhão de habitantes segundo o censo de 2022 e/ou ser uma capital estadual ou federal), os resultados foram compilados na Tabela 5, que está ordenada pelo número de ecopontos instalados no município.

Além da quantidade, a tabela também compila dados sobre o início da operação dos ecopontos, a denominação utilizada para esses pontos de coleta em cada município e suas respectivas referências.

Tabela 5 - Lista de municípios brasileiros que possuem ecopontos, ordenados por quantidade.

Cidade	Qtde.	Início da Operação	Denominação	Referência
São Paulo	124	2003	Ecoponto	São Paulo, 2023a.
Fortaleza	95	2015	Ecoponto	Fortaleza, 2023b.
Rio de Janeiro	82	N/D	Ecoponto	Rio de Janeiro, 2023.
Belo Horizonte	34	1995	Unidades de Recebimento de Pequenos Volumes (URPVs)	Belo Horizonte, 2023.
Guarulhos	33	N/D	Ecoponto	Guarulhos, 2023.
São Luís	25	N/D	Ecoponto	São Luís, 2023.
Brasília	21	N/D	Papa-Entulho	Distrito Federal, 2023.
Campinas	16	2010	Ecoponto	Campinas, 2023.
Curitiba	13	2019	Ecoponto	Curitiba, 2023.
Recife	10	2013	Ecoestações	Recife, 2023.
Florianópolis	9	N/D	Ecoponto	Florianópolis, 2023.
Porto Alegre	7	2010	Destino Certo	Porto Alegre, 2023.
Aracaju	6	2018	Ecoponto	Aracaju, 2023.
Goiânia	5	2018	Ecoponto	Goiânia, 2023.
Campo Grande	5	2018	Ecoponto	Campo Grande, 2023.
Maceió	5	2014	Ecoponto	Maceió, 2023.
Salvador	4	2014	Ecoponto	Salvador, 2023.
Boa Vista¹	3	2024	Ecoponto	Boa Vista, 2023.

Cidade	Qtde.	Início da Operação	Denominação	Referência
Natal	3	N/D	Ecoponto	Natal, 2023.
Rio Branco	1	2017	Ecoponto	Rio Branco, 2023.
Vitória	1	2013	Estação Bota-Fora	Vitória, 2023.
Teresina	N/D	N/D	N/D	N/D
Cuiabá	N/D	N/D	N/D	N/D
João Pessoa	N/D	N/D	N/D	N/D
Porto Velho	N/D	N/D	N/D	N/D
Manaus	N/D	N/D	N/D	N/D
Palmas²	N/D	N/D	N/D	N/D
Macapá²	N/D	N/D	N/D	N/D
Belém²	N/D	N/D	N/D	N/D

Fonte: Elaborado pelo autor (2024).

Observações:

¹ Número previsto.

² Não recebe entulhos e resíduos volumosos.

N/D Informação não disponível.

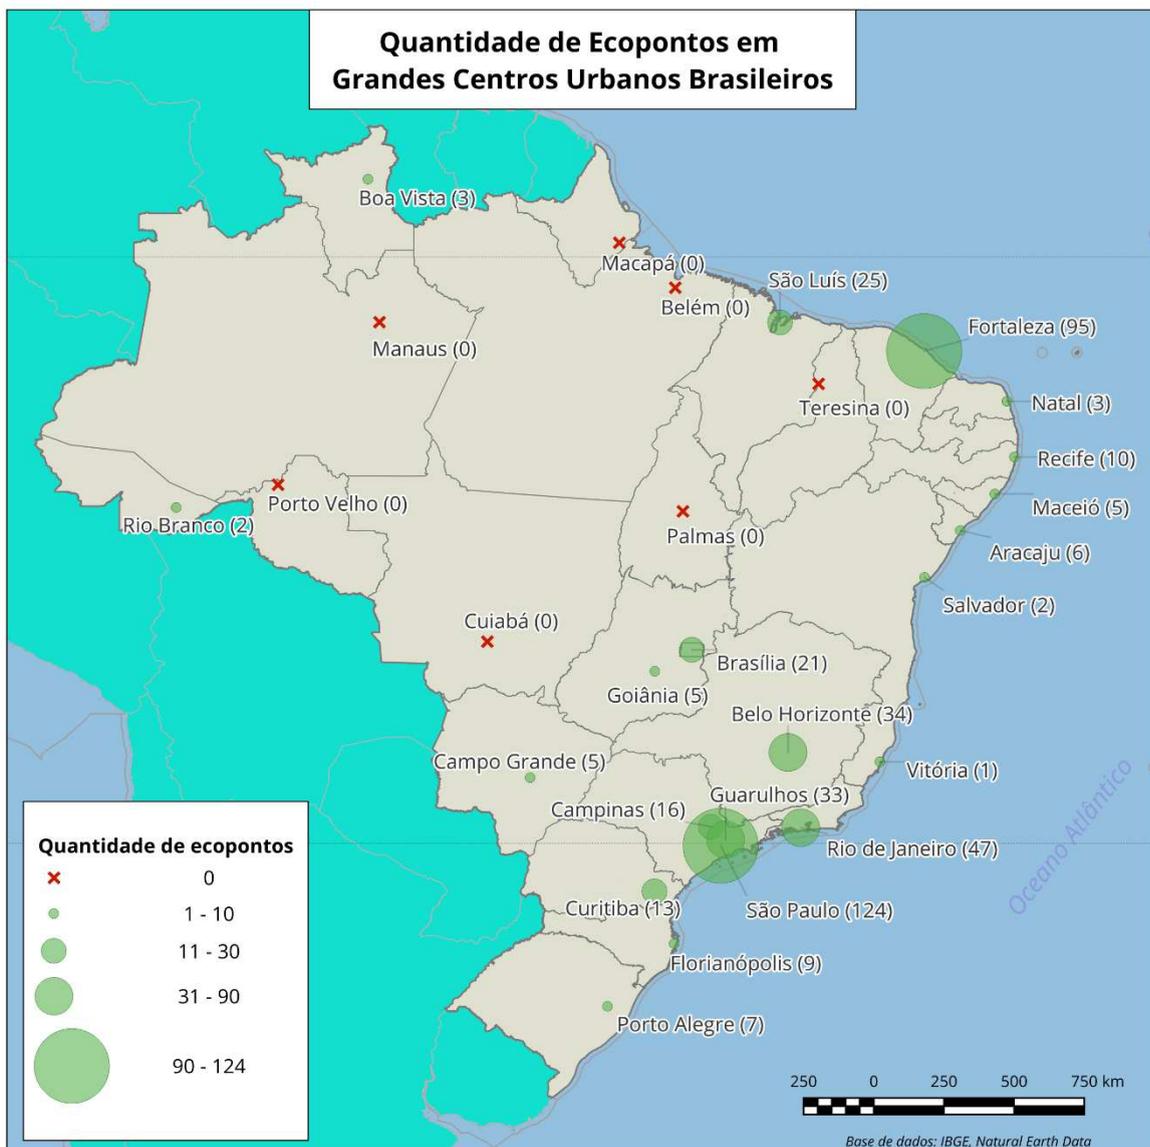
Ao analisar a tabela, pode-se observar que embora exista uma clara predominância para a denominação “Ecopontos”, diversos municípios utilizam denominações distintas como "Unidades de Recebimento de Pequenos Volumes (URPVs)" (Belo Horizonte) e "Papa-Entulho" (Brasília). Neste estudo, todas estas instalações serão doravante denominadas de ecopontos.

Também se observa que a maioria dos municípios iniciou a operação de seus ecopontos após 2010, o que pode sugerir uma relação direta com a implementação da Política Nacional de Resíduos Sólidos no país, definida pela Lei nº 12.305, de 2 de agosto de 2010 (Brasil, 2010).

Importante destacar que alguns municípios possuem equipamentos chamados também de ecopontos, mas que não recebem resíduos da construção civil, podas de árvores e outros resíduos volumosos (Macapá, 2023; Pará, 2023; Palmas, 2023). Embora com a mesma nomenclatura, são equipamentos que mais se assemelham com PEVs, focados em coleta seletiva e/ou logística reversa. Estes não foram contabilizados neste estudo, tendo em vista que são equipamentos mais compactos e de instalação menos complexa do que os ecopontos tradicionais.

Os resultados da tabela anterior foram representados espacialmente no mapa apresentado na Figura 16 onde a quantidade de ecopontos é representada na forma de círculos com raios proporcionais à sua quantidade.

Figura 16 - Mapa representativo da quantidade de ecopontos em grandes centros urbanos brasileiros.



Fonte: Elaborado pelo autor (2024).

5.2 Análise de ecopontos nas cidades selecionadas

Conforme justificado anteriormente na descrição da metodologia do presente estudo, as cidades de Belo Horizonte, Fortaleza e Guarulhos foram selecionadas pelas elevadas quantidades de ecopontos e, principalmente, pela disponibilidade de dados de peso coletado por ecoponto.

Desta forma, foi realizada uma análise estatística descritiva dos pesos coletados por ecopontos de cada cidade. Os resultados foram compilados na Tabela 6 abaixo, que apresenta valores em toneladas por ano.

Tabela 6 - Estatística descritiva da variável peso coletado de resíduos em cada ecoponto nas cidades de Belo Horizonte, Fortaleza e Guarulhos, em toneladas por ano, para o período de 2021 a 2023.

Medidas	Belo Horizonte	Fortaleza	Guarulhos
Média	3769	992	2303
Mediana	3480	708	1854
Amplitude	10002	6395	6147
Mínimo	476	9	270
Máximo	10478	6404	6417
Desvio padrão	1903	998	1673
Coeficiente de variação	50,5 %	100,7 %	72,7 %
P90	5687	2008	4542
P10	1797	168	555

Fonte: Elaborado pelo autor (2024).

A análise da Tabela 6 revela diferenças nos pesos coletados por ecopontos nas três cidades, permitindo a identificação de alguns padrões iniciais. A média e a mediana dos pesos coletados em Belo Horizonte é a mais alta, seguida por Guarulhos e Fortaleza respectivamente, sugerindo uma maior eficácia ou uso mais intensivo dos ecopontos em Belo Horizonte. Entretanto, essa hipótese ainda não pode ser confirmada sem analisar outros fatores que possuem influência, tais como número de ecopontos, população atendida por ecoponto, densidade demográfica etc.

O coeficiente de variação, que expressa a variação relativa em torno da média, é mais elevado em Fortaleza (100,67%), indicando uma grande dispersão dos

dados, enquanto Belo Horizonte (50,48%) e Guarulhos (72,66%) apresentam variações moderadas.

Embora com populações similares, a média de peso coletado em Fortaleza representa cerca de 26,3% da média observada em Belo Horizonte. Este dado, aliado à análise do coeficiente de variação e dos percentis 10 e 90, que apresentaram valores baixos em comparação às outras cidades, e pode indicar que os ecopontos estão subaproveitados ou até que ocorre uma saturação de ecopontos em Fortaleza. Ou seja, Fortaleza, que já possui 95 unidades, pode não observar um aumento significativo de resíduos coletados ao instalar novos ecopontos em seu território.

Após esta análise inicial, procedeu-se para o cálculo de alguns indicadores relativos que levassem em consideração a área e a população dos municípios. Os resultados são apresentados na Tabela 7.

Tabela 7 - Análises de distância entre ecopontos e parâmetros relativos dos pesos de resíduos coletados por ecoponto nas cidades selecionadas.

Indicador	Belo Horizonte	Fortaleza	Guarulhos
Densidade de Ecopontos (un./km ²)	0,1026 un./km ²	0,3048 un./km ²	0,1035 un./km ²
População atendida (hab./un)	68.088 hab./un.	25.558 hab./un.	39.121 hab./un.
Peso coletado per capita	55,36 kg/hab.ano	38,80 kg/hab.ano	49,95 kg/hab.ano
Menor distância entre vizinhos	547 m	321 m	537 m
Maior distância entre vizinhos	4.168 m	2.585 m	3.955 m

Fonte: Elaborado pelo autor (2024).

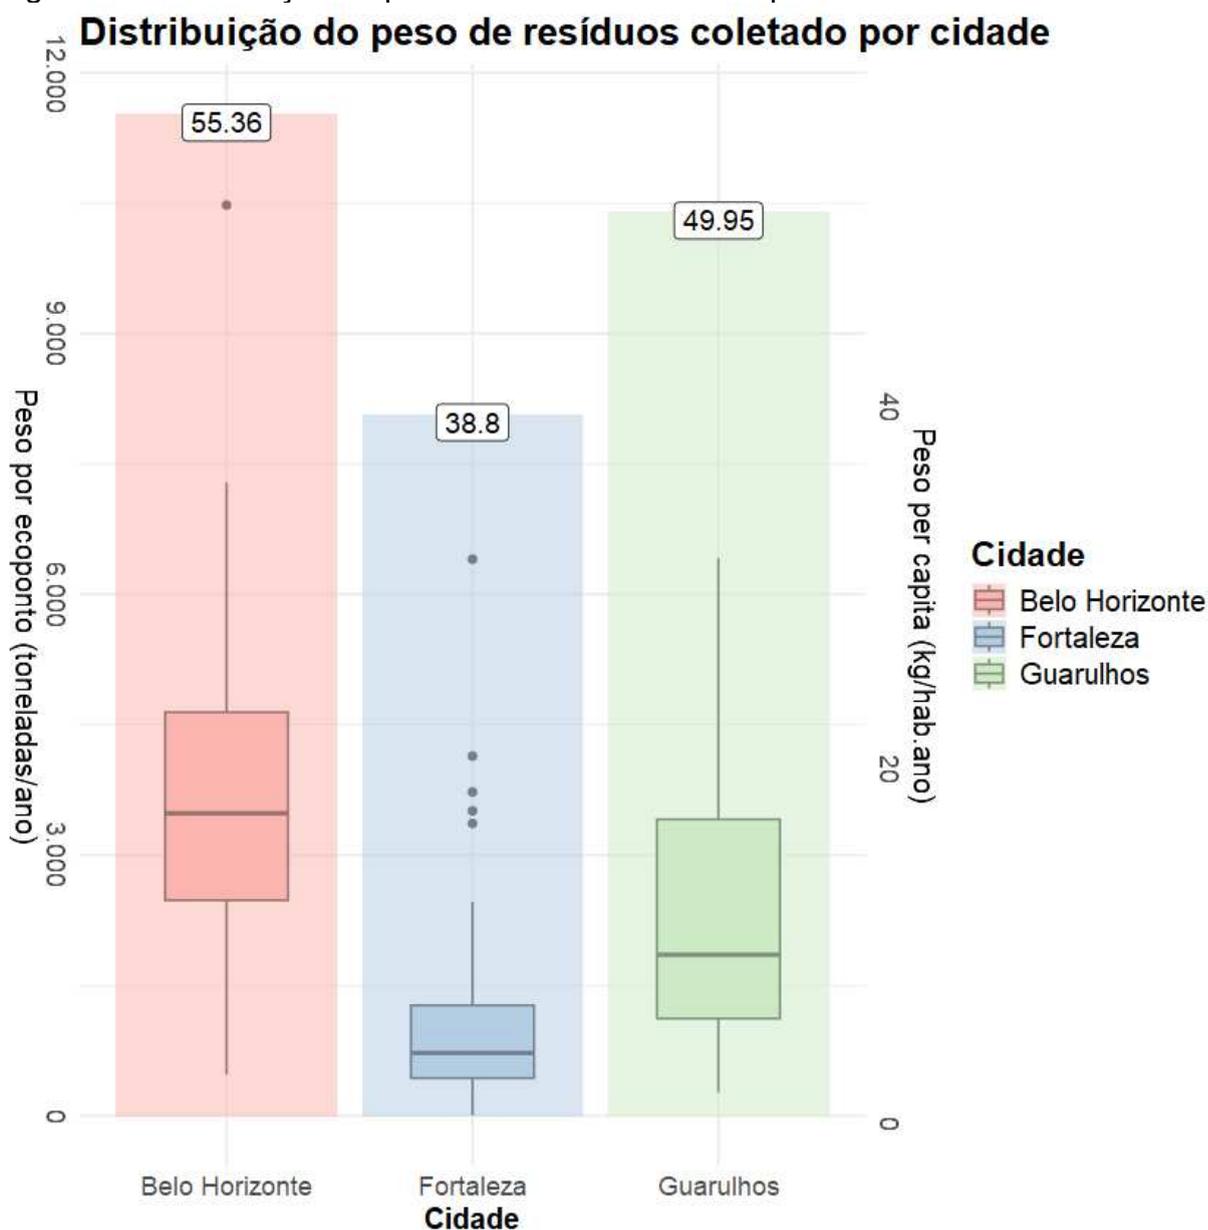
Observa-se que Fortaleza possui três vezes mais ecopontos por quilômetro quadrado do que Belo Horizonte e Guarulhos, o que indica uma melhor cobertura espacial.

Belo Horizonte se destaca com o maior valor de peso coletado per capita, seguido por Guarulhos e Fortaleza. Este indicador ratifica a análise estatística anterior que indica uma maior eficiência na coleta de resíduos em Belo Horizonte, sugerindo que os ecopontos estão sendo bem utilizados pela população.

Já com relação às análises de distâncias mínimas e máximas entre ecopontos vizinhos, Fortaleza possui os menores valores observados entre ecopontos

vizinhos, o que é esperado devido à elevada quantidade de ecopontos nesta cidade e ao fato de as áreas das três cidades serem similares. Por fim, foi possível gerar o diagrama de caixas (*boxplot*) na Figura 17, que ilustra a distribuição do peso de resíduos coletado por ecoponto em cada cidade.

Figura 17 - Distribuição do peso de resíduos coletado por cidade.



Fonte: Elaborado pelo autor (2024).

No eixo vertical esquerdo, temos a variável peso coletado por ecoponto em toneladas, enquanto no eixo vertical direito, temos o peso per capita em quilogramas por habitante por ano.

Belo Horizonte destaca-se pela maior eficiência na coleta de resíduos em termos de peso por ecoponto e peso per capita. Fortaleza apresenta muitos outliers, o que pode indicar uma distribuição desigual de coleta de resíduos. Guarulhos mostra uma eficiência intermediária, com menor variação e ausência de outliers extremos.

5.3 Área de cobertura dos ecopontos

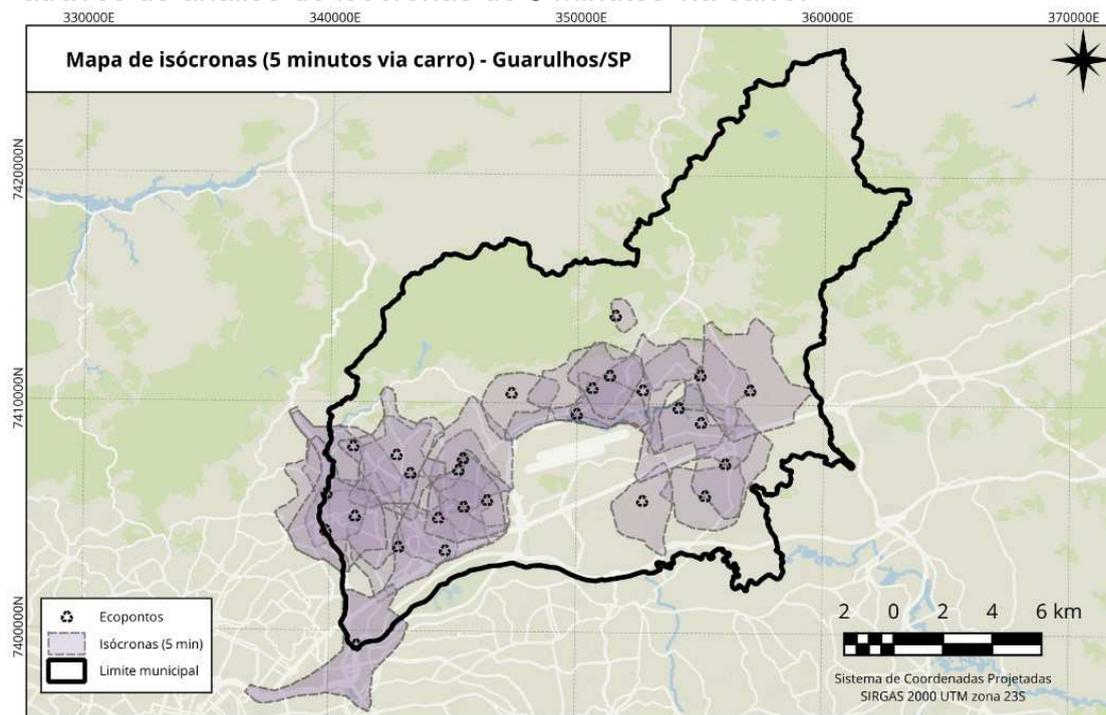
Levando em consideração a dinâmica de funcionamento de ecopontos, estes devem ser analisados não apenas por sua localização, mas também por todo o seu entorno, denominado área de cobertura. Isto se deve pelo fato de que a população do entorno se desloca até eles para descartar os resíduos. Dessa forma, as variáveis socioeconômicas, estruturais e ambientais devem ser analisadas em sua área de cobertura e não apenas na área onde o ecoponto está instalado.

Com relação a análise da cobertura dos ecopontos nas cidades de Guarulhos, Fortaleza e Belo Horizonte, foram utilizadas duas abordagens distintas: linhas isócronas e polígonos de Voronoi. Ambas as metodologias apresentam particularidades que merecem ser discutidas em detalhes.

Os mapas de linhas isócronas, apresentados nas Figuras 18 a 20, representam áreas acessíveis em um intervalo de 5 minutos de carro. Ou seja, cada ecoponto possui uma área, delimitada pela linha isócrona, onde qualquer pessoa se locomovendo de carro consegue chegar no ecoponto em questão em até 5 minutos. Este método, ao considerar a malha viária das cidades, proporciona uma análise mais fidedigna das áreas efetivamente atendidas (cobertura dos ecopontos).

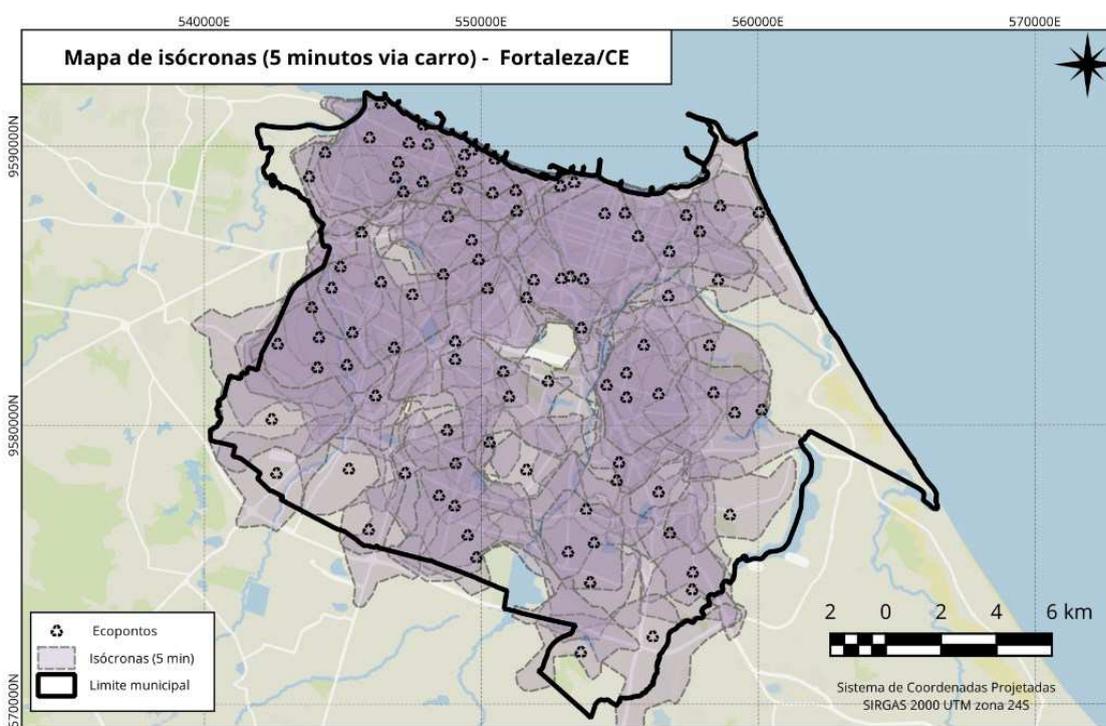
Entretanto, a análise espacial da área de cobertura ou influência utilizando isócronas apresenta uma complexidade adicional, que é a forma geométrica irregular das isócronas. Este formato irregular dificulta a sobreposição e a análise combinada ao cruzar dados com outras variáveis, como densidade demográfica e IDHM.

Figura 18 - Mapa da área de cobertura de cada ecoponto em Guarulhos/SP através de análise de isócronas de 5 minutos via carro.



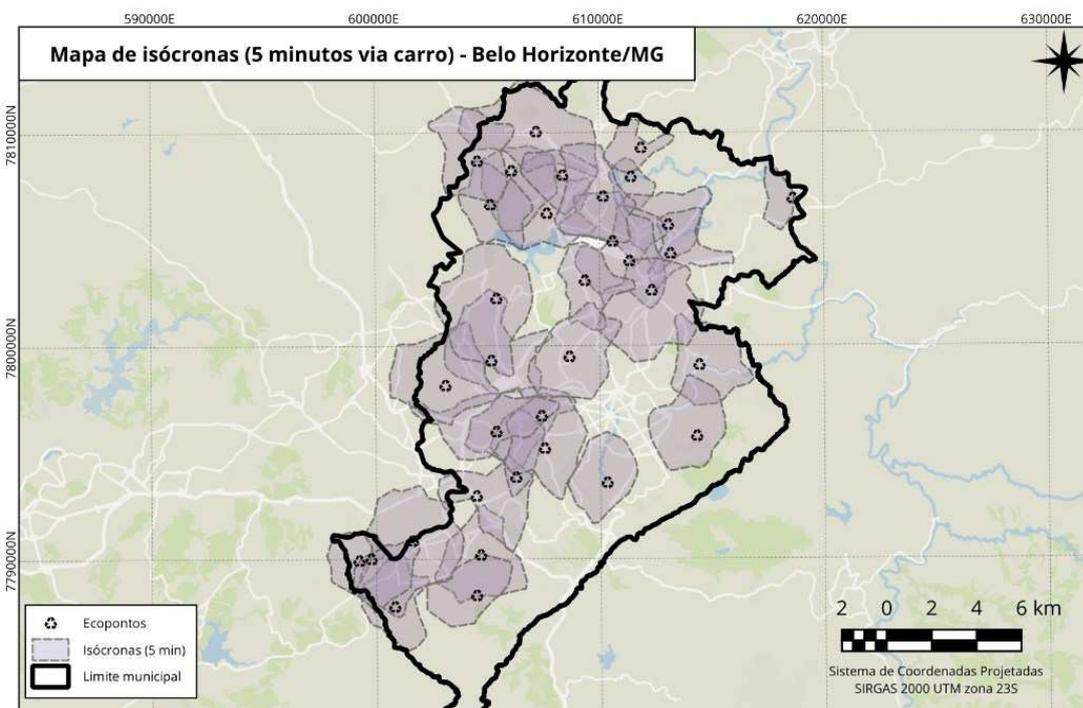
Fonte: Elaborado pelo autor (2024).

Figura 19 - Mapa da área de cobertura de cada ecoponto em Fortaleza/CE através de análise de isócronas de 5 minutos via carro.



Fonte: Elaborado pelo autor (2024).

Figura 20 - Mapa da área de cobertura de cada ecoponto em Belo Horizonte/MG através de análise de isócronas de 5 minutos via carro.



Fonte: Elaborado pelo autor (2024).

Por outro lado, temos a possibilidade de utilizar polígonos de Voronoi com a representação das áreas de cobertura de cada ecoponto (Figuras 21 a 23). Os polígonos de Voronoi dividem a área de estudo de maneira mais uniforme, atribuindo aos ecopontos uma região de influência baseada na proximidade geográfica.

Este método facilita a análise espacial ao gerar formas geométricas regulares, tornando mais viável o cruzamento com as variáveis estudadas.

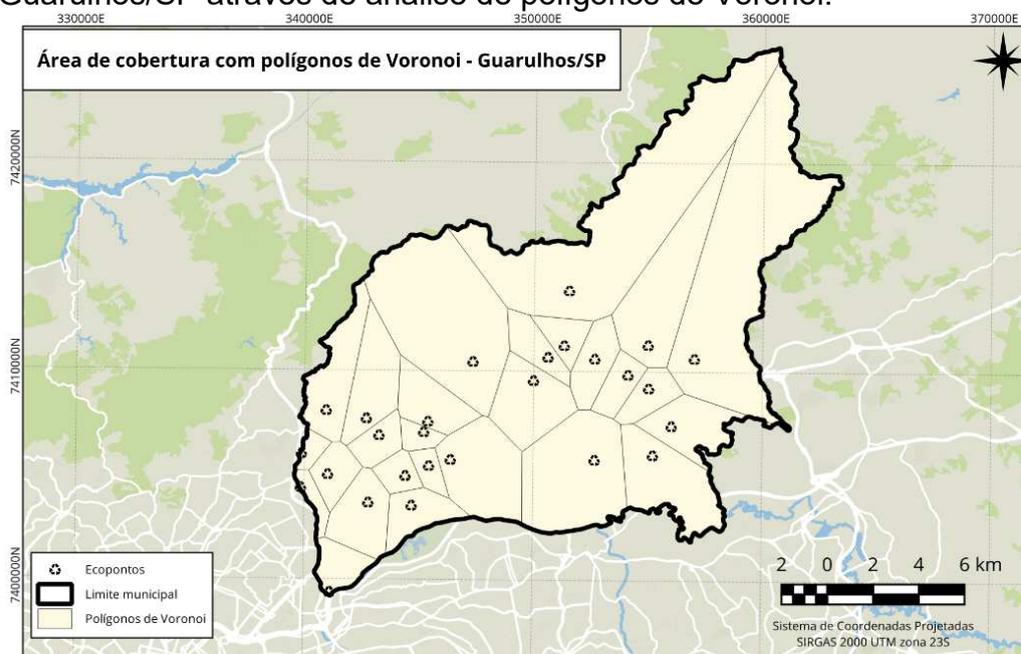
Considerando os mapas apresentados nas Figuras 18 a 23, foi realizada a análise das áreas médias dos polígonos de Voronoi e o cálculo da porcentagem de cobertura das linhas isócronas em cada cidade.

As áreas médias dos polígonos de Voronoi foram de 9,745 km² em Belo Horizonte, 3,288 km² em Fortaleza e 11,155 km² em Guarulhos. Já em relação à porcentagem de cobertura com isócronas de 5 minutos, o valor observado foi de 62,90% em Belo Horizonte, 87,82% em Fortaleza e 36,83% em Guarulhos.

A área média dos polígonos de Voronoi em Fortaleza é consideravelmente menor que as demais, motivada pela elevada quantidade de ecopontos neste município.

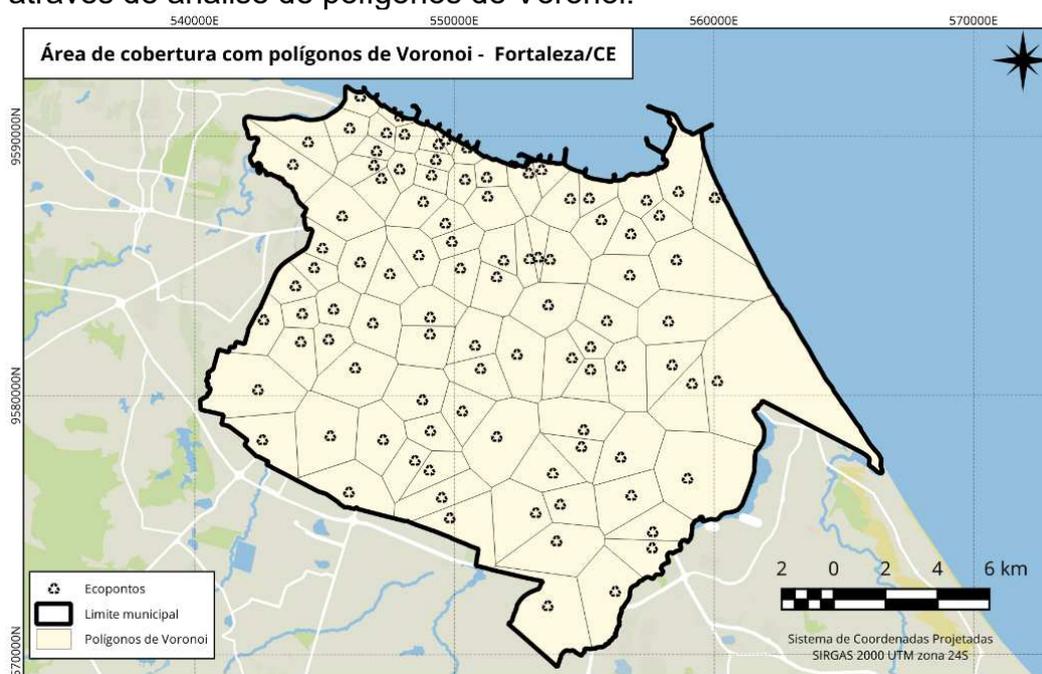
Além disso, é importante notar que, com esta metodologia, a cobertura nunca atingirá 100%, tendo em vista que existem áreas intransponíveis, como parques, mangues e aeroportos, que não possuem vias de acesso.

Figura 21 - Mapa da área de cobertura de cada ecoponto em Guarulhos/SP através de análise de polígonos de Voronoi.



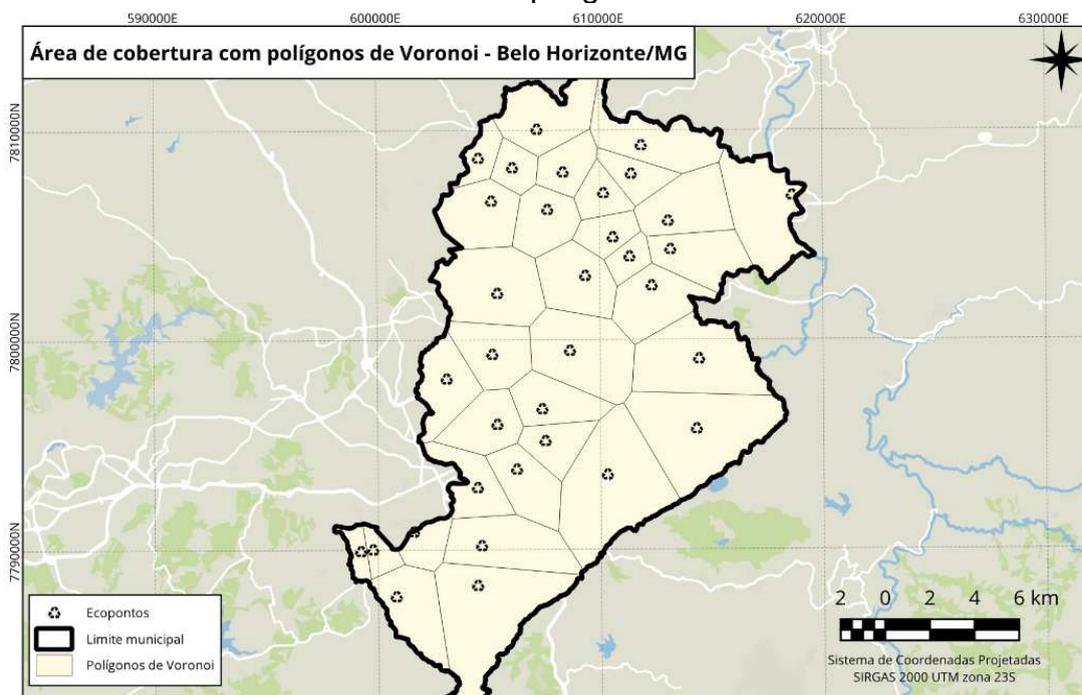
Fonte: Elaborado pelo autor (2024).

Figura 22 - Mapa da área de cobertura de cada ecoponto em Fortaleza/CE através de análise de polígonos de Voronoi.



Fonte: Elaborado pelo autor (2024).

Figura 23 - Mapa da área de cobertura de cada ecoponto em Belo Horizonte/MG através de análise de polígonos de Voronoi.



Fonte: Elaborado pelo autor (2024).

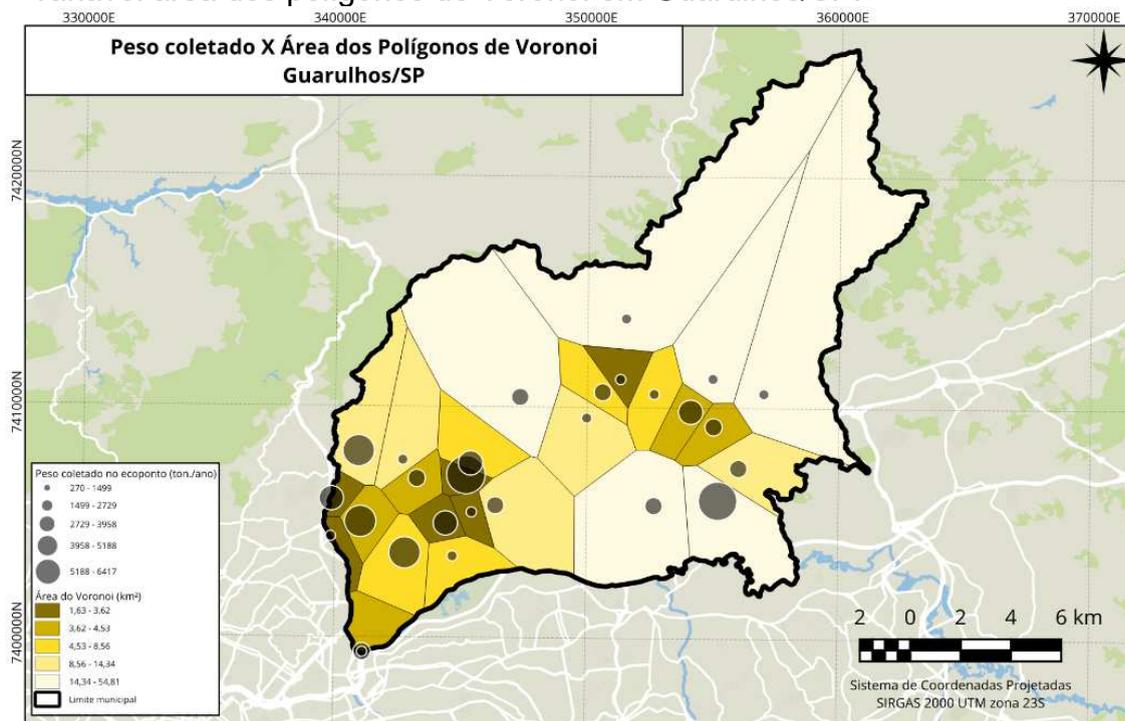
Levando em conta as características dos dois métodos, optou-se pelos polígonos de Voronoi, sendo os principais motivos desta escolha o fato deste método cobrir toda a área das cidades e a forma geométrica favorecer as operações de geoprocessamento necessárias para o desenvolvimento deste estudo.

Por fim, tendo sido definidas as áreas de influência dos ecopontos como sendo os polígonos de Voronoi, foi realizada uma comparação nas três cidades entre o peso coletado por ecoponto e a área do respectivo Voronoi. Os mapas estão dispostos nas Figuras 24 a 26.

Ao analisar os mapas, não foi possível identificar algum padrão claro entre a área e o peso coletado. Isto pode ser justificado porque grandes áreas não necessariamente representam uma maior população atendida, já que estas áreas podem ser áreas inacessíveis ou inabitadas.

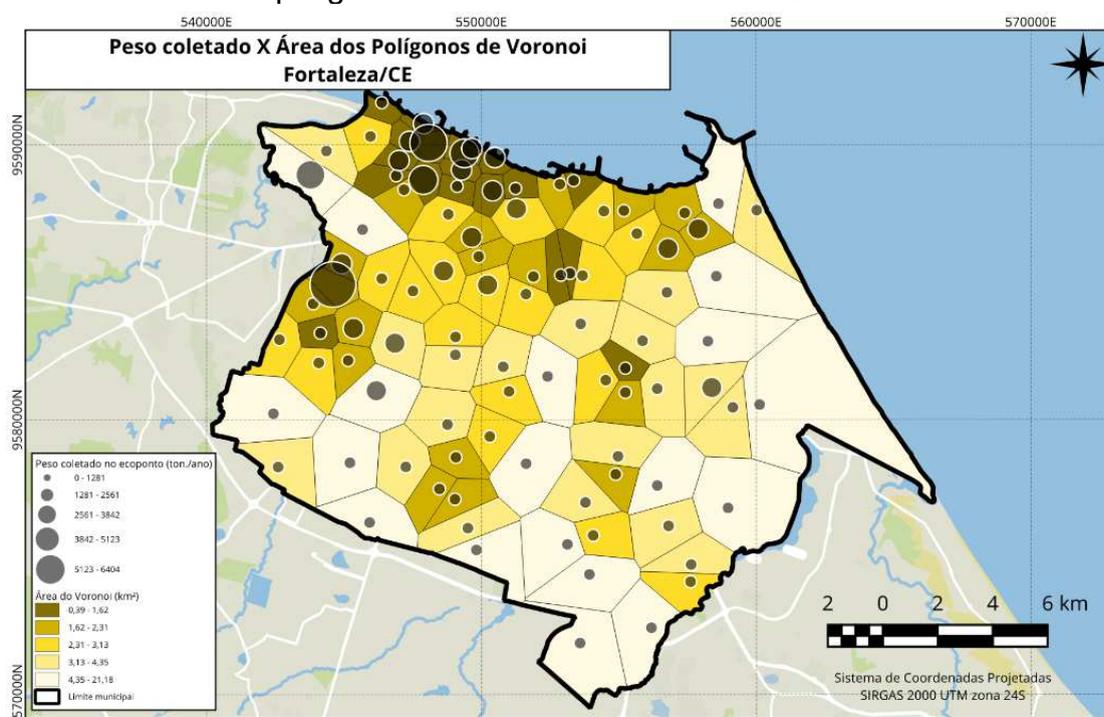
Esta ausência de padrão também reforça a tese que existem variáveis independentes que precisam ser analisadas para explicar as grandes variações entre pesos coletados em ecopontos.

Figura 24 - Mapa do cruzamento de pesos coletados por ecopontos com a variável área dos polígonos de Voronoi em Guarulhos/SP.



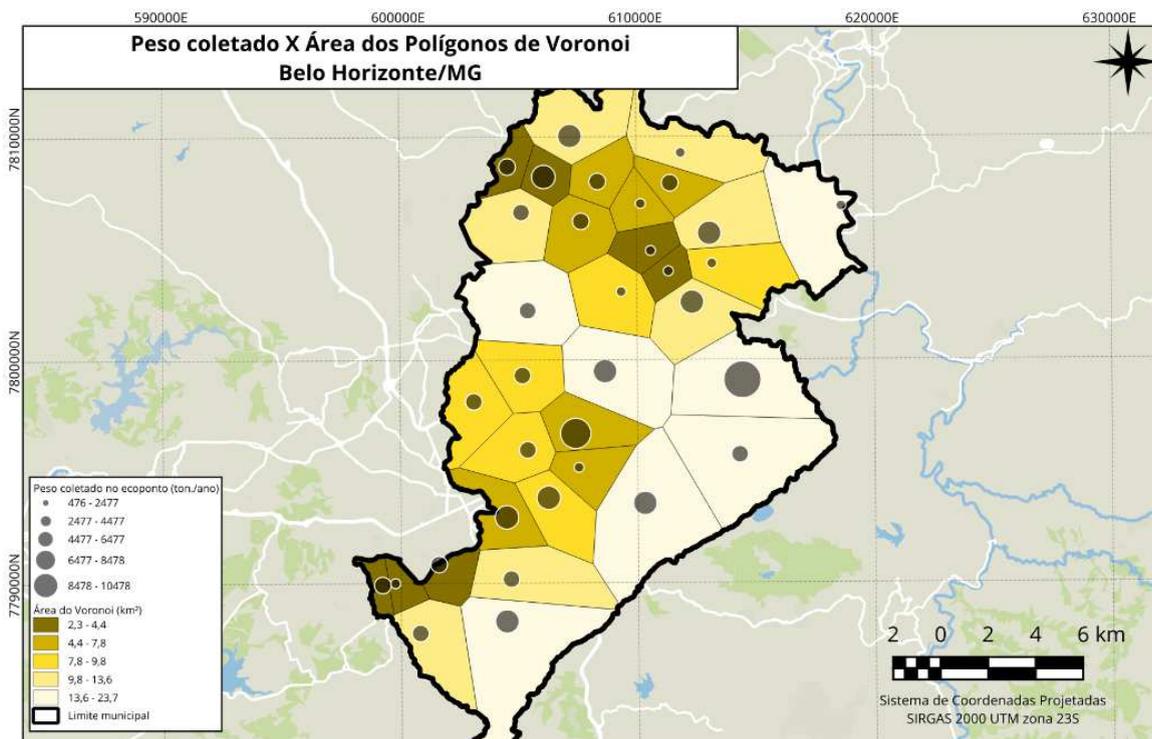
Fonte: Elaborado pelo autor (2024).

Figura 25 - Mapa do cruzamento de pesos coletados por ecopontos com a variável área dos polígonos de Voronoi em Fortaleza/CE.



Fonte: Elaborado pelo autor (2024).

Figura 26 - Mapa do cruzamento de pesos coletados por ecopontos com a variável área dos polígonos de Voronoi em Belo Horizonte/MG.



Fonte: Elaborado pelo autor (2024).

5.4 Análise exploratória da variável dependente

Para a análise exploratória da variável dependente (peso coletado por ecoponto), foram realizadas três análises principais: Índice de Moran, Análise de Padrão de Pontos (*Point Pattern Analysis*) e Mapa LISA (*Local Indicators of Spatial Association*).

O Índice de Moran observado para Fortaleza foi de 0,261, o que sugere uma autocorrelação espacial positiva que pode ser classificada entre leve e moderada. Isso significa que existe uma tendência de que valores semelhantes estão espacialmente próximos uns dos outros, mas essa tendência não é forte.

Já Belo Horizonte e Guarulhos apresentaram um Índice de Moran de 0,034 e 0,072, respectivamente. Estes valores sugerem uma autocorrelação espacial muito fraca e quase inexistente, indicando que os valores da variável peso coletado são distribuídos de forma quase aleatória no espaço, com pouca ou nenhuma dependência espacial significativa.

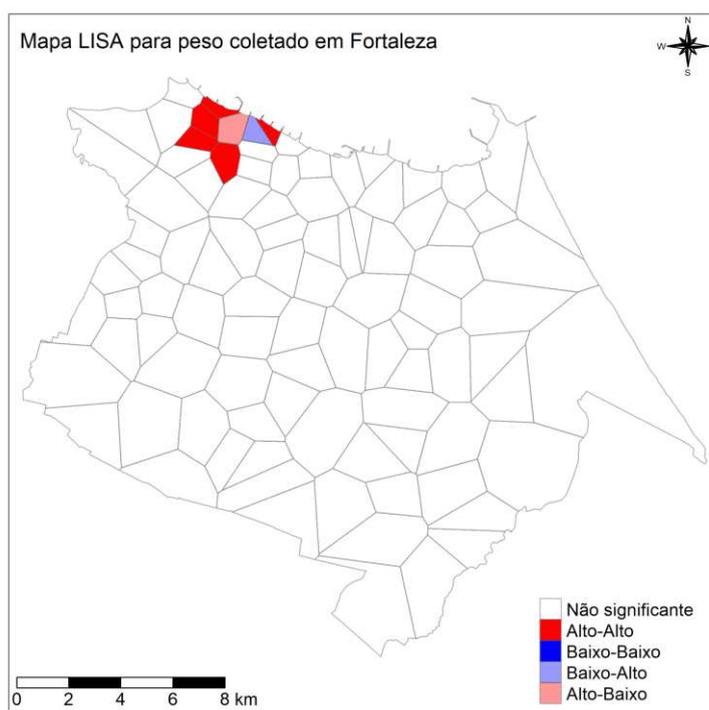
Em outras palavras, o peso coletado nas duas cidades não está significativamente correlacionado com o peso coletado nas áreas vizinhas.

Já em relação à Análise de Padrão de Pontos, Guarulhos apresentou um p-valor de 0,152, Fortaleza de 0,212 e Belo Horizonte 0,245. Esta análise indicou que, em todas as três cidades, a distribuição dos ecopontos não apresenta evidências estatisticamente significativas de agrupamento ou padronização espacial, sugerindo uma distribuição aleatória.

Em outras palavras, a localização dos ecopontos não segue um padrão espacial discernível, o que pode ser interpretado como uma distribuição não influenciada por fatores espaciais óbvios.

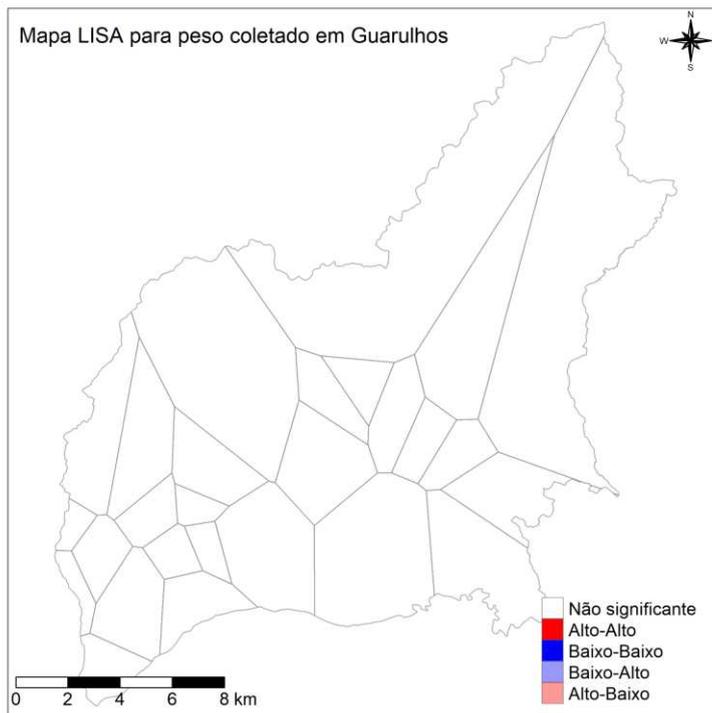
Por fim, em relação ao Mapa LISA de clusters, foram gerados os três mapas apresentados nas Figuras 27 a 29. Os resultados indicaram que mais de 90% das áreas em cada cidade não apresentaram autocorrelação espacial significativa, ou seja, não há um padrão claro de concentração ou dispersão dos resíduos.

Figura 27 - Mapa LISA de clusters para a variável peso coletado de resíduos na cidade de Fortaleza.



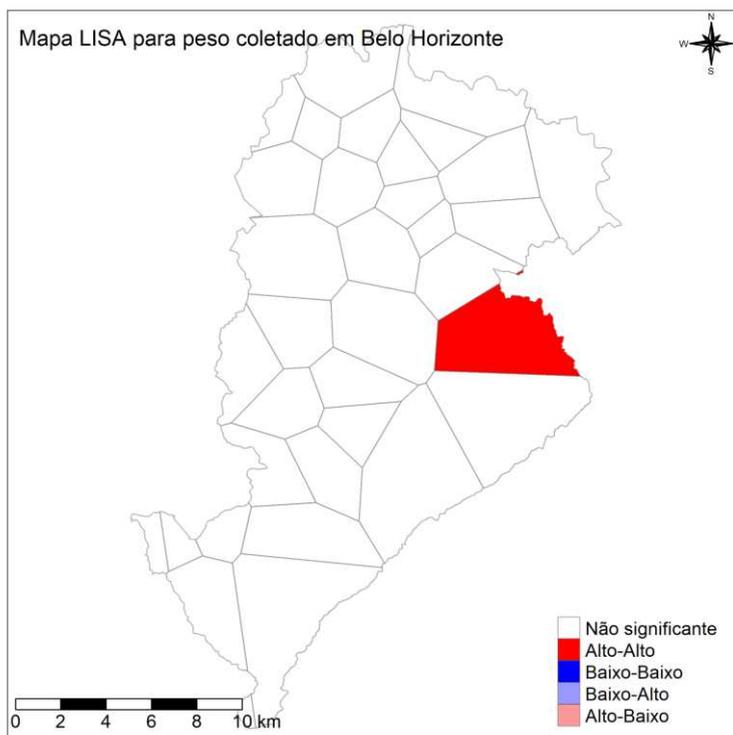
Fonte: Elaborado pelo autor (2024).

Figura 28 - Mapa LISA de clusters para a variável peso coletado de resíduos na cidade de Guarulhos.



Fonte: Elaborado pelo autor (2024).

Figura 29 - Mapa LISA de clusters para a variável peso coletado de resíduos na cidade de Belo Horizonte.



Fonte: Elaborado pelo autor (2024).

Por fim, após estas três análises, pode-se concluir que a distribuição da variável analisada é aleatória e não segue um padrão espacial claro, o que sugere que outros fatores podem estar influenciando esta distribuição de resíduos coletados. Desta forma, se fez necessário a realização de análises adicionais para identificar estes fatores correlacionados.

5.5 Análise de variáveis independentes

A fim de analisar e identificar padrões nos ecopontos de alta performance em cada uma das três cidades, foram gerados mapas temáticos e gráficos para tentar representar espacialmente como estas variáveis se comportam ao longo dos municípios. Inicialmente, foram analisadas as variáveis densidade demográfica, IDHM e proximidade de vias. As demais variáveis foram analisadas nas etapas subsequentes do estudo e serão discutidas nos próximos tópicos.

5.5.1 Densidade demográfica

Os mapas apresentados nas Figuras 30 a 32 ilustram a densidade demográfica por setor censitário e o peso coletado nos ecopontos nas três cidades estudadas. Estes mapas são fundamentais para entender a distribuição espacial da população e se há evidências de correlação com o peso coletado nos ecopontos.

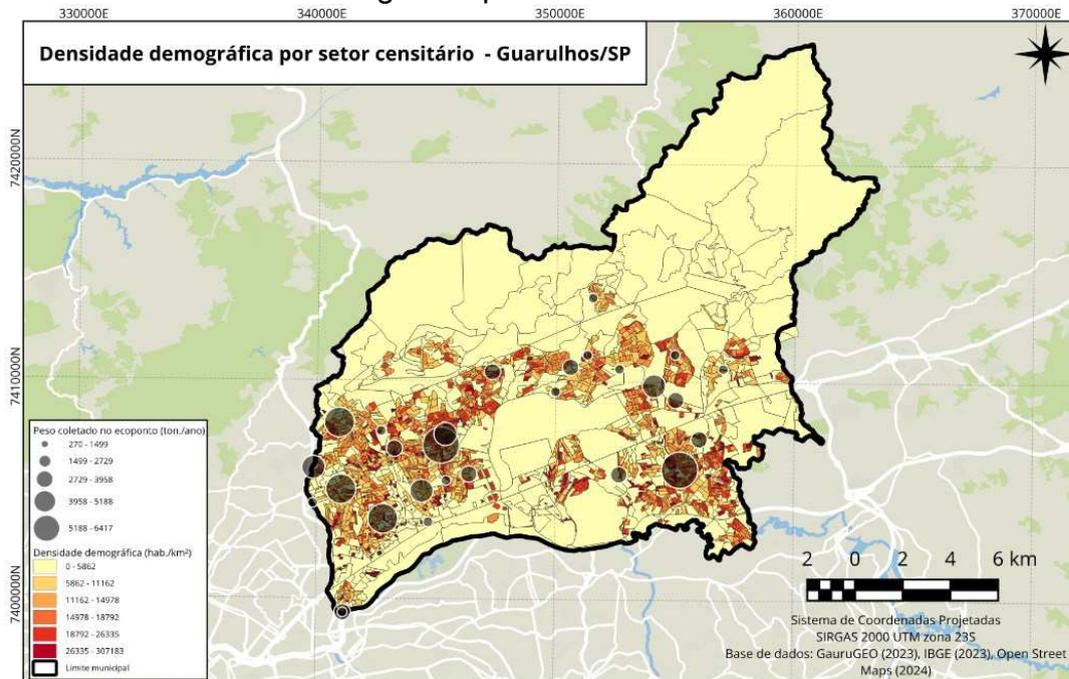
Em Guarulhos, a densidade demográfica é particularmente elevada nos setores localizados a sudoeste, onde também se concentram os maiores pesos de resíduos coletados nos ecopontos, indicados pelos círculos maiores. As porções norte e nordeste do município apresentam áreas menos densamente povoadas ou até inabitadas, por se tratarem de regiões de mata nativa. Nestas regiões, de forma justificada, não existem ecopontos instalados.

Já no mapa de Fortaleza, é observado uma densidade demográfica elevada em diversas áreas, especialmente na zona oeste da cidade. Os ecopontos localizados nessas regiões registram os maiores pesos de resíduos coletados.

Por fim, em Belo Horizonte, a densidade demográfica é elevada nas áreas central e leste e os ecopontos que coletam os maiores pesos de resíduos estão bem distribuídos pela cidade. Áreas com menor densidade demográfica, especialmente na

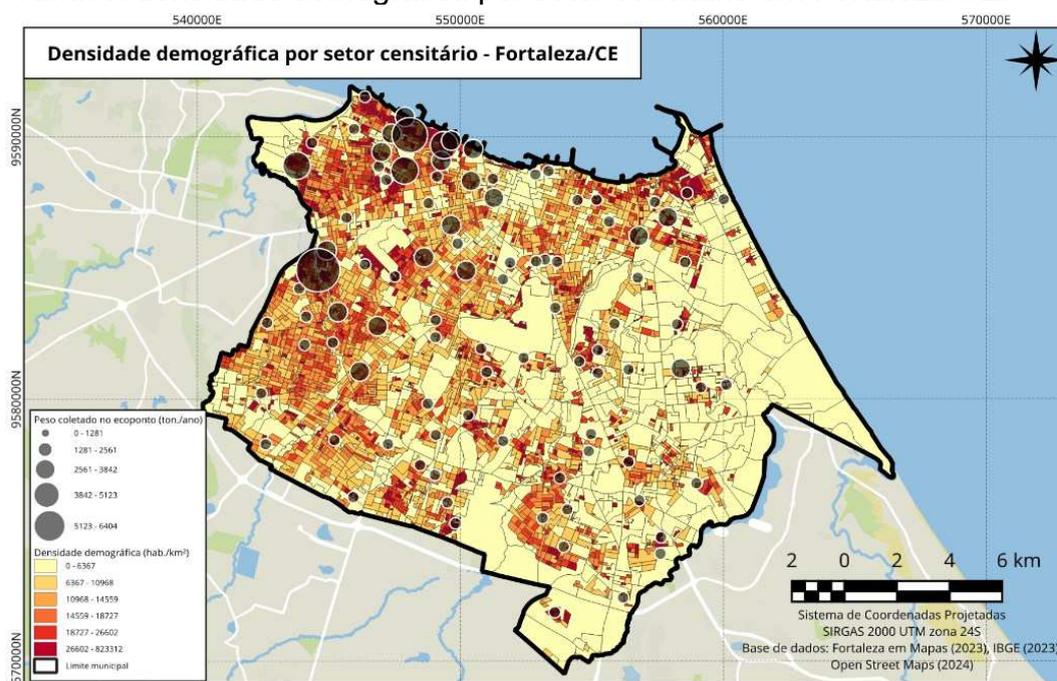
periferia, possuem menores pesos coletados, alinhando-se com o padrão observado nas outras cidades.

Figura 30 – Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica por setor censitário em Guarulhos/SP.



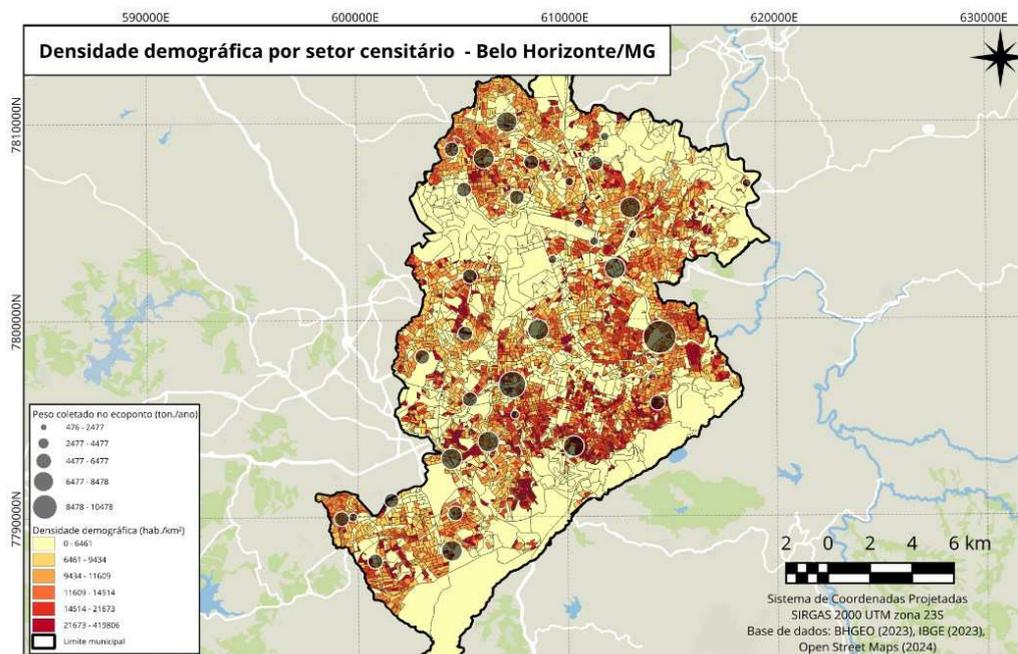
Fonte: Elaborado pelo autor (2024).

Figura 31 - Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica por setor censitário em Fortaleza/CE.



Fonte: Elaborado pelo autor (2024).

Figura 32 - Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica por setor censitário em Belo Horizonte/MG.



Fonte: Elaborado pelo autor (2024).

Embora úteis para uma visualização mais detalhada da distribuição demográfica nas cidades, o uso da divisão territorial como sendo os setores censitários traz variações significativas em áreas relativamente pequenas, dificultando a visualização clara da correlação entre a densidade demográfica e a quantidade de resíduos coletados. A variação granular na densidade demográfica dentro dos setores censitários adiciona uma camada de complexidade que não facilita a interpretação rápida.

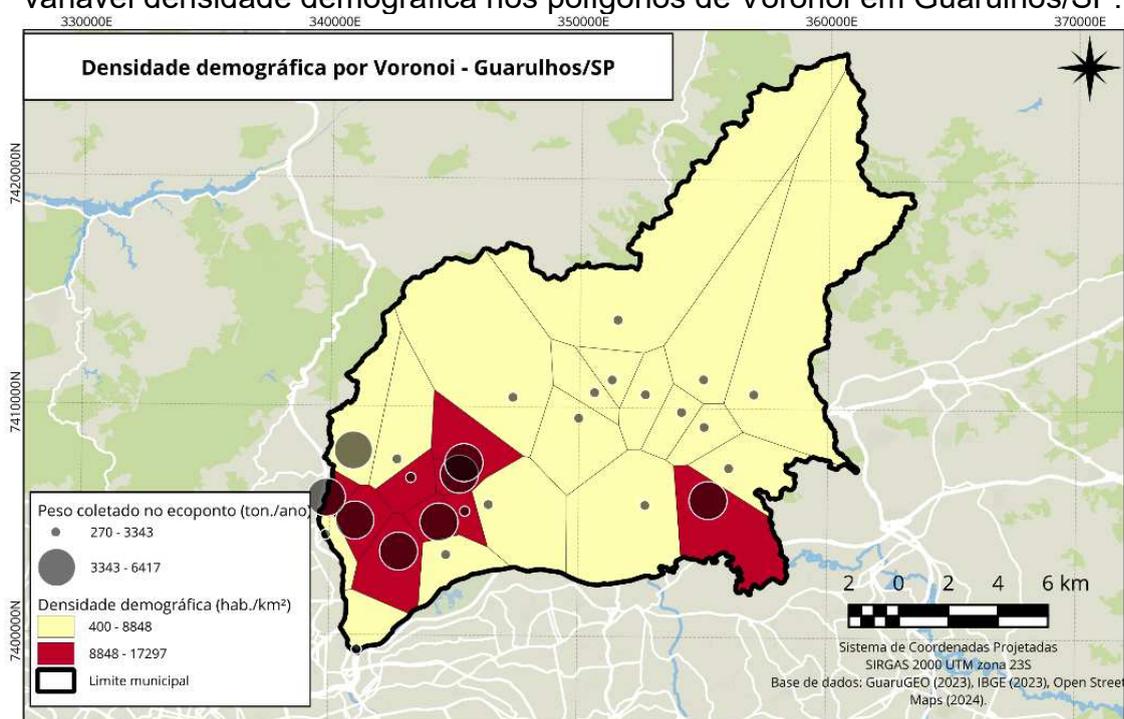
Por este motivo, a variável densidade demográfica foi representada através de polígonos de Voronoi, que além de representar melhor a área de influência de cada ecoponto, permite uma visualização mais clara e direta da correlação entre densidade demográfica e pesos coletados de resíduos nos ecopontos. As Figuras 33 a 35 apresentam os mapas gerados a partir do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica atribuída nos polígonos de Voronoi de cada cidade estudada.

Nos mapas, reduziu-se o número de classes de pesos e densidade demográfica, sendo estas variáveis representadas em apenas duas classes cada com intervalos iguais.

Ao analisar as três cidades, pode-se observar claramente que existe uma correlação positiva entre as duas variáveis. Nas três cidades, a grande maioria dos ecopontos fica localizado em áreas de alta densidade demográfica.

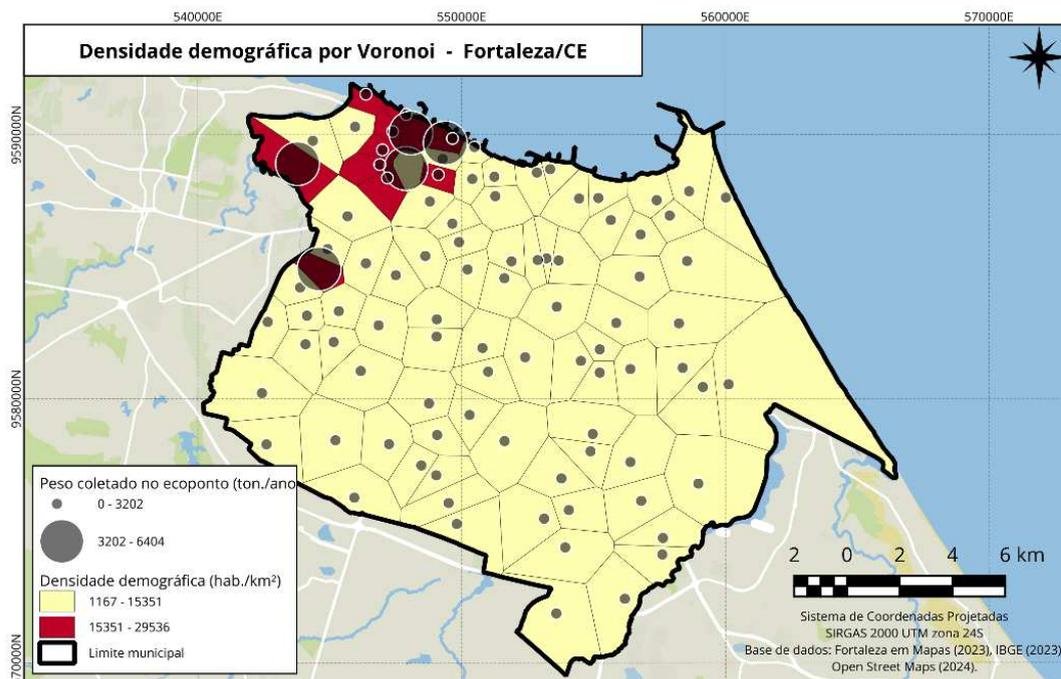
Entretanto, também pode-se observar que a densidade demográfica não é a única variável que possui influência sobre a performance de um ecoponto, tendo em vista que existem alguns ecopontos, localizados em áreas de alta densidade populacional, que não apresentam uma alta performance em termos de peso coletado.

Figura 33 - Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica nos polígonos de Voronoi em Guarulhos/SP.



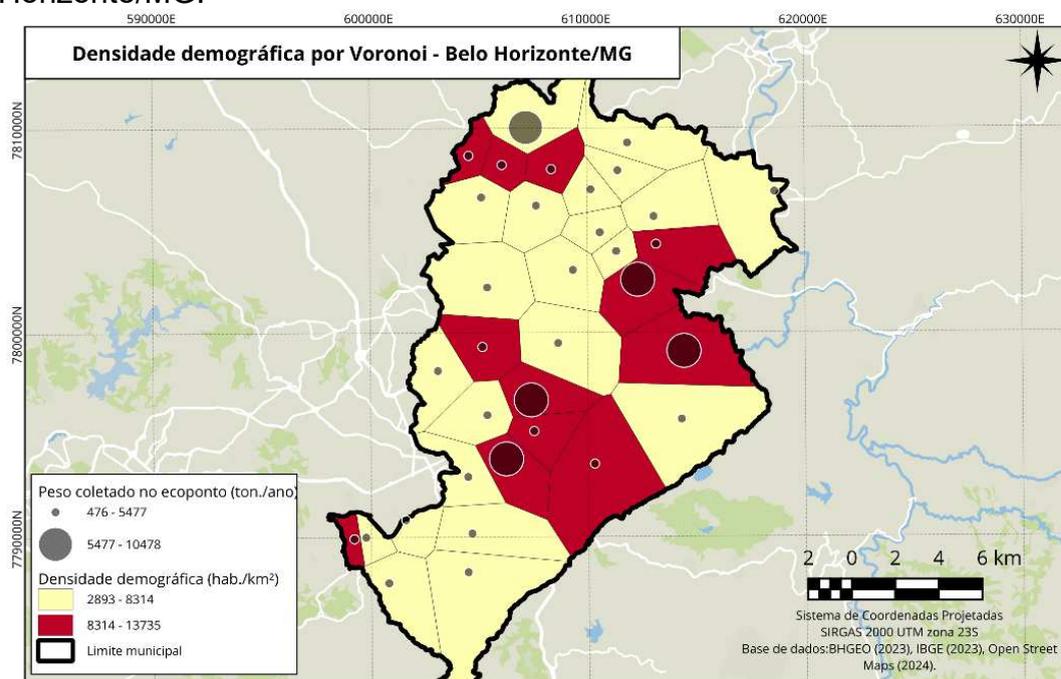
Fonte: Elaborado pelo autor (2024).

Figura 34 - Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica nos polígonos de Voronoi em Fortaleza/CE.



Fonte: Elaborado pelo autor (2024).

Figura 35 - Mapa do cruzamento de pesos coletados por ecoponto com a variável densidade demográfica nos polígonos de Voronoi em Belo Horizonte/MG.



Fonte: Elaborado pelo autor (2024).

5.5.2 IDHM

De forma análoga, os mapas apresentados nas Figuras 36 a 38 ilustram a variação de IDHM por setor censitário e o peso coletado nos ecopontos nas três cidades estudadas.

Em Guarulhos, observamos que os setores com IDHM mais elevados (acima de 0,83) estão concentrados na região sudoeste da cidade, onde também se encontra uma alta densidade populacional. As áreas com IDHM mais baixos (entre 0,65 e 0,74) estão localizadas principalmente nas regiões norte e leste, onde os pesos coletados nos ecopontos são menores. Este padrão sugere que áreas com maior IDHM e maior densidade populacional têm uma maior utilização dos ecopontos pela população.

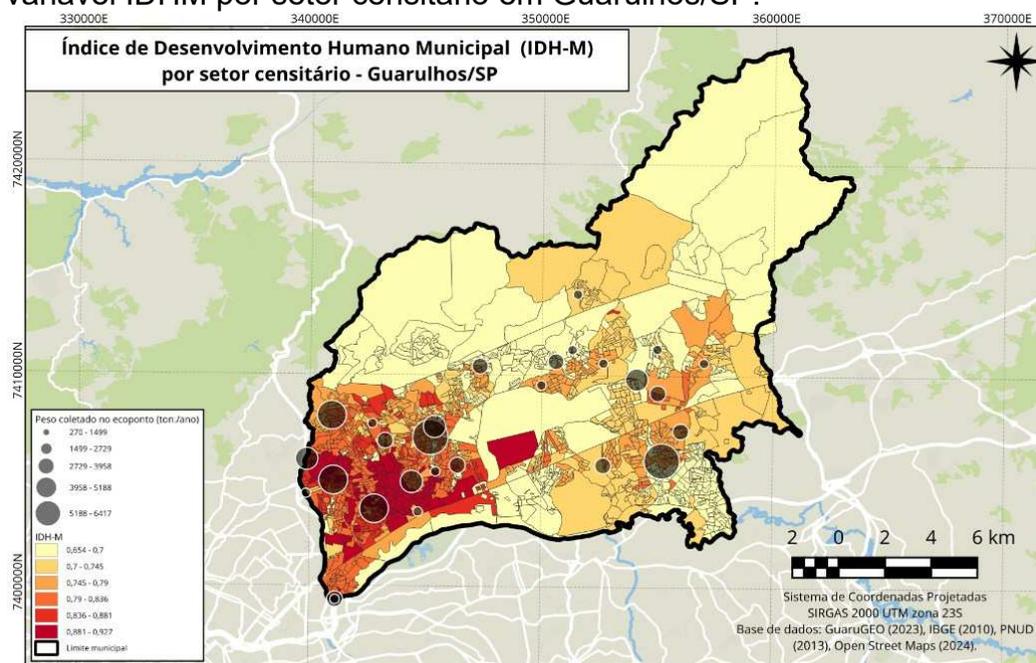
Fortaleza apresenta uma distribuição mista de IDHM, com setores de alto desenvolvimento (acima de 0,82) principalmente nas regiões leste e nordeste da cidade, onde os pesos de resíduos coletados tendem a ser menores. Setores com IDHM mais baixo (entre 0,56 a 0,75) estão localizados principalmente nas áreas oeste, sul e noroeste da cidade. Nestas regiões, os ecopontos registram os maiores pesos de resíduos coletados, embora existam muitas áreas com IDHM baixo e com o peso coletado também baixo. Este padrão indica que, em Fortaleza, os ecopontos localizados em áreas com menor IDHM tendem a ser mais utilizados, embora não seja uma regra.

Uma hipótese para tentar explicar este padrão observado em Fortaleza é a existência dos programas de incentivo financeiro para o descarte de materiais nos ecopontos. Estes estímulos monetários na forma de desconto na conta de energia elétrica (Recicla Fortaleza) e créditos em estabelecimentos locais (E-carroceiro), despertam um maior interesse na população com menor renda.

Por fim, em Belo Horizonte, os setores com IDHM mais baixo (0,61 a 0,78) estão localizados principalmente nas regiões periféricas da cidade, onde se observam valores moderados ou baixos de pesos coletados nos ecopontos. Setores com IDHM mais alto (acima de 0,84) estão concentrados nas regiões noroeste e sudeste, apresentando maiores volumes de resíduos coletados.

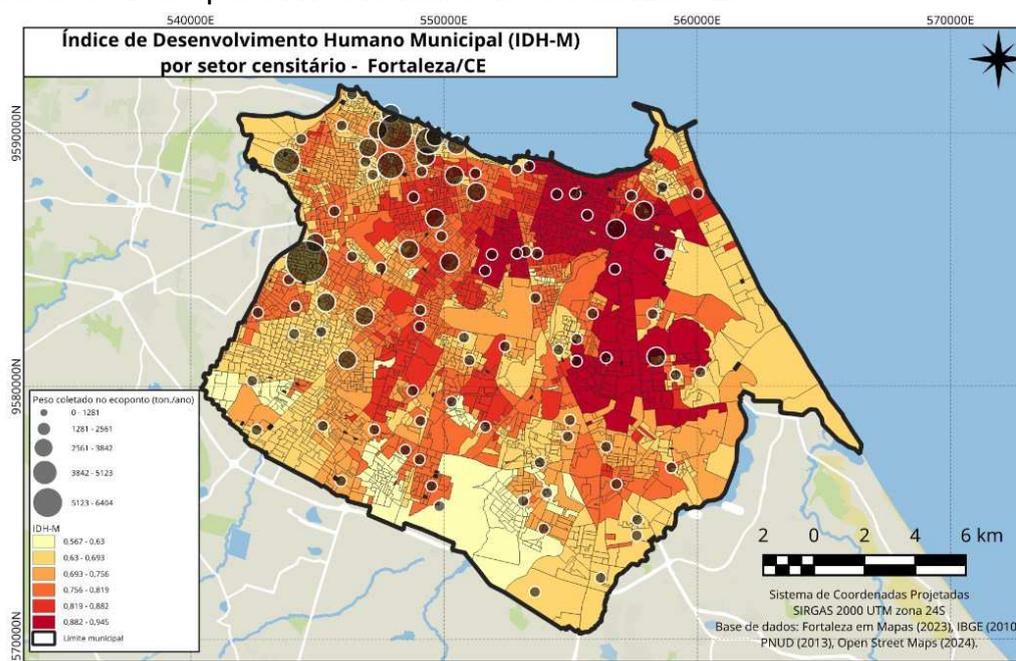
A análise dos mapas de IDHM por setor censitário e peso coletado nos ecopontos não nos revela uma correlação muito clara e que esteja presente nos três municípios.

Figura 36 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM por setor censitário em Guarulhos/SP.



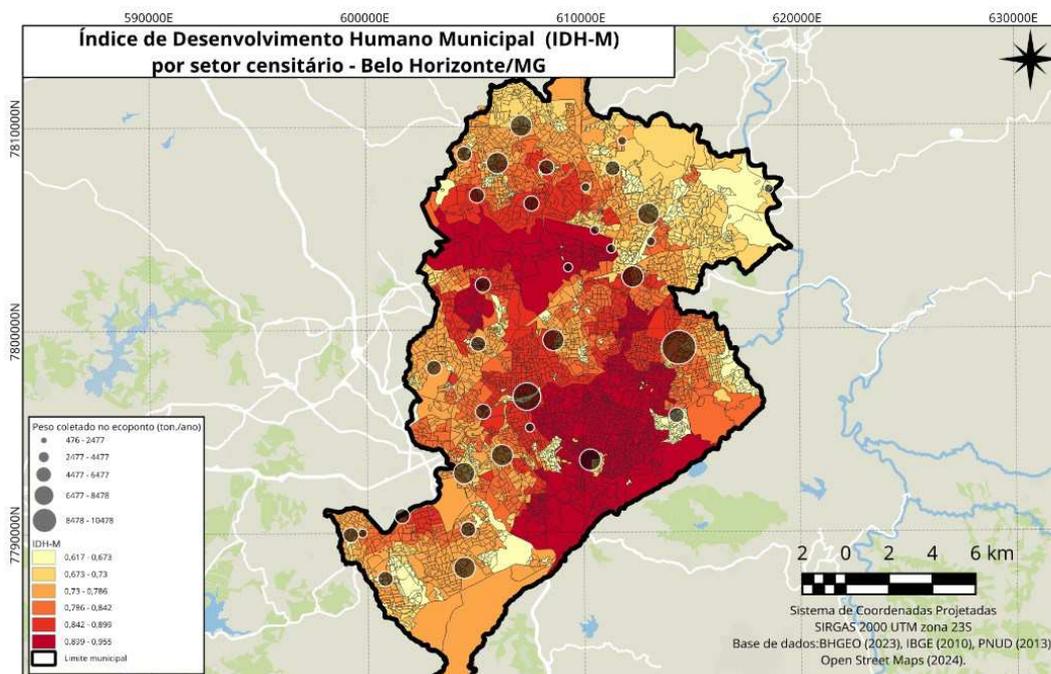
Fonte: Elaborado pelo autor (2024).

Figura 37 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM por setor censitário em Fortaleza/CE.



Fonte: Elaborado pelo autor (2024).

Figura 38 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM por setor censitário em Belo Horizonte/MG.



Fonte: Elaborado pelo autor (2024).

Para tentar facilitar a identificação de padrões que podem ter a visualização prejudicada pela complexidade granular dos setores censitários, novamente recorreu-se à simplificação espacial proporcionada pelos polígonos de Voronoi.

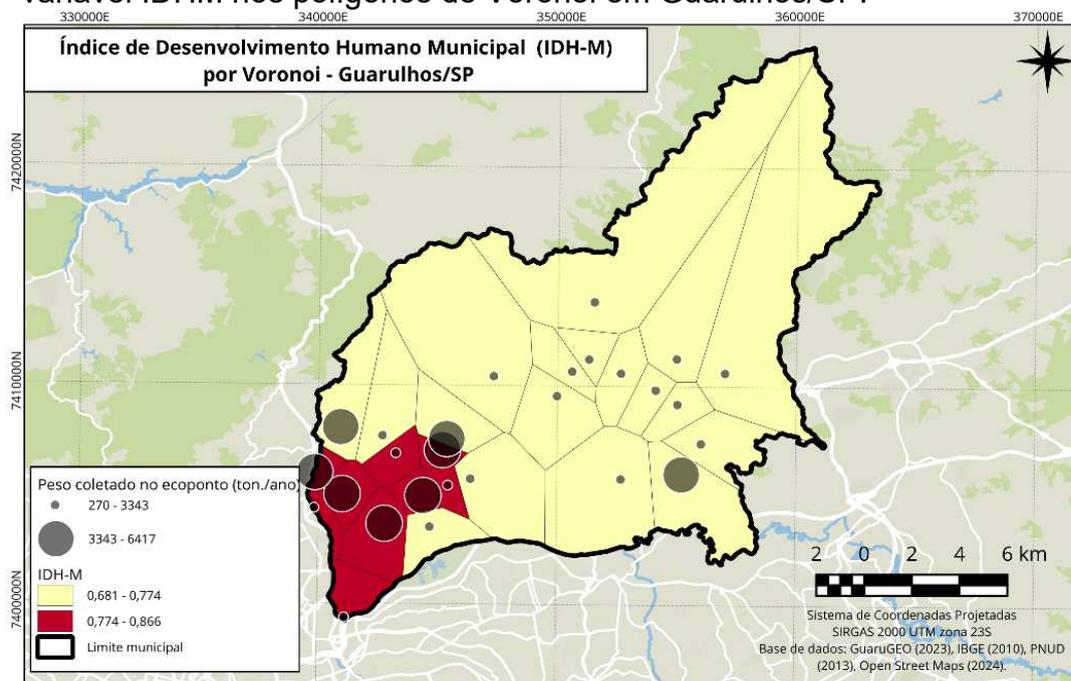
As Figuras 39 a 41 apresentam os mapas gerados a partir do cruzamento de pesos coletados por ecoponto com a variável IDHM atribuída nos polígonos de Voronoi de cada cidade estudada.

De forma similar à variável densidade demográfica, reduziu-se o número de classes de pesos e IDHM, sendo estas variáveis representadas em apenas duas classes cada com intervalos iguais.

Ao analisar as três cidades, pode-se observar que esta variável se comporta de forma diferente em cada cidade. Em Guarulhos, ecopontos de alta performance estão localizados em áreas de maior IDHM. Já em Fortaleza, esta relação é invertida, sendo as áreas com IDHM menor as que mais descartam resíduos nos ecopontos. Por fim, em Belo Horizonte, áreas com IDHM mais elevados não possuem consistência em relação ao peso coletado.

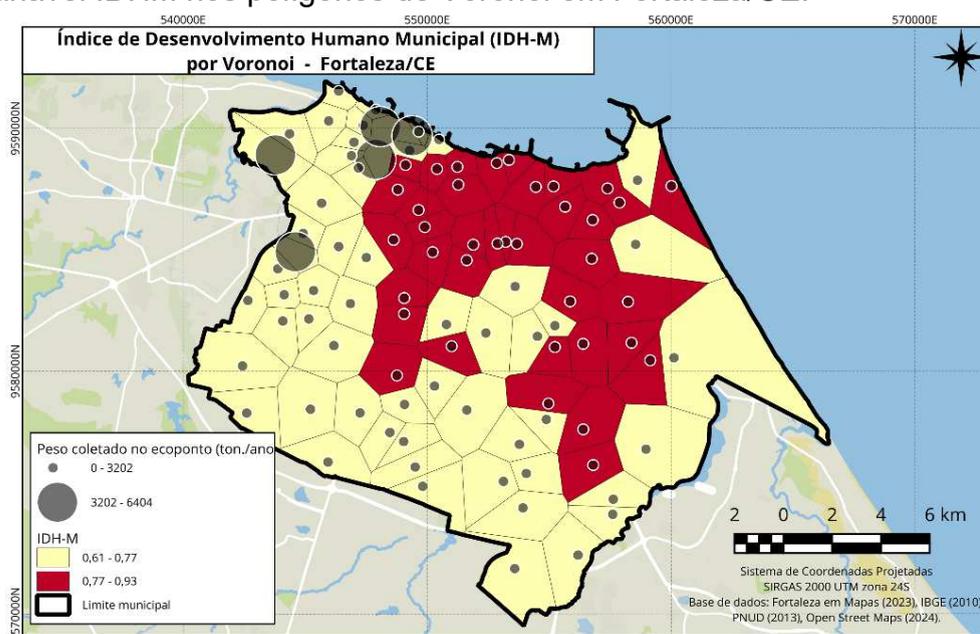
Esta observação sugere que o IDHM é uma variável relevante nesta questão, mas que deve ser tratada e analisada individualmente em cada cidade. Ou seja, um padrão observado em um município pode não se repetir em outro.

Figura 39 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM nos polígonos de Voronoi em Guarulhos/SP.



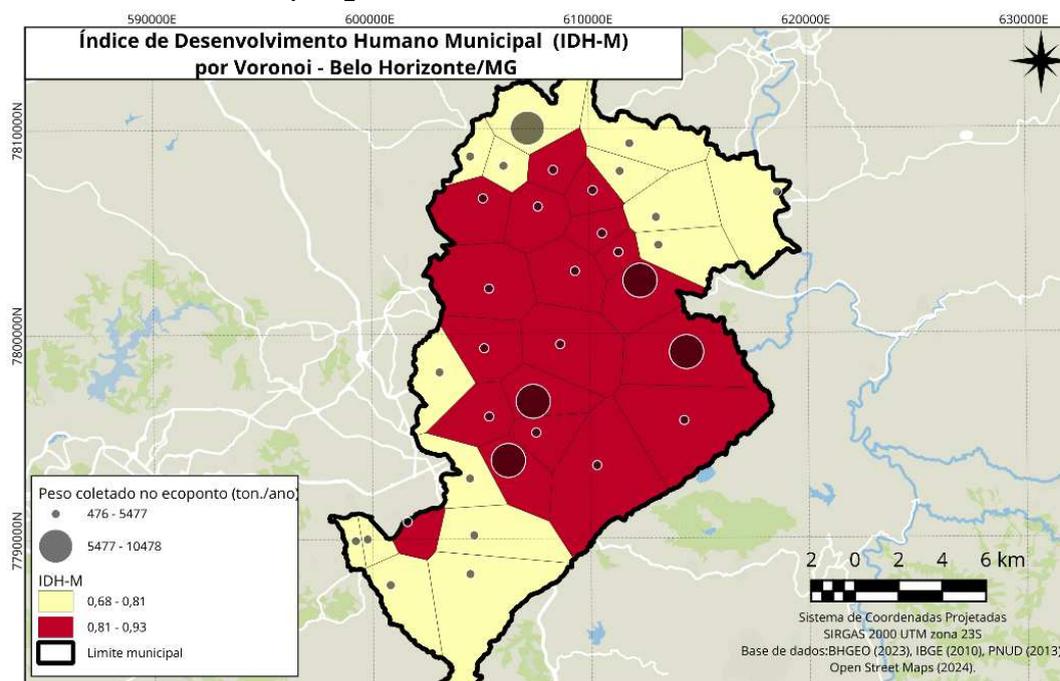
Fonte: Elaborado pelo autor (2024).

Figura 40 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM nos polígonos de Voronoi em Fortaleza/CE.



Fonte: Elaborado pelo autor (2024).

Figura 41 - Mapa do cruzamento de pesos coletados por ecoponto com a variável IDHM nos polígonos de Voronoi em Belo Horizonte/MG.



Fonte: Elaborado pelo autor (2024).

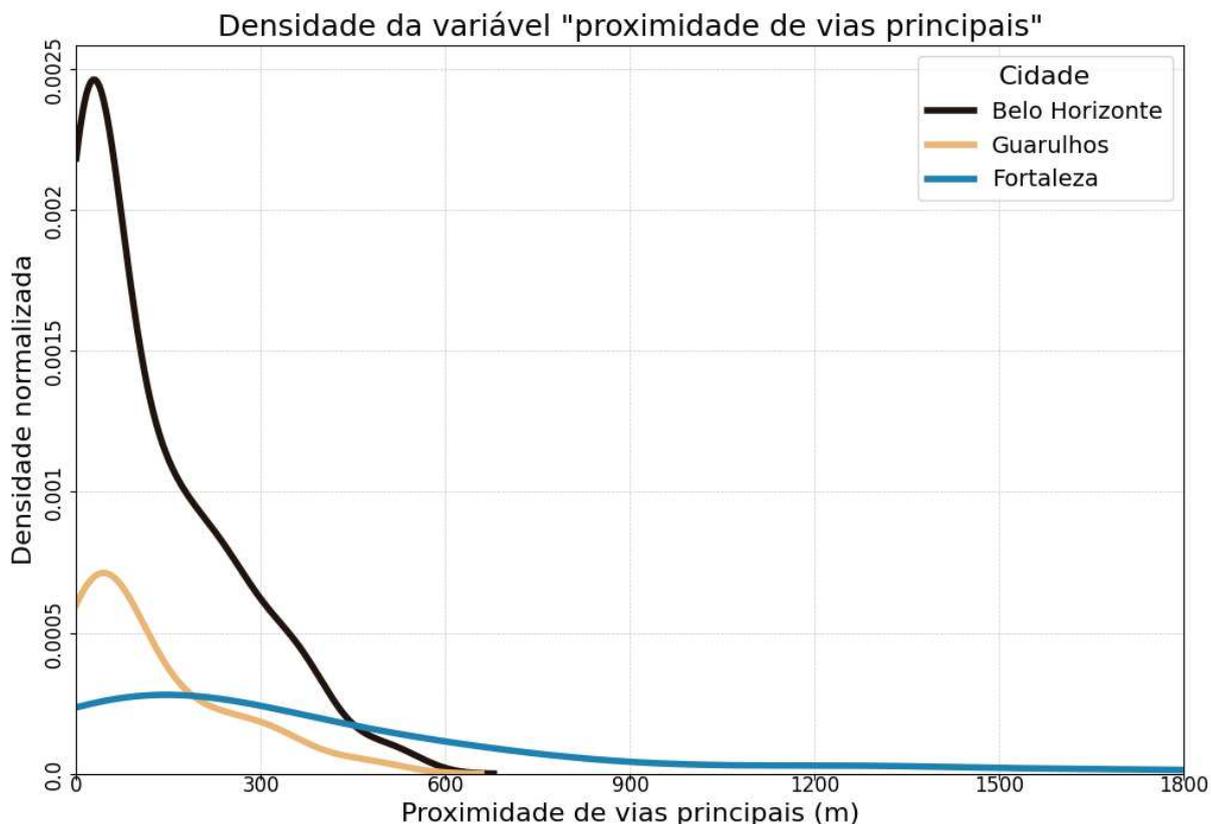
5.5.3 Proximidade de vias principais

A variável proximidade de vias principais também foi analisada separadamente nesta etapa do estudo. Esta variável representa o quão próximo um ecoponto está de uma via considerada principal (vias arteriais, expressas, rodovias, avenidas de grande largura etc.).

Diferentemente das variáveis anteriores, sua representação na forma de mapa não contribui de forma relevante para a discussão desta variável.

Desta forma, foi gerado um gráfico de densidade normalizada para as três cidades. No eixo X, temos as distâncias em metros partindo dos ecopontos até as vias principais (proximidade) e no eixo Y temos a densidade normalizada destes valores. O resultado pode ser observado na Figura 42.

Figura 42 - Gráfico de densidade da variável proximidade de vias principais para as três cidades estudadas.

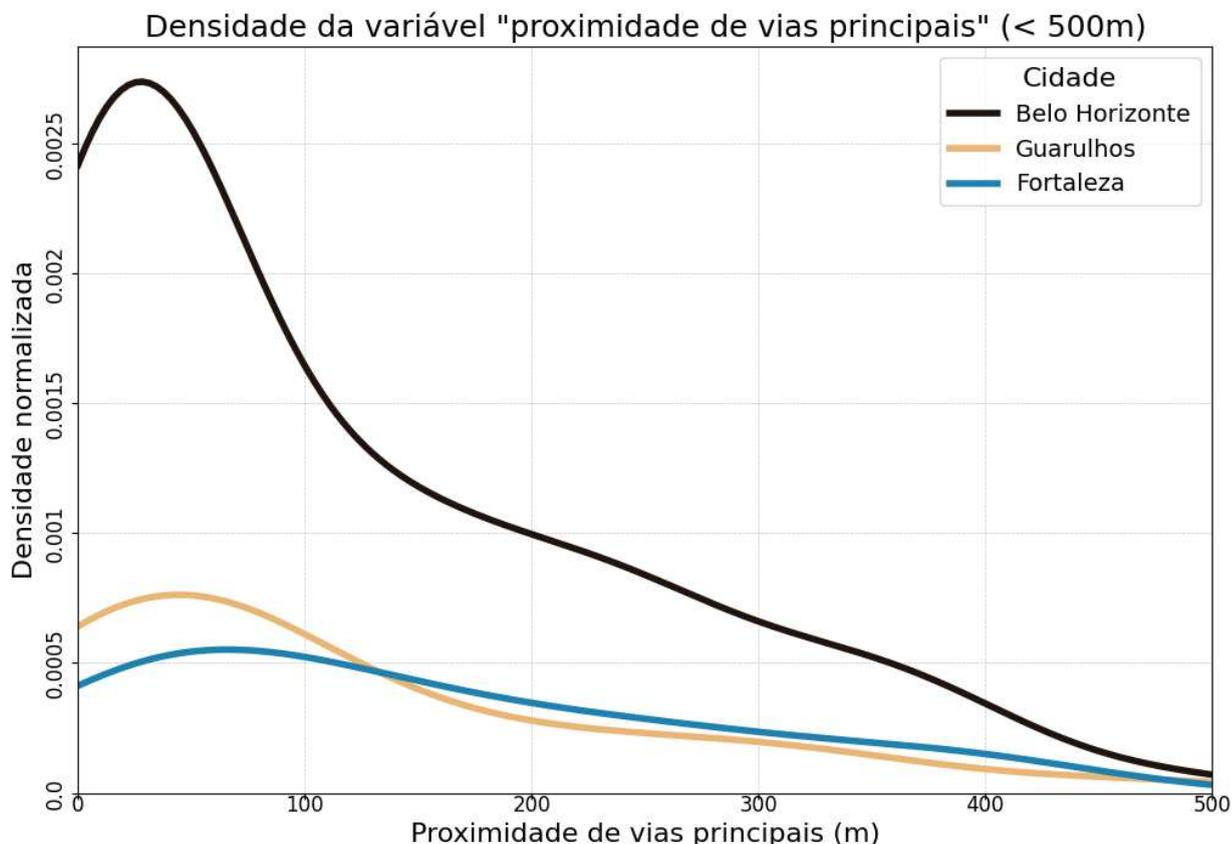


Fonte: Elaborado pelo autor (2024).

Importante citar que a linha representativa de Fortaleza é mais elevada que as demais devido ao número de valores de entrada (ecopontos) ser cerca de três vezes superior às demais cidades.

Observa-se que a imensa maioria dos ecopontos está localizado em até 600 metros de uma via principal. Para melhor visualizar esta distribuição, foi realizada uma adaptação do gráfico anterior, limitando a distância máxima em até 500 metros.

Figura 43 - Gráfico de densidade da variável proximidade de vias principais para as três cidades estudadas.



Fonte: Elaborado pelo autor (2024).

A análise da Figura 43 adaptada sugere que existe uma preferência em instalar ecopontos próximos de vias principais, em geral em até 200 metros. Esta observação possui embasamento lógico, considerando que os ecopontos devem ser acessíveis tanto para a população descartar os resíduos como para os caminhões de coleta conseguirem se deslocar com facilidade ao chegar ou partir do ecoponto.

Ao realizar a mesma análise para a variável proximidade de corpos hídricos, não foi possível observar qualquer padrão estatístico relevante.

A correlação com o peso coletado será discutida no próximo tópico, em conjunto com outras variáveis.

5.6 Análise de correlações

Para a identificação de correlações entre variáveis, foram analisadas as matrizes de correlação geradas para as três cidades brasileiras. As Figuras 44 a 46

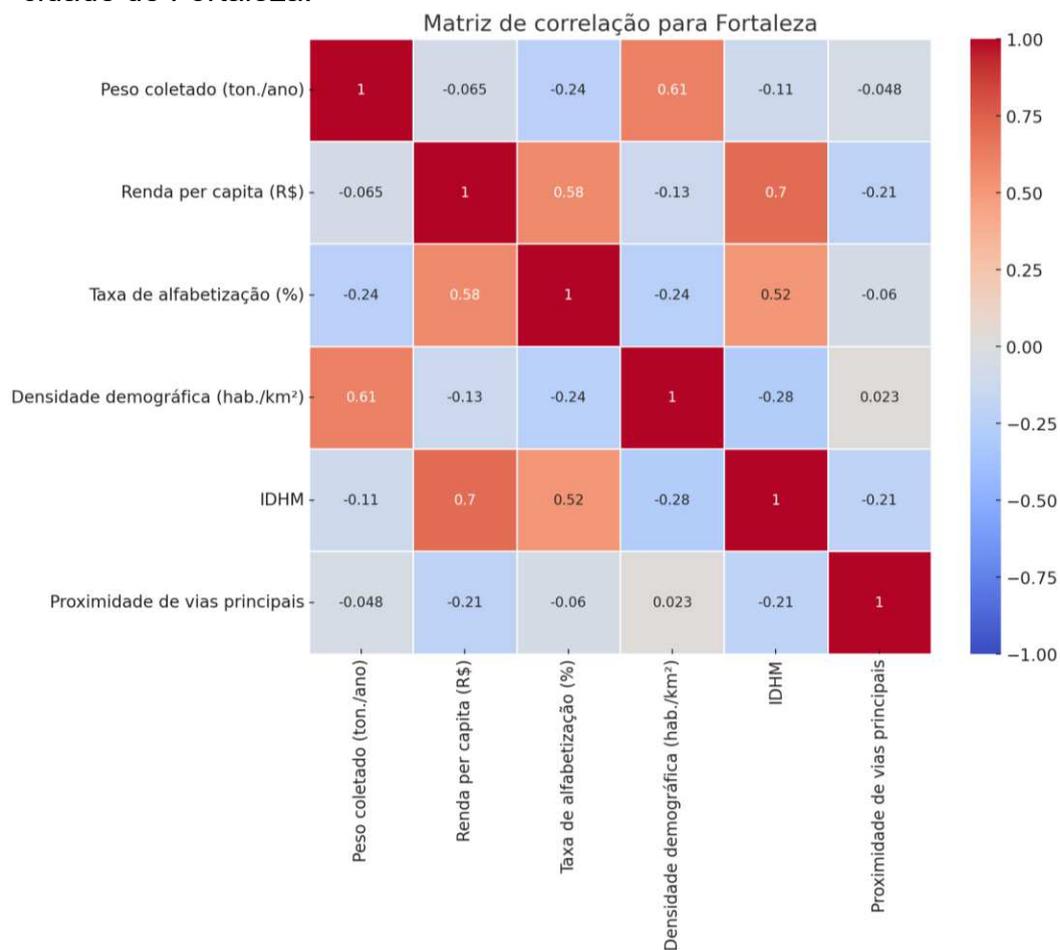
apresentam estas matrizes. O principal foco será na primeira linha de cada matriz, que retrata as correlações das demais variáveis com a variável dependente do estudo, o peso coletado por ecoponto.

Observou-se que a densidade demográfica apresentou uma correlação positiva e significativa com o peso coletado nos ecopontos em todas as cidades analisadas, indicando que áreas mais densamente povoadas tendem a gerar e coletar mais resíduos em seus ecopontos. Este padrão foi particularmente forte em Fortaleza (0,61) e Guarulhos (0,57). Esses resultados indicam que a densidade demográfica é uma variável determinante na quantidade de resíduos coletados nos ecopontos, mostrando uma relação consistente e significativa nas três cidades analisadas.

Nas três cidades analisadas, o IDHM apresenta correlações variadas com o peso coletado nos ecopontos. Em Belo Horizonte, a correlação é positiva (0,14), mas fraca, indicando uma ligeira tendência de que áreas com maior IDHM coletam mais resíduos. Já em Fortaleza, a correlação é levemente negativa (-0,11), sugerindo uma relação inversa ao observado em Belo Horizonte. Guarulhos apresenta uma correlação positiva moderada (0,26), indicando que áreas com maior IDHM coletam mais resíduos, mostrando uma relação mais perceptível entre o desenvolvimento humano e a quantidade de resíduos coletados.

Essas variações sugerem que, embora o IDHM tenha algum impacto na quantidade de resíduos coletados, sua influência pode diferir significativamente a depender de características locais e/ou culturais da cidade analisada.

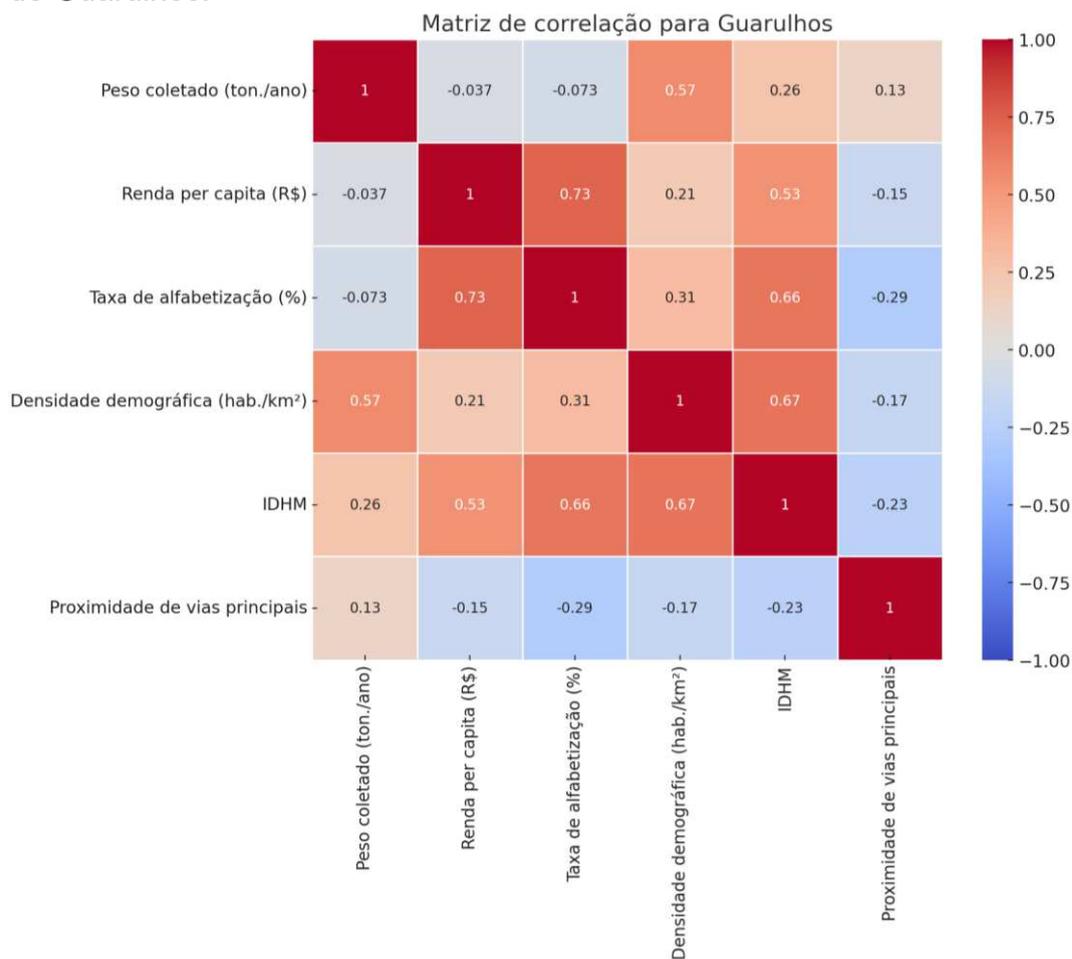
Figura 44 - Matriz de correlação entre as variáveis estudadas para a cidade de Fortaleza.



Fonte: Elaborado pelo autor (2024).

Com relação às variáveis renda per capita e a taxa de alfabetização, estas mostraram correlações negativas com o peso coletado, embora menos intensas. Em Belo Horizonte, a renda per capita apresentou uma correlação negativa moderada (-0,21) com o peso coletado, sugerindo que áreas com menor renda tendem a gerar mais resíduos. A taxa de alfabetização também mostrou uma relação negativa, com áreas com taxas menores de alfabetização coletando mais resíduos, especialmente em Fortaleza (-0,24).

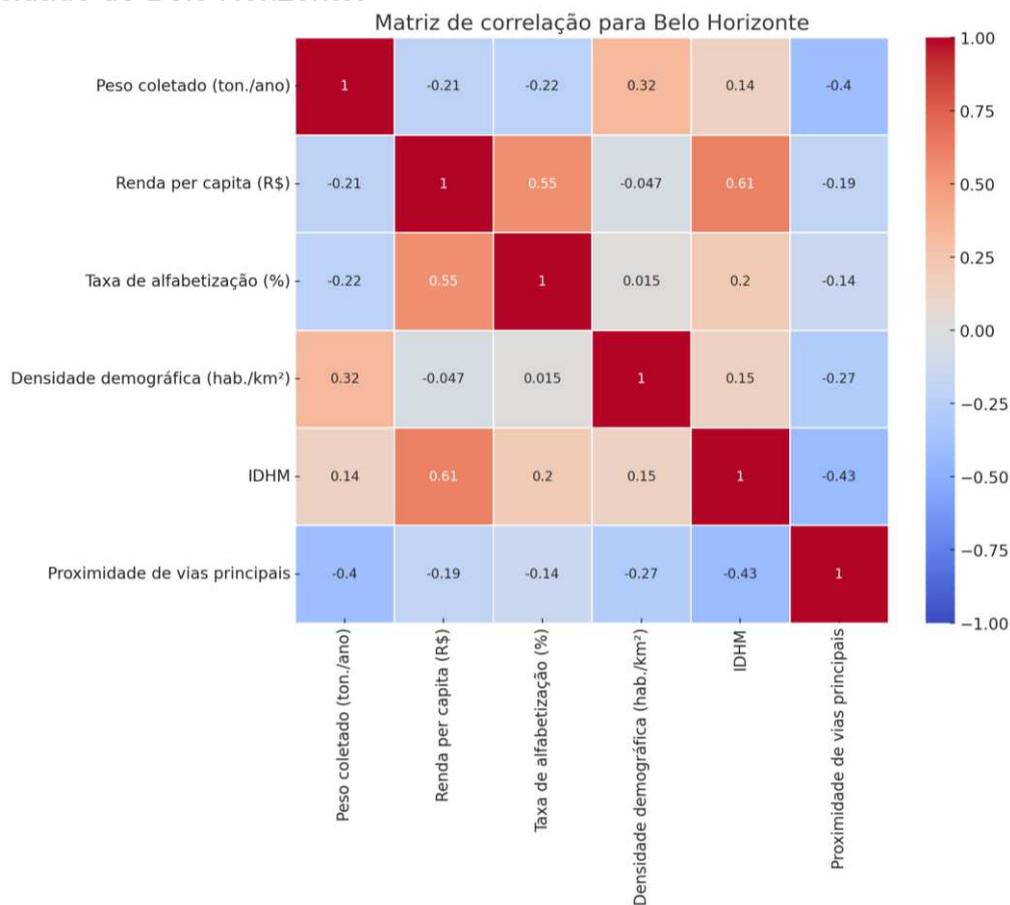
Figura 45 - Matriz de correlação entre as variáveis estudadas para a cidade de Guarulhos.



Fonte: Elaborado pelo autor (2024).

Por fim, a proximidade de vias principais apresenta correlações diferentes com o peso coletado nos ecopontos nas três cidades analisadas. Em Belo Horizonte, a correlação é negativa moderada (-0.4), indicando que ecopontos mais afastados de vias principais tendem a coletar mais resíduos. Em Fortaleza, a correlação é quase nula (-0.048), sugerindo que a proximidade de vias principais possui pouca ou nenhuma relação com a quantidade de resíduos coletados. Em Guarulhos, a correlação é levemente positiva (0.13), indicando que ecopontos mais próximos de vias principais coletam ligeiramente mais resíduos. Essas variações indicam que, assim como o IDHM, a influência da variável proximidade de vias principais pode ser diversa e dependente de fatores contextuais específicos de cada cidade, não apresentando um comportamento uniforme.

Figura 46 - Matriz de correlação entre as variáveis estudadas para a cidade de Belo Horizonte.



Fonte: Elaborado pelo autor (2024).

Após analisar todas estas observações estatísticas, foi possível realizar a seleção das variáveis mais relevantes para o modelo preditivo inicial. Foram selecionadas as variáveis densidade demográfica, IDHM e proximidade de vias.

A escolha da densidade demográfica se deve à alta correlação observada nas três cidades e às análises dos mapas apresentados no tópico anterior, confirmando que esta variável é bastante relevante na coleta de resíduos nos ecopontos.

Por outro lado, a escolha do IDHM como variável do modelo em detrimento da taxa de alfabetização e da renda per capita é justificada pela alta correlação entre estas variáveis. Considerando que o IDHM incorpora em sua composição tanto a renda quanto a taxa de alfabetização, as altas correlações observadas do IDHM nas três cidades com estas variáveis são prontamente justificadas por este motivo. Portanto, ao utilizar o IDHM, estamos essencialmente considerando a influência de

ambas as variáveis de forma integrada, além de reduzir a redundância de variáveis correlacionadas, o que minimiza problemas de multicolinearidade e simplifica o modelo.

Por fim, embora sem apresentar uma correlação consistente nas três cidades, a variável proximidade de vias principais também foi considerada no desenvolvimento do modelo devido à acessibilidade do ecoponto ser um fator relevante. Ao desconsiderar esta variável, poderiam existir áreas inacessíveis, como parques e regiões de mata nativa, que seriam classificadas como adequadas para a instalação de ecopontos. Desta forma, esta variável é adicionada ao modelo principalmente como um parâmetro construtivo, e não como uma variável que afeta positiva ou negativamente a quantidade de resíduos coletados.

5.7 Modelo determinístico

Tendo sido selecionadas as variáveis para o desenvolvimento deste modelo, inicialmente procedeu-se à preparação destes dados. As camadas referentes à densidade demográfica e IDHM foram normalizadas e classificadas em cinco classes (1 a 5), onde cada classe possui o mesmo número de dados e um número maior indica uma maior densidade e maior IDHM. Por fim, estas camadas reclassificadas foram rasterizadas.

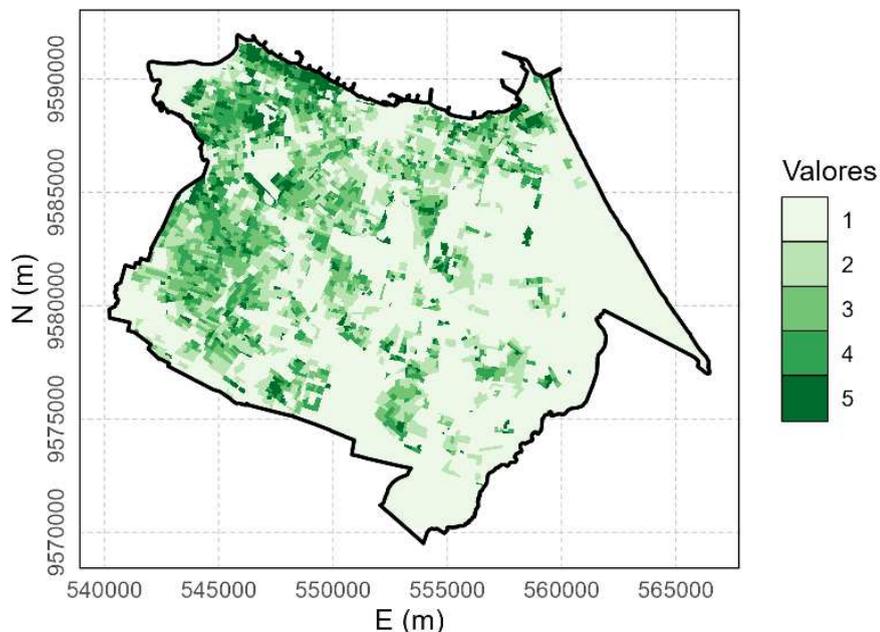
O procedimento referente à camada com as vias principais foi ligeiramente diferente, tendo em vista de se tratar de uma camada de linhas. Foi criado um raster de proximidade, onde o valor de cada pixel corresponde à distância em linha reta até a via mais próxima. Este raster foi reclassificado atribuindo as mesmas cinco classes, onde quanto mais próximo de uma via principal maior é o valor. A reclassificação foi baseada na análise das Figuras 42 e 43 e os intervalos definidos para esta variável foram:

- a) 5: de 0 a 50 metros;
- b) 4: de 50 a 100 metros;
- c) 3: de 100 a 200 metros;
- d) 4: de 200 a 300 metros;
- e) 1: acima de 300 metros.

As Figuras 47 a 49 mostram a visualização final de cada uma das camadas de entrada do modelo.

Figura 47 - Representação da variável densidade demográfica para o modelo determinístico.

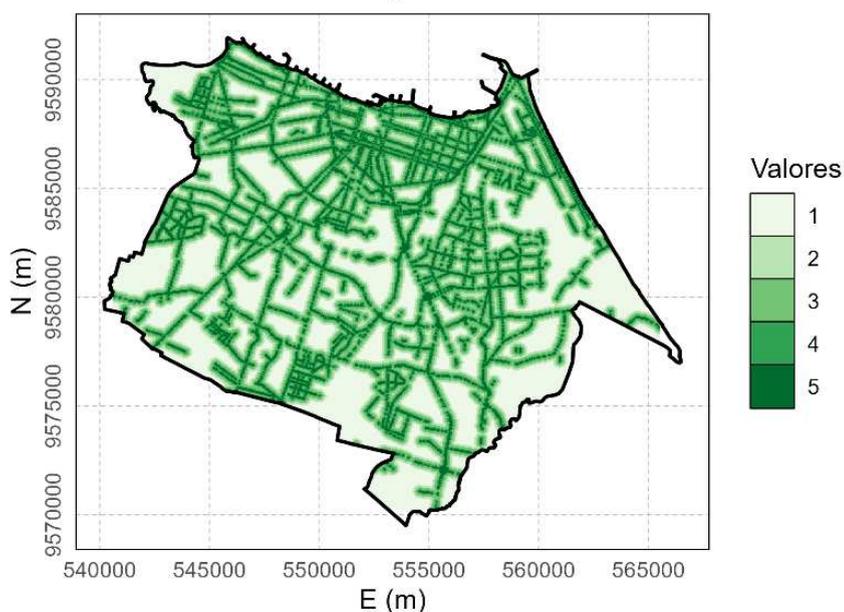
Fortaleza - Variável densidade demográfica



Fonte: Elaborado pelo autor (2024).

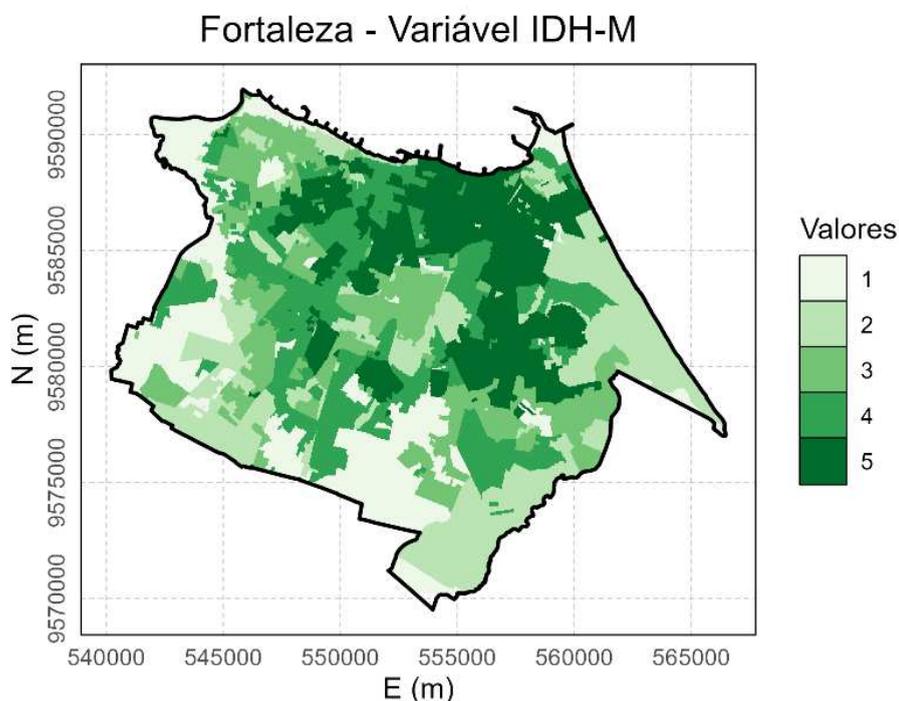
Figura 48 - Representação da variável proximidade de vias para o modelo determinístico.

Fortaleza - Variável proximidade de vias



Fonte: Elaborado pelo autor (2024).

Figura 49 - Representação da variável IDH-M para o modelo determinístico.



Fonte: Elaborado pelo autor (2024).

Os cenários de contorno definidos para o modelo com três variáveis foram definidos da seguinte forma para a cidade de Fortaleza, conforme a Tabela 8 abaixo.

Tabela 8 - Cenários de contorno do modelo determinístico com três variáveis para a cidade de Fortaleza/CE.

Cenários	Cenário 1 (excelente)	Cenário 2 (bom)	Cenário 3 (ruim)	Cenário 4 (péssimo)
Nota final	10	7	3	0
Classe densidade demográfica	5	4	2	1
Classe IDHM	1	3	4	5
Classe proximidade de vias	5	3	2	1

Fonte: Elaborado pelo autor (2024).

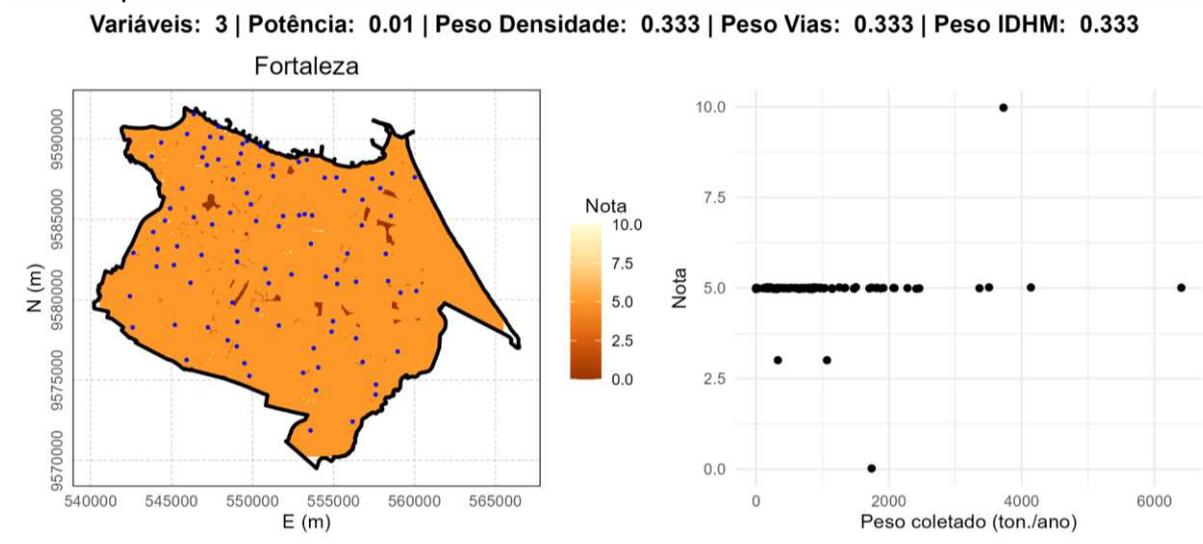
O cenário 1 indica o melhor cenário (nota máxima, 10) para instalação de ecopontos. Neste cenário, foi definido que esta área possui uma densidade demográfica alta, um IDHM baixo e com vias principais a até 50 metros de distância.

Da mesma forma, o cenário 4 indica o pior cenário (nota mínima, 0) para uma área receber um ecoponto.

Importante destacar que estes cenários foram desenhados para a cidade de Fortaleza e as notas atribuídas possuem embasamento nas análises estatísticas realizadas nos tópicos anteriores, como por exemplo o fato do IDHM ter uma correlação negativa com o peso coletado nesta cidade. Assim como o coeficiente atribuído para cada variável, estas notas são subjetivas e podem ser alteradas pelo gestor ou tomador de decisão.

Após estas definições, foram realizadas simulações para avaliar o impacto dos pesos e da potência nas notas finais. Para avaliar o impacto da potência, foram realizadas simulações com o mesmo peso padrão de 0,333 para cada variável e potências 0,01 - 0,1 - 1 - 2 - 5 -10. Os resultados destas simulações estão apresentados nas Figuras 50 a 55, onde temos à esquerda o mapa com todas as áreas da cidade classificadas com notas variando de 0 a 10 e à direita o gráfico de dispersão cruzando o peso coletado em toneladas por ano em cada ecoponto com a nota prevista para aquela área.

Figura 50 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 0,01. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.



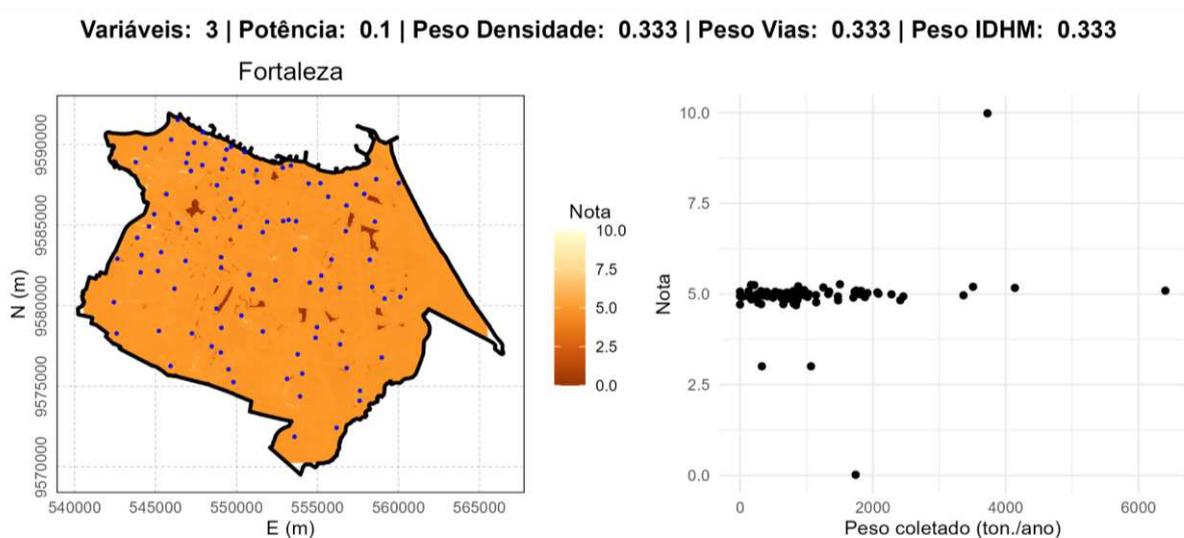
Fonte: Elaborado pelo autor (2024).

Para a potência 0,01, as notas previstas são quase constantes em toda a área, com mínimas variações. Isso ocorre porque a influência da distância é quase

nula, resultando em um mapa que praticamente reflete uma média global das variáveis, praticamente sem variações locais.

Para a potência 0,1 as notas ainda apresentam pouca variação, mas já se observa um leve aumento de influência da proximidade. As diferenças ainda são mínimas e o padrão é relativamente uniforme, indicando que a distância de um ponto P qualquer até os cenários definidos tem uma influência muito baixa nas notas.

Figura 51 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 0,1. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.



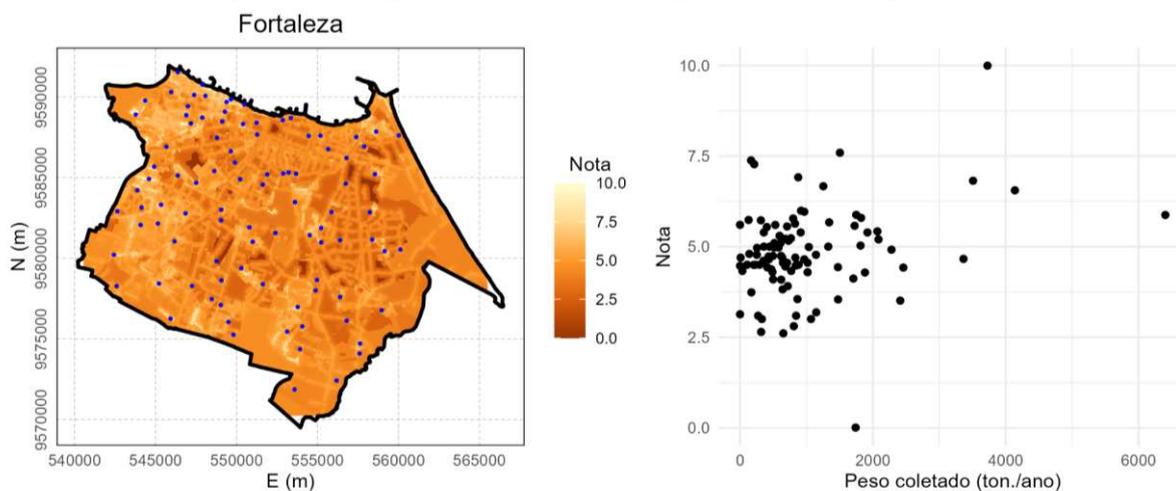
Fonte: Elaborado pelo autor (2024).

Com a potência 1, as notas começam a variar de maneira mais perceptível conforme a distância dos pontos até os cenários começa a ter maior influência. As áreas mais próximas aos pontos com cenários conhecidos apresentam notas diferentes, refletindo a variação das variáveis locais.

Continuando a tendência, a influência da distância é mais pronunciada quando utilizamos potência 2. As notas variam significativamente com a proximidade dos pontos, e as áreas próximas aos pontos com cenários conhecidos têm notas consideravelmente diferentes das áreas mais distantes. Isso mostra uma distribuição mais granular das notas previstas.

Figura 52 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 1. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.

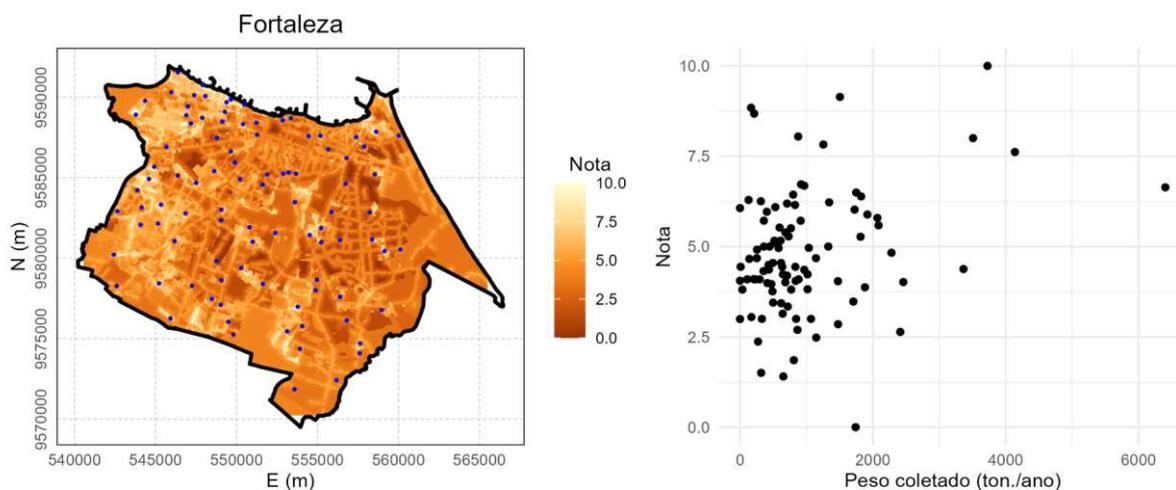
Variáveis: 3 | Potência: 1 | Peso Densidade: 0.333 | Peso Vias: 0.333 | Peso IDHM: 0.333



Fonte: Elaborado pelo autor (2024).

Figura 53 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 2. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.

Variáveis: 3 | Potência: 2 | Peso Densidade: 0.333 | Peso Vias: 0.333 | Peso IDHM: 0.333



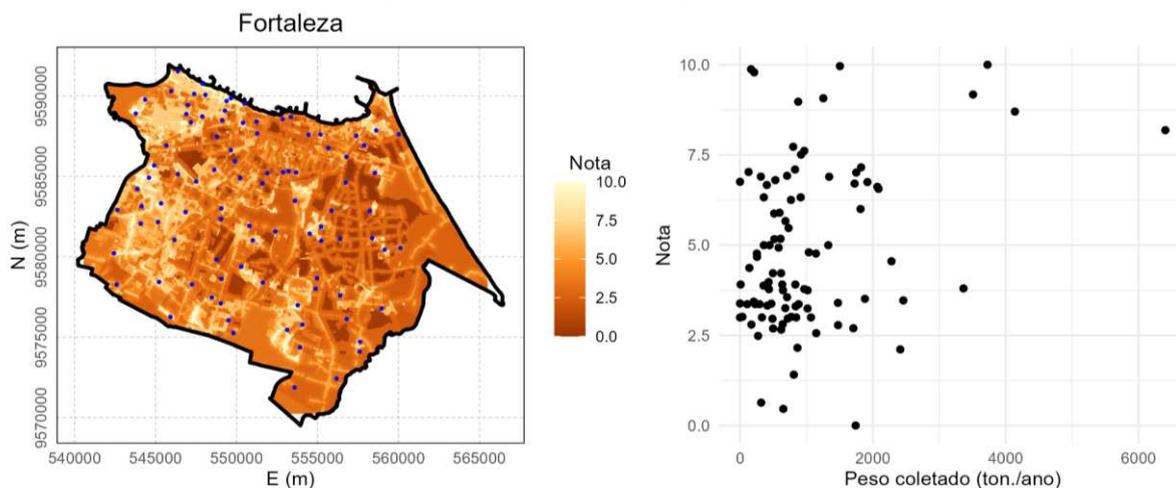
Fonte: Elaborado pelo autor (2024).

Já na potência 5, a influência da proximidade é ainda mais acentuada. As áreas próximas aos pontos têm notas muito diferentes das áreas distantes, e a granularidade é alta. Esse valor de potência começa a destacar bem as diferenças locais.

Por fim, na potência 10 a granularidade pode ser considerada máxima, com as notas variando drasticamente conforme a proximidade dos pontos com notas conhecidas.

Figura 54 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 5. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.

Variáveis: 3 | Potência: 5 | Peso Densidade: 0.333 | Peso Vias: 0.333 | Peso IDHM: 0.333

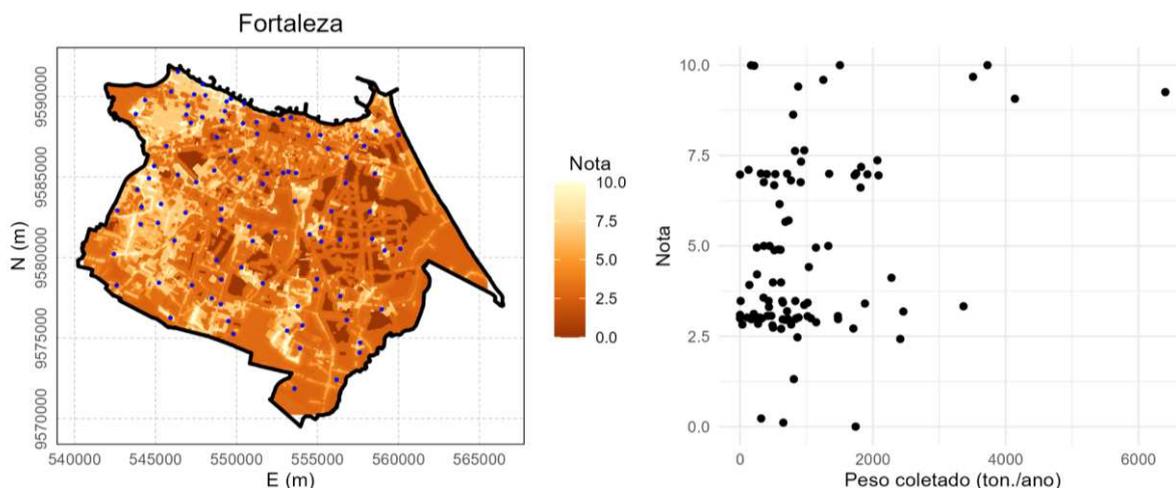


Fonte: Elaborado pelo autor (2024).

Desta forma, pode-se concluir que a análise dos resultados obtidos com o método determinístico retrata com clareza a influência da potência nas notas previstas. Quando a potência é muito baixa (0.01 e 0.1), a variação nas notas é mínima, indicando que a distância entre um ponto P qualquer e os cenários definidos têm pouca influência. Esse cenário é útil para uma análise global, mas falha em capturar variações locais.

Figura 55 - À esquerda, mapa de Fortaleza classificado com notas de 0 a 10 utilizando potência 10. À direita, gráfico de dispersão com o peso coletado e as notas previstas dos ecopontos.

Variáveis: 3 | Potência: 10 | Peso Densidade: 0.333 | Peso Vias: 0.333 | Peso IDHM: 0.333



Fonte: Elaborado pelo autor (2024).

Por outro lado, ao utilizar potências moderadas (entre 1 e 2), as notas começam a variar de maneira mais perceptível conforme a distância de um ponto P para os cenários aumenta a sua influência. Este intervalo de potência captura bem as variações locais ao balancear a influência da distância sem exagerar na granularidade, sendo ideal para análises que precisam considerar a proximidade sem perder a visão geral do contexto urbano.

À medida que a potência aumenta ainda mais (5 a 10), a influência da distância se torna muito forte, resultando em uma granularidade máxima. Nessas configurações, as áreas próximas aos pontos com cenários conhecidos apresentam notas muito diferentes das áreas mais distantes, criando um efeito de "ilhas" de notas altas e baixas. Em outras palavras, pontos muito próximos aos pontos conhecidos obtêm notas diferentes, que variam consideravelmente em comparação com as notas de áreas mais afastadas. Esse efeito de "ilhas" indica que as notas se concentram em áreas específicas ao redor de pontos com notas conhecidas a partir dos cenários (0, 3, 7 e 10). Esse nível de granularidade pode ser útil para identificar *hotspots* ou áreas críticas específicas, mas perde o panorama geral e cria variações extremas.

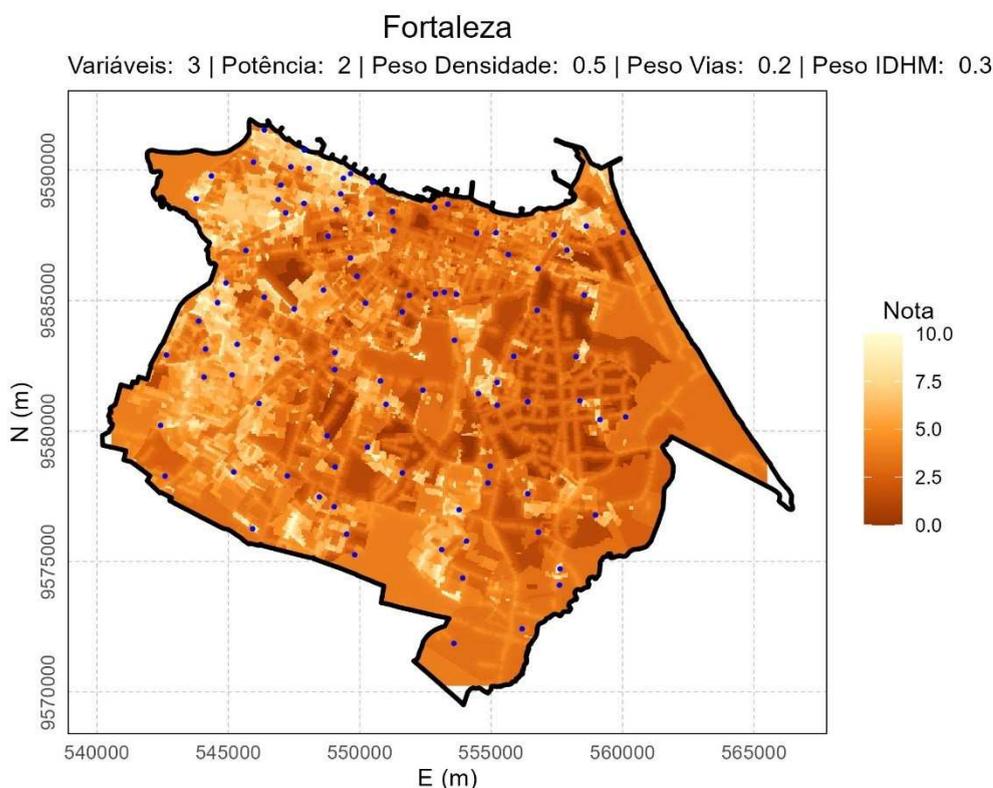
Desta forma, podemos extrair duas recomendações principais de escolha de potência a partir destas análises dos mapas e gráficos de dispersão. A primeira recomendação é que, para uma visualização mais equilibrada, potências moderadas

(entre 1 e 2) trarão melhores resultados, pois proporcionam um balanço entre a variação local e a perspectiva global. A segunda recomendação é referente às análises mais detalhadas ou voltadas para identificação de áreas críticas, onde potências mais altas podem ser mais úteis, apesar de poderem causar exageros nas variações locais.

Após analisar e descrever a influência da potência nas notas, foram realizadas simulações nas três cidades para melhor visualizar o funcionamento do modelo. Foram utilizados os seguintes parâmetros:

- a) Variáveis: 3
- b) Potência: 2
- c) Peso variável 1 (densidade demográfica): 0,5
- d) Peso variável 2 (proximidade de vias): 0,2
- e) Peso variável 3 (IDHM): 0,3

Figura 56 - Mapa de classificação de áreas para instalação de ecopontos em Fortaleza baseado na nota atribuída pelo modelo determinístico.



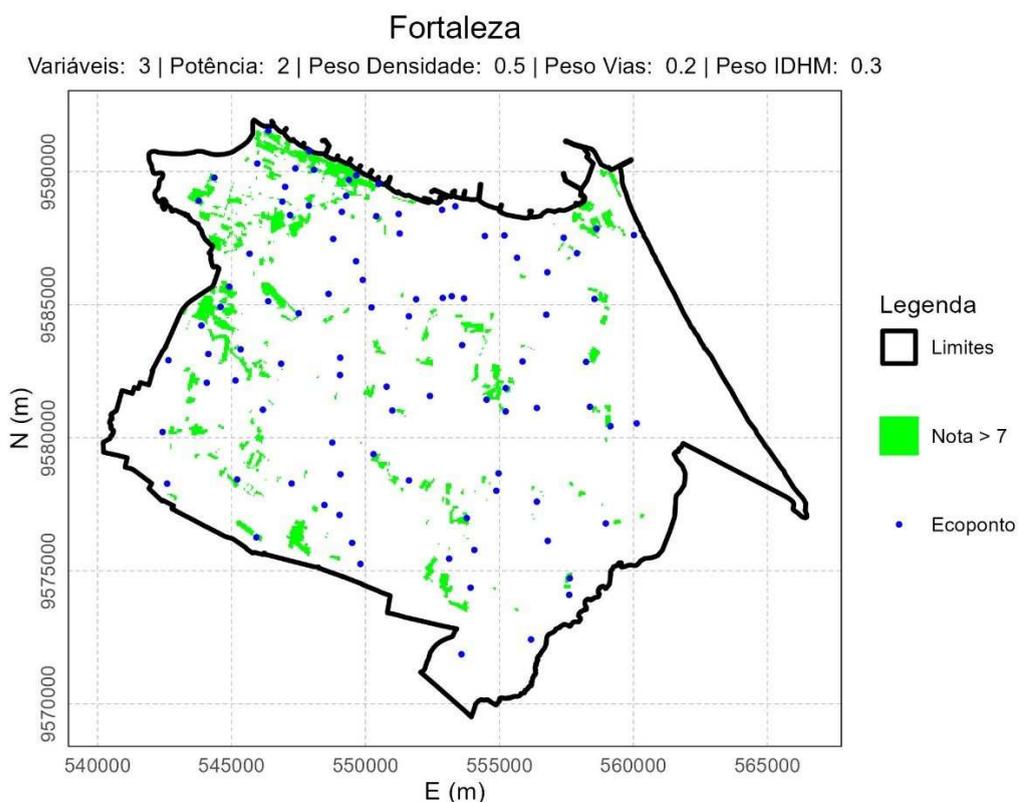
Fonte: Elaborado pelo autor (2024).

Tons mais claros indicam notas maiores, que representam áreas mais adequadas para instalação de novos ecopontos. Figura 56 acima apresenta a primeira simulação.

Pela inspeção visual do mapa, podemos perceber que as áreas mais claras estão concentradas na porção oeste e noroeste da cidade de Fortaleza, o que coincide com os ecopontos que mais coletam resíduos conforme apresentado na Figura 56. Para facilitar a visualização das áreas mais adequadas, foi gerado um novo mapa, apresentado na Figura 57, que filtra as notas maiores que sete e cruza com a localização dos ecopontos atuais.

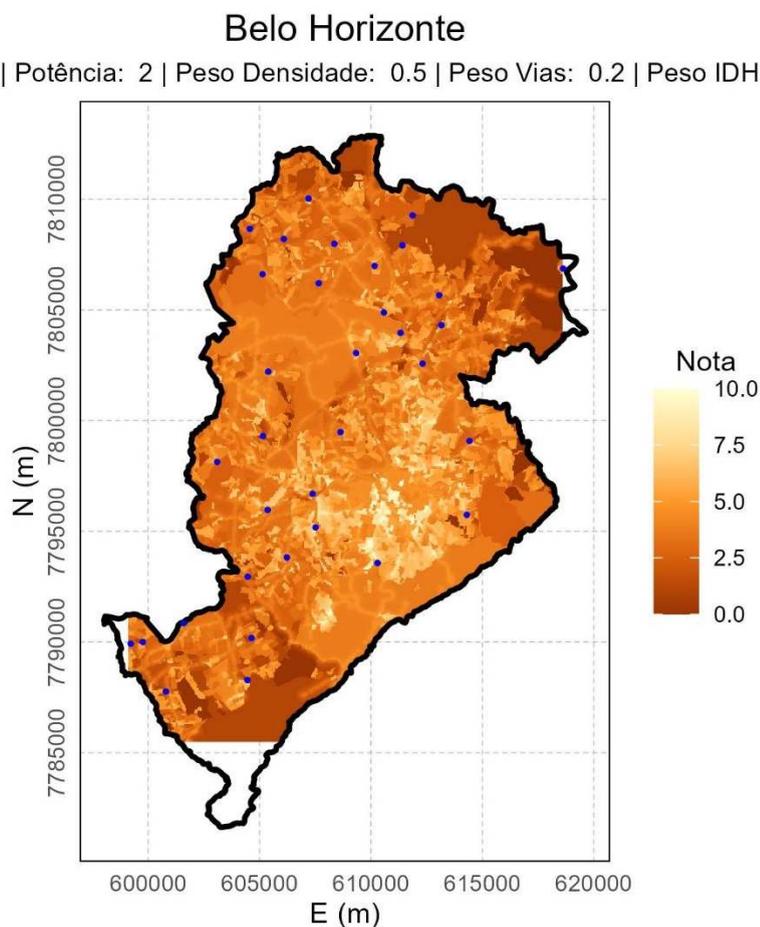
A análise deste mapa reforça a hipótese de que Fortaleza está em um certo estágio de saturação em relação à quantidade de ecopontos, tendo em vista que praticamente todas as áreas classificadas com nota sete ou superior possuem um ou mais ecopontos nas suas redondezas.

Figura 57 - Mapa de classificação de áreas com nota acima de sete para instalação de ecopontos em Fortaleza baseado na nota atribuída pelo modelo determinístico.



Fonte: Elaborado pelo autor (2024).

Figura 58 - Mapa de classificação de áreas adequadas para instalação de ecopontos em Belo Horizonte baseado na nota atribuída pelo modelo determinístico.



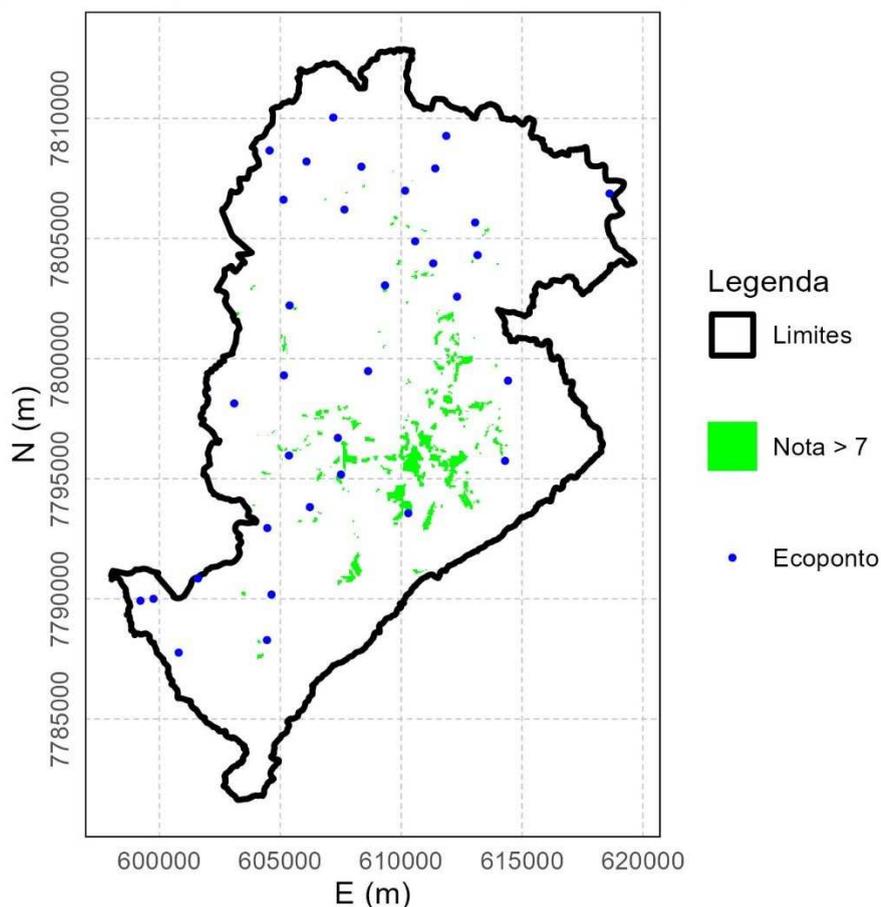
Fonte: Elaborado pelo autor (2024).

Em análise similar, foram gerados os mapas apresentados nas Figuras Figura 58 e Figura 59 para a cidade de Belo Horizonte. Os cenários de contorno utilizados foram os mesmos apresentados na Tabela 8, com apenas uma alteração na variável IDHM, onde a realizada a inversão (de 1 para 5). As Figuras indicam que, diferentemente de Fortaleza, existem áreas classificadas com notas superiores a sete em Belo Horizonte e que não possuem ecopontos próximos. Estas áreas estão concentradas na região central da cidade.

Figura 59 - Mapa de classificação de áreas com nota acima de sete para instalação de ecopontos em Belo Horizonte baseado na nota atribuída pelo modelo determinístico.

Belo Horizonte

Variáveis: 3 | Potência: 2 | Peso Densidade: 0.5 | Peso Vias: 0.2 | Peso IDHM: 0.3



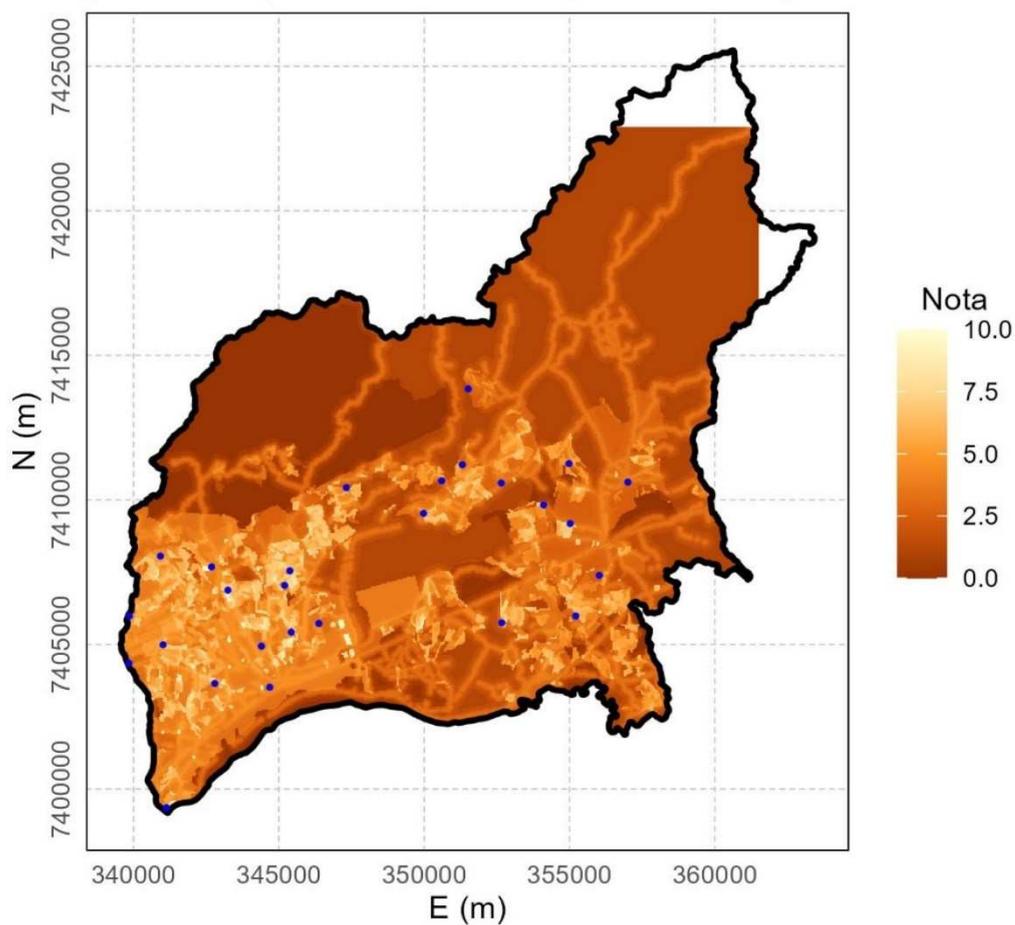
Fonte: Elaborado pelo autor (2024).

Por fim, para a simulação em Guarulhos com o mesmo cenário de contorno de Belo Horizonte, foram gerados os mapas apresentados nas Figuras 60 e 61 que indicam que também existem áreas classificadas com notas superiores a sete e que não possuem ecopontos próximos, embora em menor quantidade em comparação à Belo Horizonte.

Figura 60 - Mapa de classificação de áreas adequadas para instalação de ecopontos em Guarulhos baseado na nota atribuída pelo modelo determinístico.

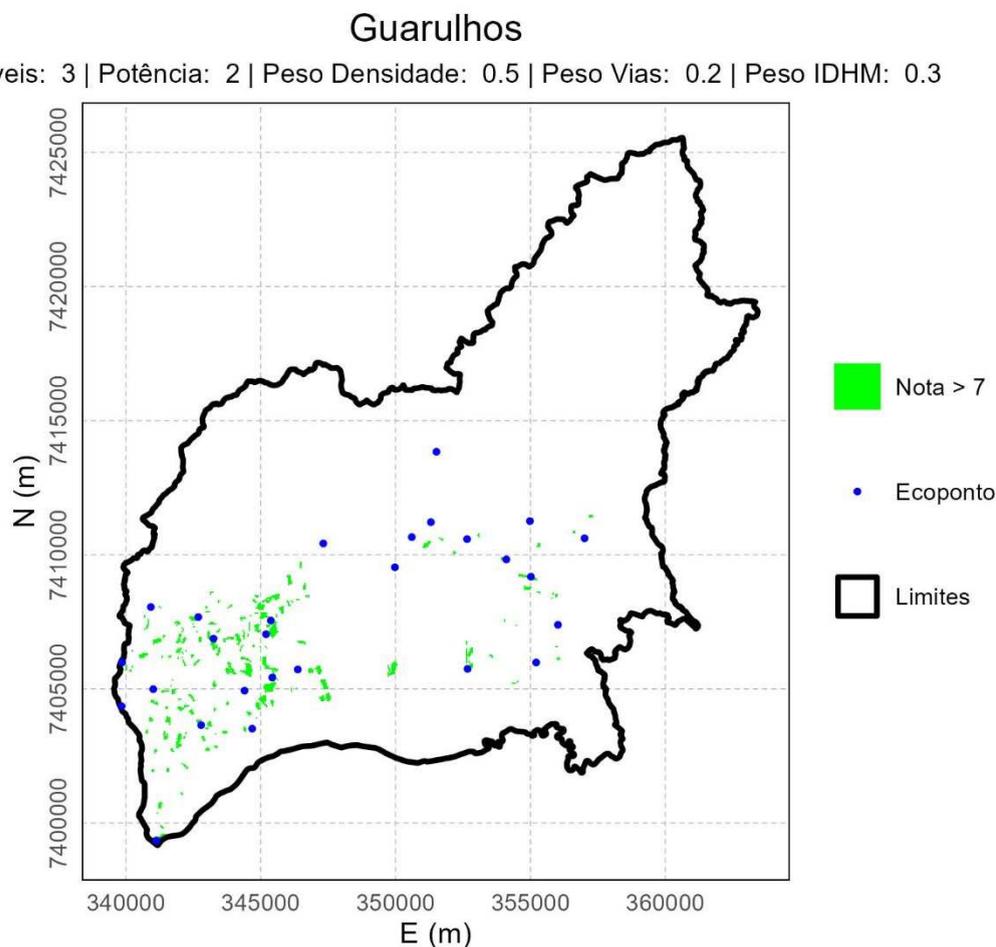
Guarulhos

Variáveis: 3 | Potência: 2 | Peso Densidade: 0.5 | Peso Vias: 0.2 | Peso IDHM: 0.3



Fonte: Elaborado pelo autor (2024).

Figura 61 - Mapa de classificação de áreas com nota acima de sete para instalação de ecopontos em Guarulhos baseado na nota atribuída pelo modelo determinístico.



Fonte: Elaborado pelo autor (2024).

Este modelo desenvolvido permite aos gestores realizarem análises espaciais utilizando camadas de dados georreferenciados acessíveis para a grande maioria dos centros urbanos brasileiros. Este modelo é particularmente vantajoso porque não depende da existência prévia de ecopontos na cidade.

Outra vantagem deste modelo é sua capacidade de incorporar características locais nas análises, permitindo ao gestor atribuir notas específicas aos cenários e pesos específicos às variáveis de acordo com a realidade de cada cidade.

Importante destacar que este método não tem como objetivo atingir o melhor ajuste aos valores observados, mas sim permitir acesso ao gestor à uma ferramenta simplificada, de fácil uso e entendimento, e que leve em consideração as variáveis determinantes. O ajuste aos valores observados de peso de resíduos

coletados, analisando o R^2 e outros parâmetros, foi realizado através de modelo de regressão linear, discutido no próximo tópico.

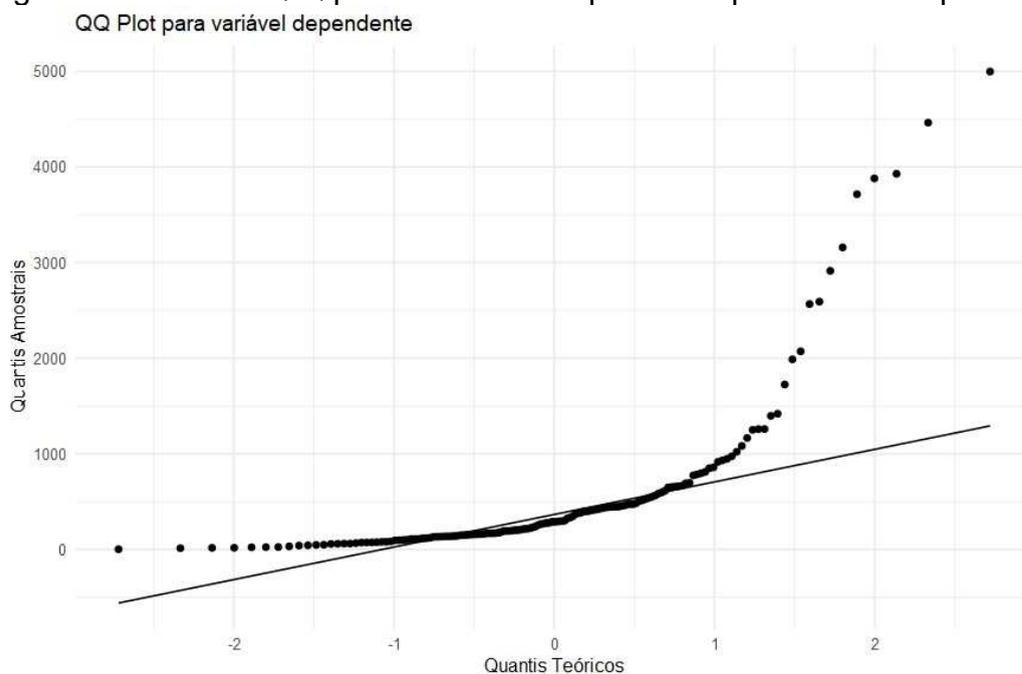
5.8 Modelo de regressão linear

No desenvolvimento do modelo baseado em regressão linear, observou-se que os dados da variável dependente (peso coletado por área) não poderiam ser considerados normalizados, que é um dos requisitos para a regressão linear. A

Figura 62 apresenta um gráfico que mostra este padrão não-normal dos dados, que é evidenciado pela falta de adequação dos pontos à linha.

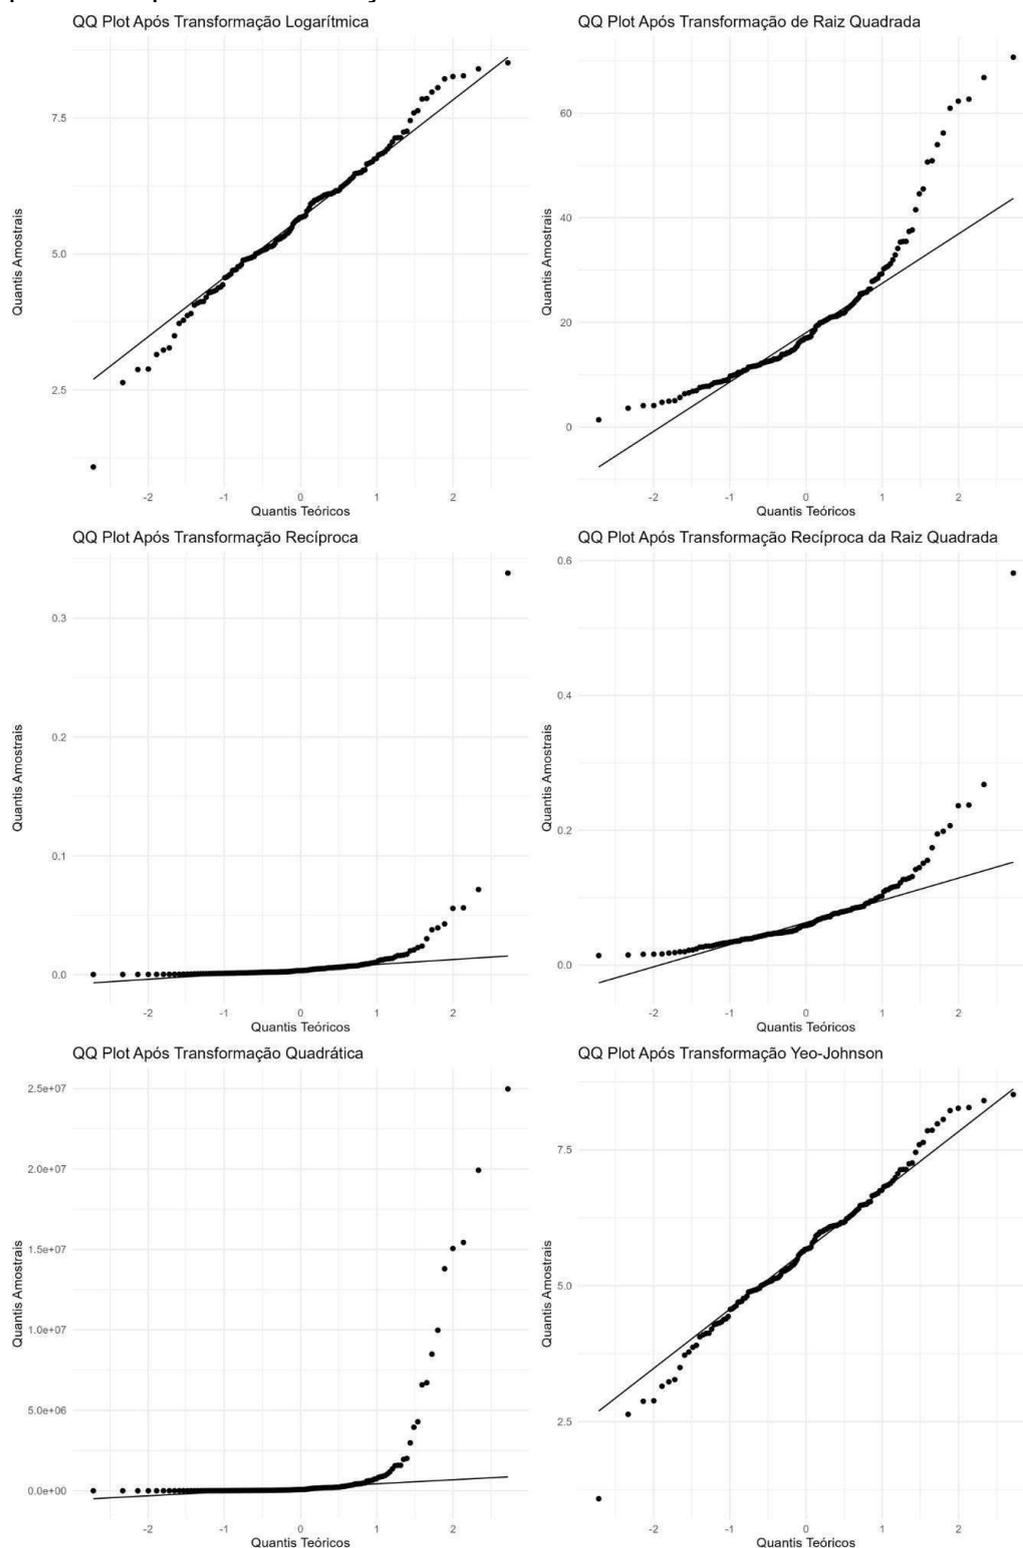
Desta forma, foi necessário a realização de testes de transformações de dados para melhorar a adequação do modelo. Dentre todas as transformações realizadas e apresentadas na Figura 63, a transformação logarítmica foi a selecionada como a mais adequada, proporcionando uma distribuição mais próxima da normalidade.

Figura 62 - Gráfico Q-Q para a variável dependente peso coletado por área.



Fonte: Elaborado pelo autor (2024).

Figura 63 - Gráficos Q-Q com as transformações realizadas na variável dependente para normalização dos dados.



Fonte: Elaborado pelo autor (2024).

Logo em seguida, prosseguiu-se para a seleção de variáveis independentes para o modelo linear. A análise dos gráficos de dispersão entre todas

as variáveis independentes e a variável dependente auxiliou na identificação das variáveis mais relevantes para o modelo e seus padrões de comportamento.

Mesmo aplicando todos os testes de transformações nos dados, não foi possível identificar padrões nos gráficos das variáveis IDHM, densidade de estabelecimentos de educação, renda per capita e taxa de alfabetização, considerando todos os ecopontos das três cidades estudadas.

Por outro lado, a variável densidade demográfica foi a que apresentou o maior coeficiente de determinação ($R^2 = 0,41$), sem necessidade de transformação nos dados. Observou-se uma tendência de maiores valores de peso por área à medida que ocorre um aumento da densidade demográfica.

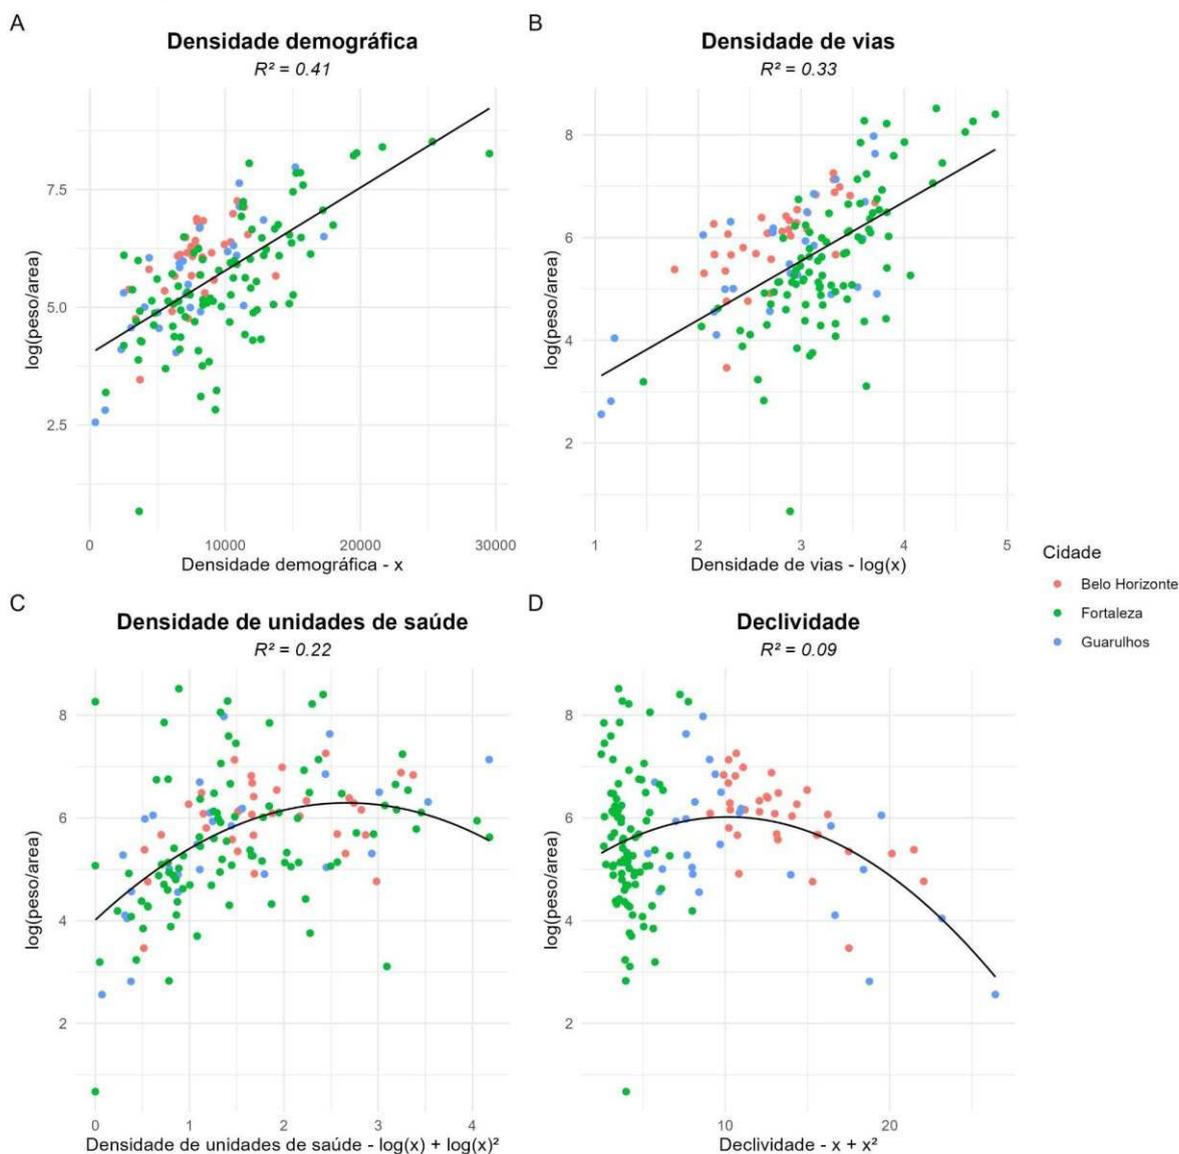
A variável densidade de vias foi a com segundo maior R^2 , com um valor de 0,33 ao utilizar a transformação logarítmica em seus valores. Observou-se a mesma tendência de maiores valores de peso por área à medida que ocorre um aumento da densidade de vias. A variável densidade de unidades de saúde apresentou um R^2 de 0,22 ao combinar a transformação logarítmica e polinomial.

Por fim, a variável declividade apresentou um R^2 de 0,09 com uma transformação polinomial. Foi possível observar que regiões com declividades maiores possuem uma tendência de menores pesos de resíduos coletados por área. Através da dispersão dos pontos no gráfico, foi possível concluir que a cidade de Fortaleza, por apresentar uma baixa variação nos valores de declividade, fez com que o coeficiente de determinação apresentasse um valor mais baixo. Ao analisar isoladamente as cidades de Guarulhos e Belo Horizonte, foi observado um R^2 de 0,40 e 0,36 respectivamente, o que evidencia a relevância desta variável.

Os gráficos de dispersão destas quatro variáveis estão apresentados na Figura 64.

Figura 64 - Gráficos de dispersão entre a variável dependente e as variáveis densidade demográfica (A), densidade de vias (B), densidade de unidades de saúde (C) e declividade (D).

Gráficos de dispersão das variáveis independentes



Fonte: Elaborado pelo autor (2024).

Após todas as etapas de desenvolvimento, o resultado foi um modelo de quatro variáveis e que apresentou um p-valor de $2,2 \cdot 10^{-16}$ e um coeficiente de determinação final de 0,5824. Este p-valor, menor que 0,05, indica que este modelo possui capacidade de predição, enquanto o R^2 indica que cerca de 58% da variação dos dados é explicada pelo modelo.

O modelo final de regressão linear múltipla foi definido pela seguinte equação:

$$\begin{aligned} \log(P) = & -0.6629205 + 0.0001166 * DD + 0.2043399 * DC - \\ & 0.0062927 * DC^2 + 0.6845790 * \log(DV) + 0.8104412 * \log(DS) - \\ & 0.1492219 * \log(DS)^2 \end{aligned} \quad (8)$$

Onde:

P é a variável dependente peso coletado por área;

DD é a variável densidade demográfica;

DC é a variável declividade;

DV é a variável densidade de vias;

DS é a variável densidade de unidades de saúde.

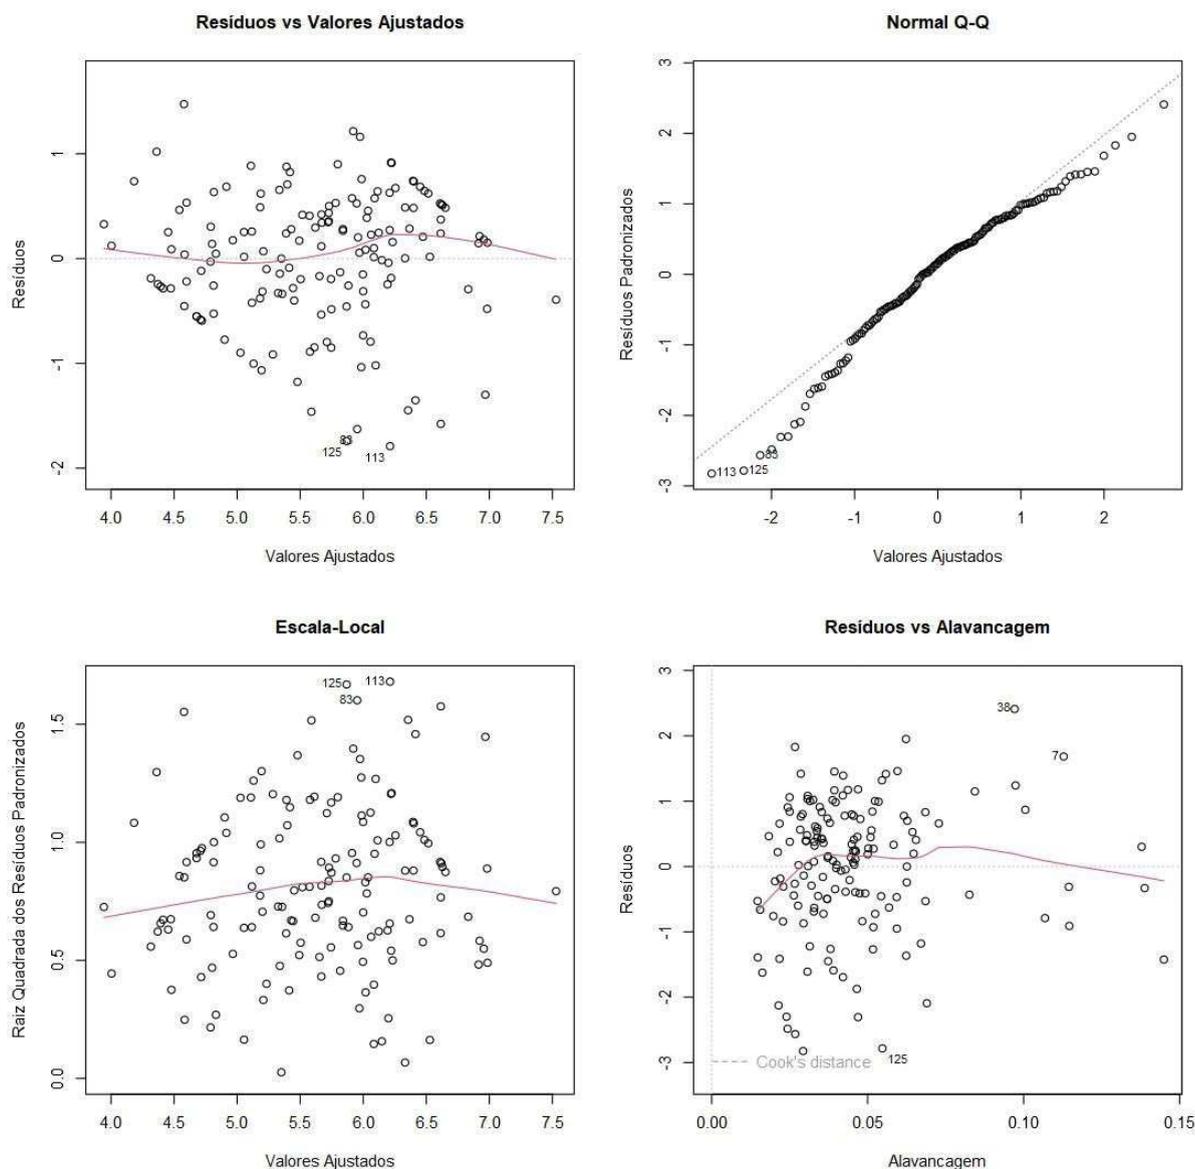
Logo em seguida, os gráficos de diagnóstico deste modelo, dispostos na Figura 65, foram analisados.

No gráfico de resíduos por valores ajustados, foi observado a existência de uma leve curvatura, o que pode sugerir a presença de alguma não linearidade que não foi capturada pelo modelo.

No gráfico Q-Q normal, os pontos seguem a linha diagonal com algumas pequenas divergências nas extremidades, indicando que os resíduos são aproximadamente normais, com pequenas violações nas caudas.

No gráfico de escala-local, foi observado aleatoriedade nos pontos em torno da linha horizontal central, sugerindo homoscedasticidade. Por fim, no gráfico de resíduos por alavancagem, há poucas observações com alta alavancagem.

Figura 65 - Gráficos de diagnóstico de ajuste do modelo linear final.



Fonte: Elaborado pelo autor (2024).

Além destas análises dos gráficos, foram realizados testes de pressupostos da regressão linear.

Ao submeter os resíduos ao teste de normalidade de Shapiro-Wilk, observou-se que a hipótese de normalidade foi rejeitada ao se obter um p-valor inferior a 0,05 ($7,043 \cdot 10^{-6}$). Embora a não-normalidade dos resíduos possa indicar possíveis desvios nos pressupostos do modelo, este fato não comprometeu de forma significativa a capacidade preditiva e a validade das inferências do modelo, conforme evidenciado pelas outras métricas de desempenho.

Apesar da rejeição no teste de normalidade, o modelo mostrou-se robusto, passando em todas as demais verificações. Para verificar a homoscedasticidade dos resíduos, foi aplicado o Teste de Breusch-Pagan, que apresentou um p-valor de 0,3479, confirmando a homoscedasticidade (valor esperado: p-valor > 0,05). O gráfico de resíduos versus valores ajustados mostrou uma distribuição aleatória dos resíduos, sem um padrão claro, indicando variância constante.

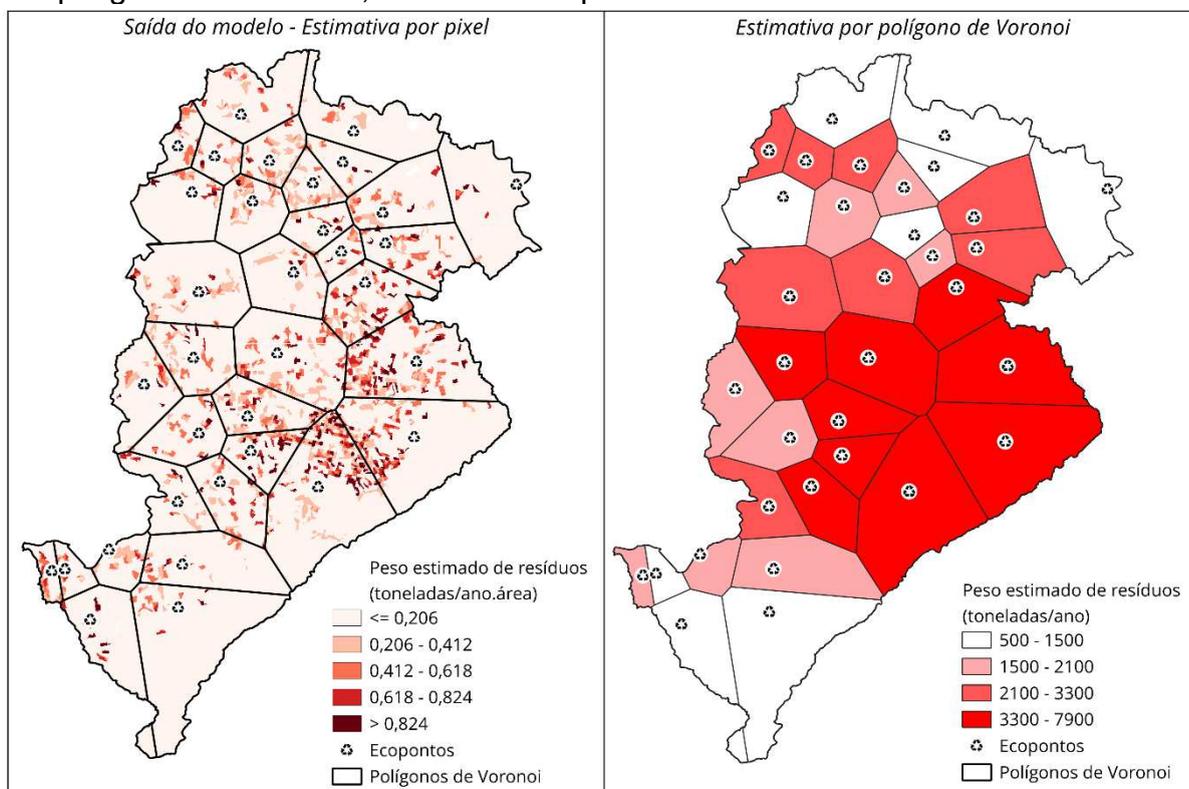
A independência dos resíduos foi testada com o Teste de Durbin-Watson, que resultou em um valor de 1,581, próximo ao valor ideal de 2 (valor esperado: entre 1,5 e 2,5). Por fim, para avaliar a ausência de multicolinearidade, foi calculado o Fator de Inflação da Variância (VIF) para cada variável independente, com todos os valores entre variáveis diferentes inferiores a 3,67 (valor esperado: VIF < 10, preferencialmente < 5), indicando a inexistência de problemas de multicolinearidade no modelo.

Por fim, foram gerados gráficos de dispersão entre os valores previstos para as cidades estudadas e os valores observados (Figura 67). É importante destacar que a saída do modelo é uma camada do tipo raster, onde cada pixel possui o valor estimado de peso de resíduo referente àquela área. Durante a geração da camada, é possível determinar as dimensões do pixel de saída (30m x 30m, 50m x 50m, 100m x 100m etc.). Quanto menor for este valor, maior o nível de detalhamento na camada de saída e maior o tempo de processamento para geração desta camada.

Desta forma, o valor estimado é a soma dos valores dos pixels internos da área de influência de cada ecoponto (neste estudo, definida como polígonos de Voronoi) da camada raster de saída do modelo, enquanto o valor observado é o valor efetivamente coletado no ecoponto relacionado àquele polígono de Voronoi.

A Figura 66 apresenta um exemplo desta dinâmica de previsão para a cidade de Belo Horizonte, onde o mapa à esquerda apresenta a previsão de peso de resíduos para áreas de 50m por 50m, enquanto o mapa à direita apresenta a previsão de peso de resíduos para cada área de influência dos ecopontos da cidade.

Figura 66 - Mapa representativo das formas de estimativa de peso de resíduos coletado com o modelo de regressão linear. À esquerda, a saída direta do modelo, com valores em toneladas por ano por área. À direita, somatória dos valores internos dos polígonos de Voronoi, em toneladas por ano.



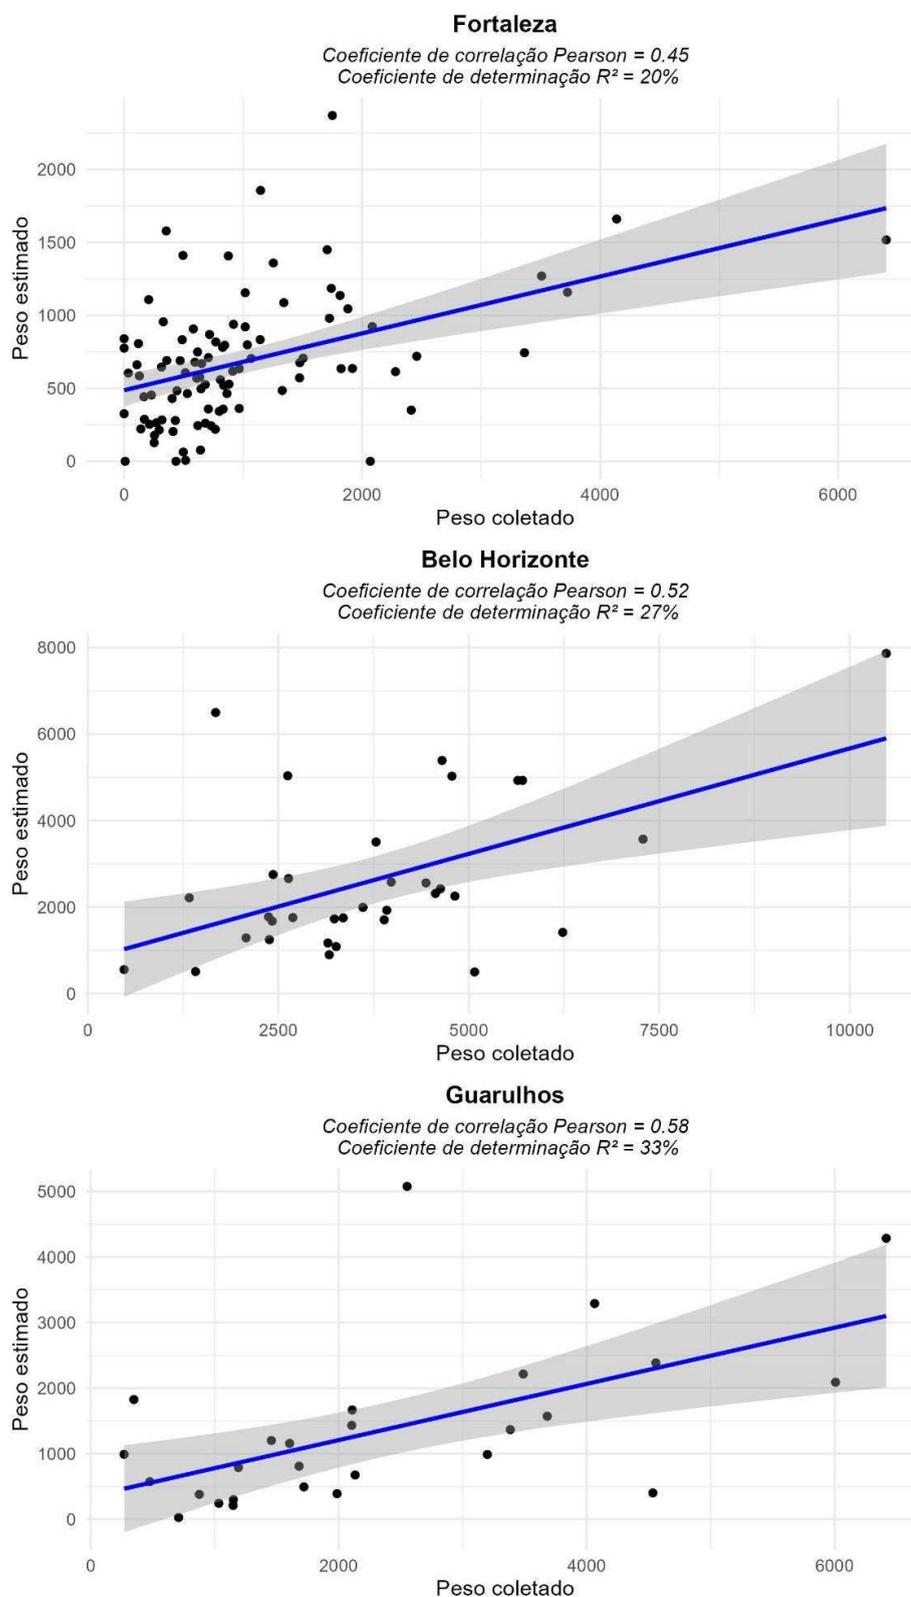
Fonte: Elaborado pelo autor (2024).

Ao analisar a Figura 67, é possível observar que, em todas as cidades, existe uma correlação positiva entre o peso coletado e o peso estimado, com a força dessa correlação variando entre 0,45 a 0,58. Guarulhos apresenta a maior correlação e coeficiente de determinação, sugerindo que o modelo de predição apresentou uma maior eficácia ao ser utilizado nesta cidade. Apesar da existência de alguns *outliers*, é possível perceber a tendência linear dos pontos, com a maioria dos valores dentro do intervalo de confiança (área em cinza).

Por sua vez, Fortaleza apresentou a menor correlação e coeficiente de determinação, indicando que o modelo é menos eficaz e que outras variáveis não consideradas no modelo podem estar impactando os resultados. A grande variação de pesos coletados entre ecopontos na cidade, constatado no item 5.2 desta pesquisa, pode ter contribuído para esta baixa eficácia do modelo.

Figura 67 - Gráfico de dispersão entre os valores observados e estimados de peso coletado por Voronoi nas três cidades estudadas.

Dispersão entre peso coletado e estimado



Fonte: Elaborado pelo autor (2024).

Os valores de R^2 , quando analisadas individualmente cada cidade, foram consideravelmente inferiores ao valor do R^2 geral do modelo (0,58) devido à menor variabilidade e tamanho amostral limitado, o que restringe a capacidade do modelo de capturar padrões gerais.

Ao combinar os dados das três cidades, o modelo se beneficia de uma maior diversidade e quantidade de dados, permitindo uma captura mais precisa das relações subjacentes.

Além disso, a combinação de dados de cidades diferentes reduz o impacto do "ruído" específico de cada uma (cultura local, políticas locais de gestão de resíduos, etc.), o que permite uma estimativa mais precisa da relação entre as variáveis.

Por fim, conforme observado nos tópicos 4.3 e 5.1, no Brasil há um baixo número de ecopontos em grandes centros urbanos e uma escassez ainda maior de dados de peso coletado nestes ecopontos. Espera-se que a disponibilidade de mais dados, provenientes de um maior número de cidades, poderia permitir a obtenção de um R^2 mais elevado para o modelo, devido à maior representatividade e diversidade dos dados.

Contudo, valores próximos de 1 são improváveis, pois existem fatores não espacializados e não mensuráveis, como criminalidade, costumes locais, senso de comunidade, impacto de programas de remuneração (como observado em Fortaleza) e até opiniões políticas. Esses fatores complexos e subjetivos influenciam a gestão e a coleta de resíduos de forma significativa, tornando inviável a obtenção de uma previsão perfeita.

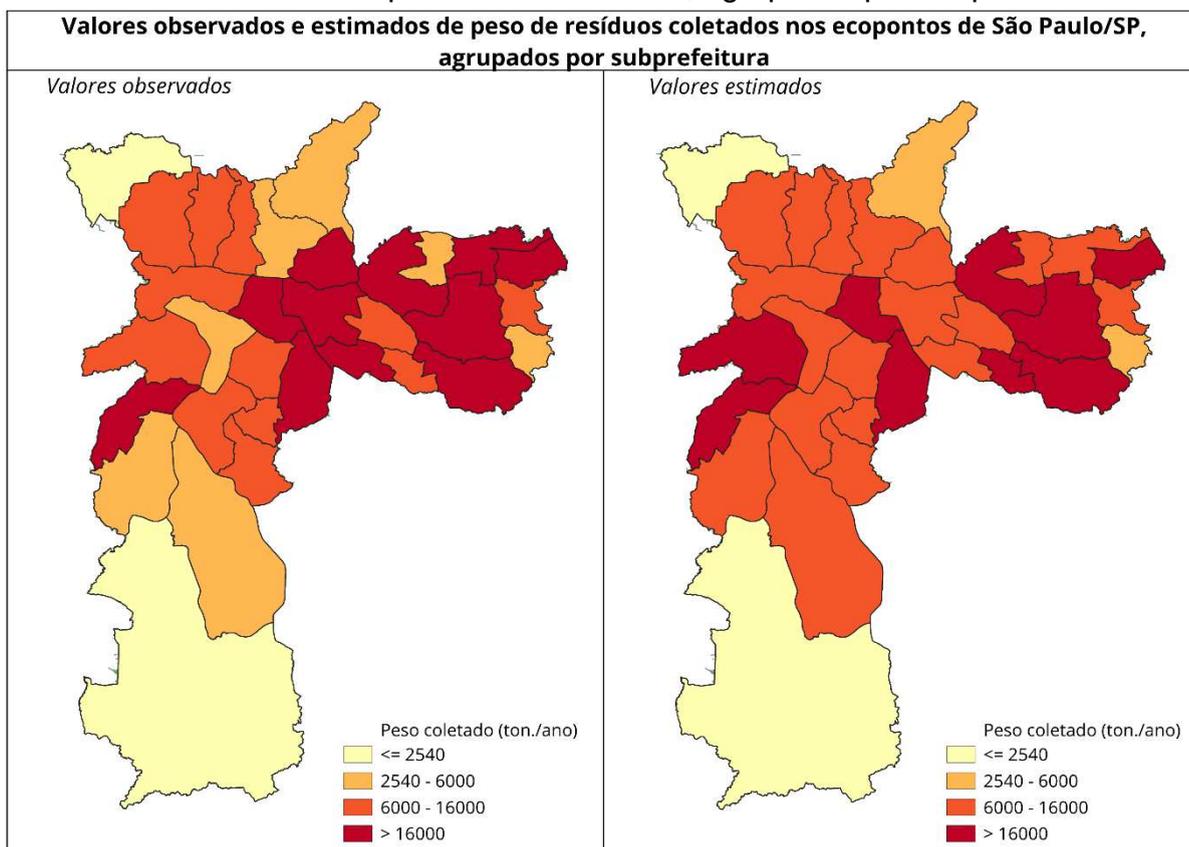
5.9 Validação do modelo de regressão linear

Para validação do modelo proposto, foi utilizado o conjunto de dados de peso coletado de resíduos nos ecopontos de cada subprefeitura da cidade de São Paulo. As variáveis do modelo (densidade demográfica, declividade, densidade de vias e densidade de unidades de saúde) foram calculadas à nível de subprefeitura, representadas na forma de camadas raster e utilizadas como entrada para a equação do modelo.

Desta forma, a saída do modelo nos forneceu uma camada raster com o valor previsto por cada subprefeitura. A Figura 68 apresenta a comparação entre os

valores observados e estimados de peso de resíduos coletados, em uma representação por subprefeitura. À esquerda, temos os valores observados e, à direita, os valores estimados pelo modelo.

Figura 68 - Mapa comparativo entre valores observados e estimados de peso de resíduos coletados nos ecopontos de São Paulo, agrupados por subprefeitura.



Fonte: Elaborado pelo autor (2024).

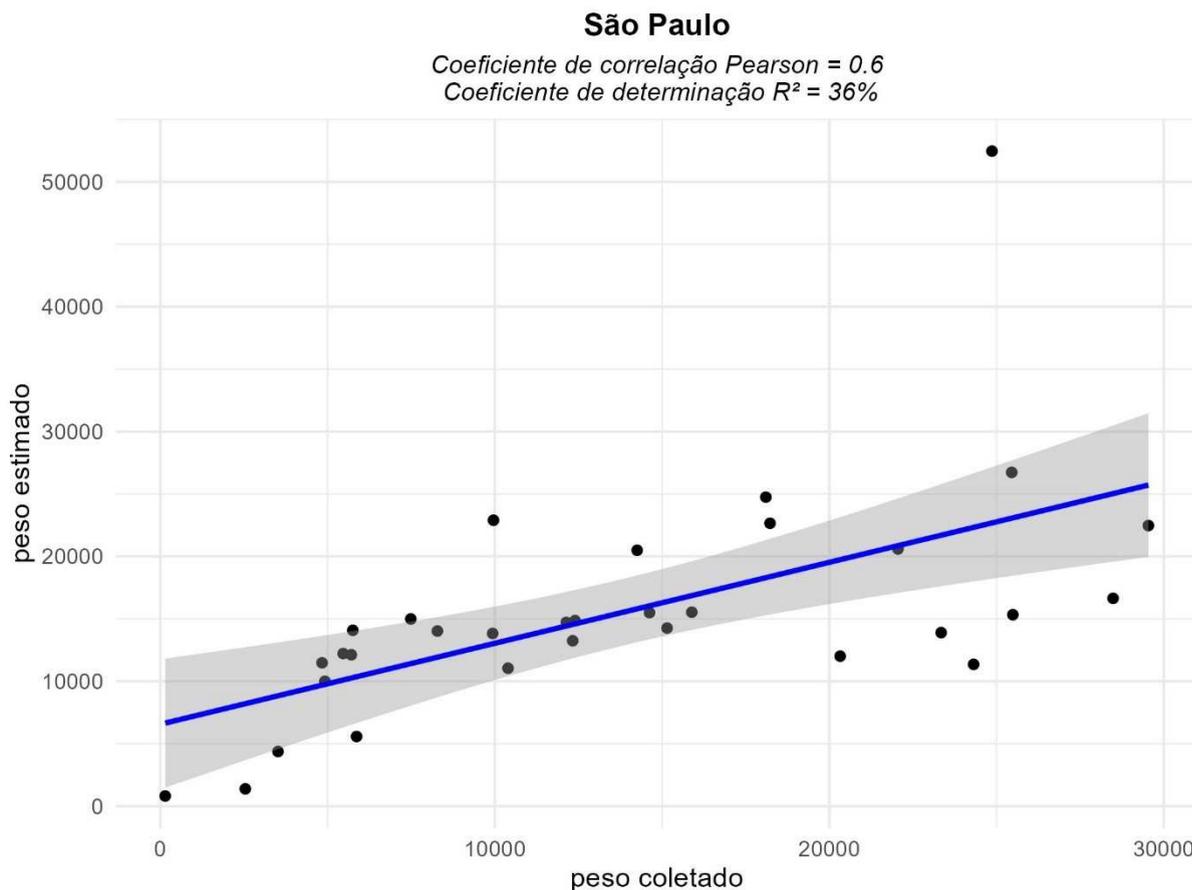
Ao analisar a Figura 68, observa-se que o modelo consegue capturar as principais tendências espaciais na distribuição do peso coletado. As subprefeituras com maior quantidade de resíduos coletados, representadas em vermelho escuro, coincidem em grande parte entre os valores observados e estimados. Isso indica que o modelo tem uma boa capacidade de prever áreas com alta coleta de resíduos.

Além disso, 20 das 32 subprefeituras apresentaram constância em relação à classe nos dois mapas. Ou seja, dividindo o peso coletado em 4 classes, 62,5% das subprefeituras permaneceram na mesma classe ao comparar os valores observados e os estimados.

Por fim, nenhuma subprefeitura que estava na classe inferior (menor ou igual a 2.540 toneladas/ano) teve sua estimativa como pertencente à classe superior

(acima de 16.000 toneladas/ano) e vice-versa. Essa observação indica que, embora possam existir discrepâncias entre os valores observados e estimados, o modelo não cometeu erros extremos ao classificar as subprefeituras quanto ao peso dos resíduos coletados.

Figura 69 - Gráfico de dispersão entre os valores observados e estimados de peso coletado, em toneladas por ano, por subprefeitura na cidade de São Paulo.



Fonte: Elaborado pelo autor (2024).

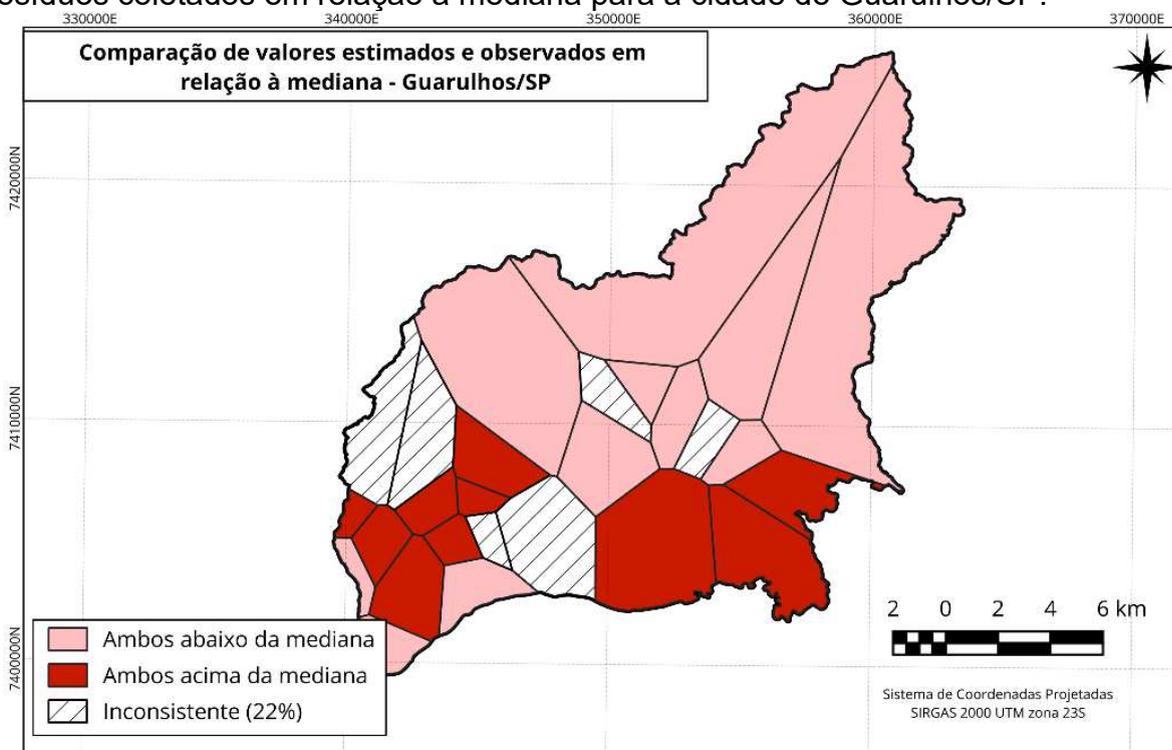
A Figura 69 acima, que apresenta o gráfico de dispersão entre os valores observados e estimados para a cidade de São Paulo, mostra um coeficiente de correlação de Pearson de 0,6 e um coeficiente de determinação de 36%. Isso indica uma correlação positiva moderada, superior inclusive ao observado em Fortaleza, Belo Horizonte e Guarulhos. A linha de regressão e a faixa de confiança destacam a tendência geral dos dados, que apresentam um padrão linear com poucos *outliers*, confirmando a eficácia do modelo, embora o mesmo não explique a totalidade das observações.

Em conclusão, o modelo proposto se mostra promissor e eficaz para a predição do peso de resíduos coletados, oferecendo uma ferramenta valiosa para a tomada de decisões na gestão de RSU. No entanto, há espaço para melhorias adicionais, especialmente com a inclusão de mais dados de entrada. Com esses resultados, pode-se considerar que o modelo foi validado, mas com a ressalva de que melhorias adicionais podem aumentar sua precisão.

5.10 Aplicação do modelo de regressão linear

Neste tópico, são apresentadas algumas aplicações do modelo em cidades brasileiras. Inicialmente, foi analisada a capacidade do modelo de prever se determinada área terá uma quantidade de resíduos coletados acima ou abaixo da mediana para aquela cidade. As Figuras 70 a 72, que comparam os valores estimados e observados em relação à mediana para as cidades de Guarulhos, Fortaleza e Belo Horizonte, ilustram essa aplicação.

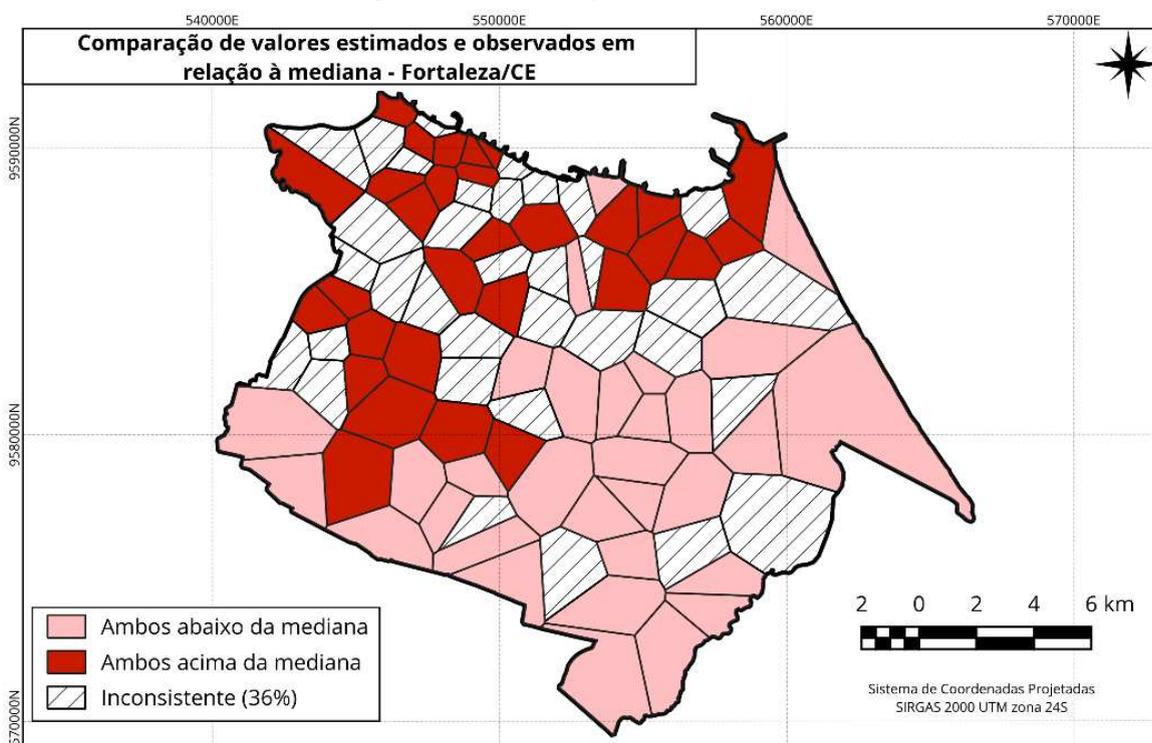
Figura 70 - Mapa comparativo entre valores observados e estimados de peso de resíduos coletados em relação à mediana para a cidade de Guarulhos/SP.



Fonte: Elaborado pelo autor (2024).

Cada mapa está dividido em polígonos de Voronoi, que são as áreas de influência de cada ecoponto, e as áreas em tom mais claro indicam que tanto os valores observados quanto os estimados foram abaixo da mediana. As áreas em tom mais escuro mostram que ambos os valores estão acima da mediana. Por fim, as áreas hachuradas representam inconsistências, onde os valores observados e estimados divergem em relação à mediana (combinação acima-abaixo ou abaixo-acima).

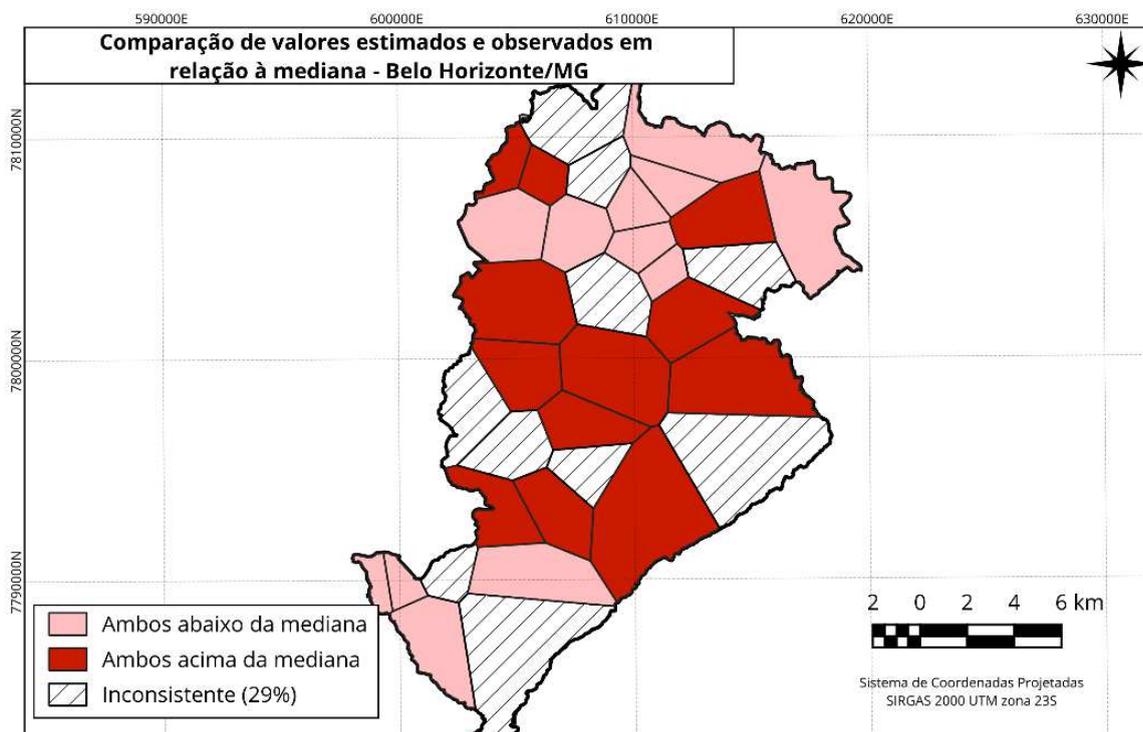
Figura 71 - Mapa comparativo entre valores observados e estimados de peso de resíduos coletados em relação à mediana para a cidade de Fortaleza/CE.



Fonte: Elaborado pelo autor (2024).

A capacidade do modelo de prever se uma área coletará resíduos acima ou abaixo da mediana é uma ferramenta de grande valor para a gestão de resíduos urbanos. Os mapas demonstram que, em geral, o modelo consegue identificar corretamente as zonas de alta e baixa geração de resíduos, com variações na precisão entre as três cidades.

Figura 72 - Mapa comparativo entre valores observados e estimados de peso de resíduos coletados em relação à mediana para a cidade de Belo Horizonte/MG.



Fonte: Elaborado pelo autor (2024).

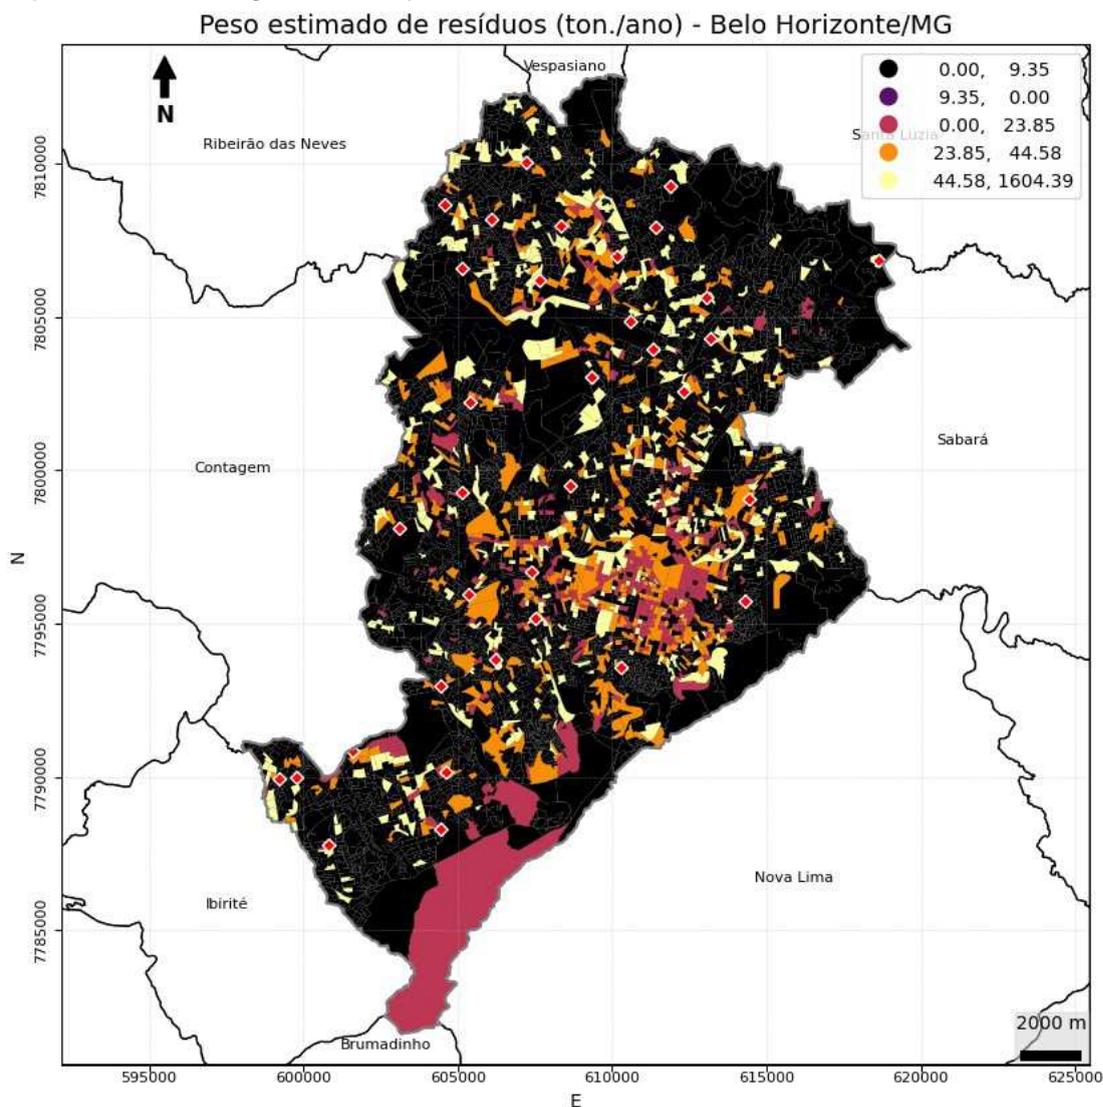
Em Guarulhos, a baixa porcentagem de áreas inconsistentes (22%) sugere uma boa performance do modelo para este tipo de análise. Até mesmo em Fortaleza, com uma taxa de inconsistência de 36%, o modelo ainda apresenta uma performance aceitável e que pode fornecer informações úteis para os gestores.

Apesar de algumas discrepâncias, a aplicação do modelo oferece uma visão estratégica para a gestão de resíduos, permitindo a identificação de áreas prioritárias para intervenções e planejamento.

Outra aplicação que este modelo permite é a priorização e identificação de áreas para instalação de novos ecopontos. A saída do modelo permite realizar análises em qualquer tipo de divisão territorial: setor censitário, quadra, bairro, distrito etc. A partir desta característica, foram geradas as Figuras 73 a 75, que apresentam mapas preditivos utilizando setores censitários das três cidades de entrada do modelo (Fortaleza, Belo Horizonte e Guarulhos), onde também são plotadas as localizações dos ecopontos atuais (losangos vermelhos com bordas brancas). Estes mapas possibilitam a realização de uma análise técnica que identifique áreas para instalação de novos ecopontos que não possuem um ecoponto próximo.

Analisando o mapa de Belo Horizonte (Figura 73), observa-se que há áreas significativas na região sul e sudeste da cidade, com alta estimativa de coleta de resíduos, que não possuem ecopontos próximos. Essas áreas seriam prioritárias para a instalação de novos ecopontos.

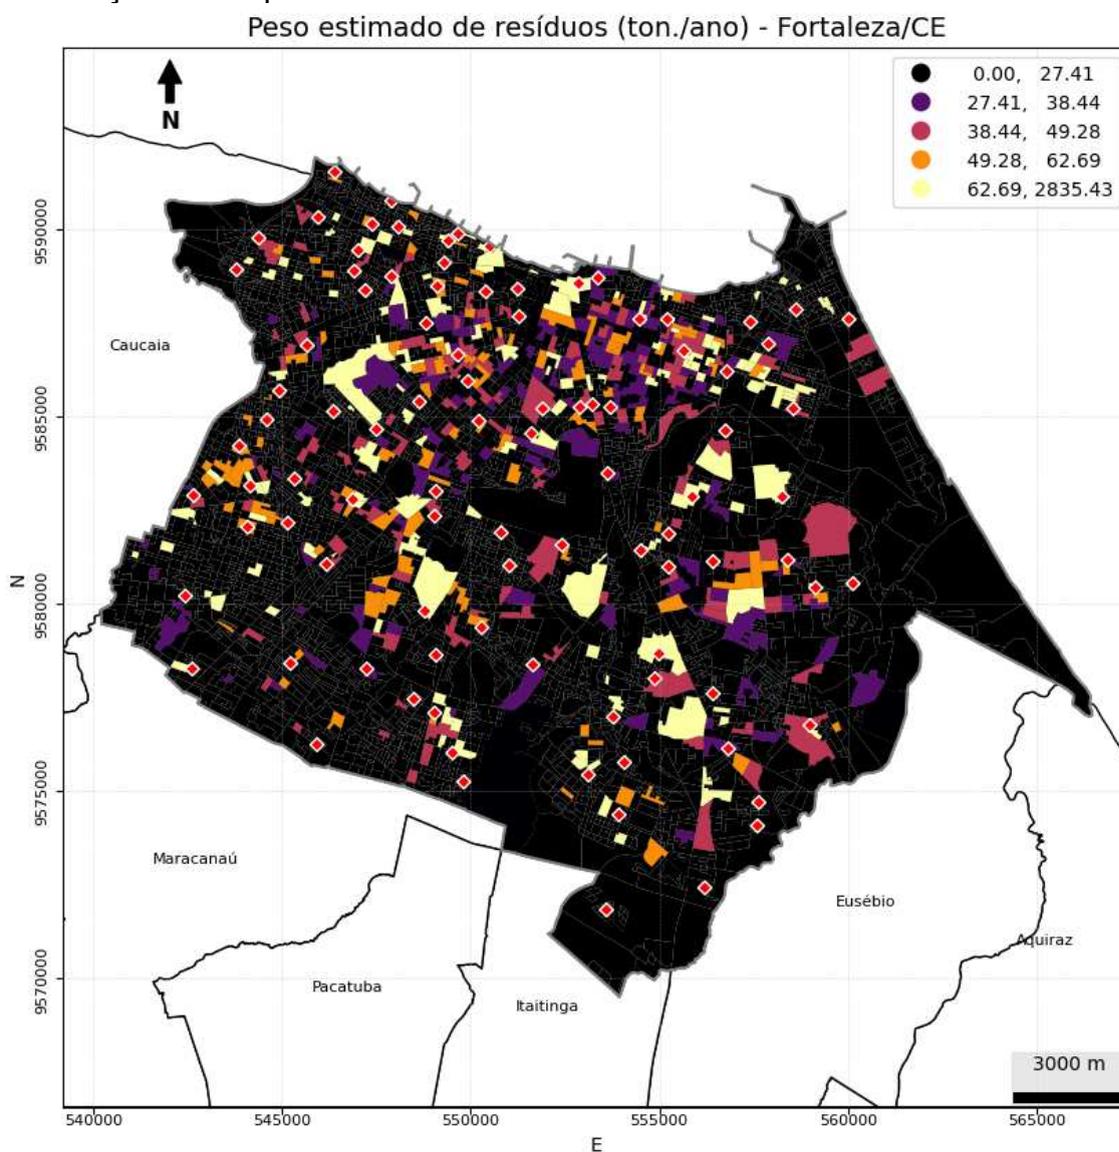
Figura 73 - Mapa preditivo gerado com o uso da equação de regressão linear múltipla utilizando setores censitários na cidade de Belo Horizonte/MG e a respectiva localização de ecopontos.



Fonte: Elaborado pelo autor (2024).

Em Fortaleza, conforme discutido anteriormente, o elevado número atual de ecopontos na cidade reduz drasticamente as opções de novas áreas para receber instalações onde se estima que apresentariam alta performance.

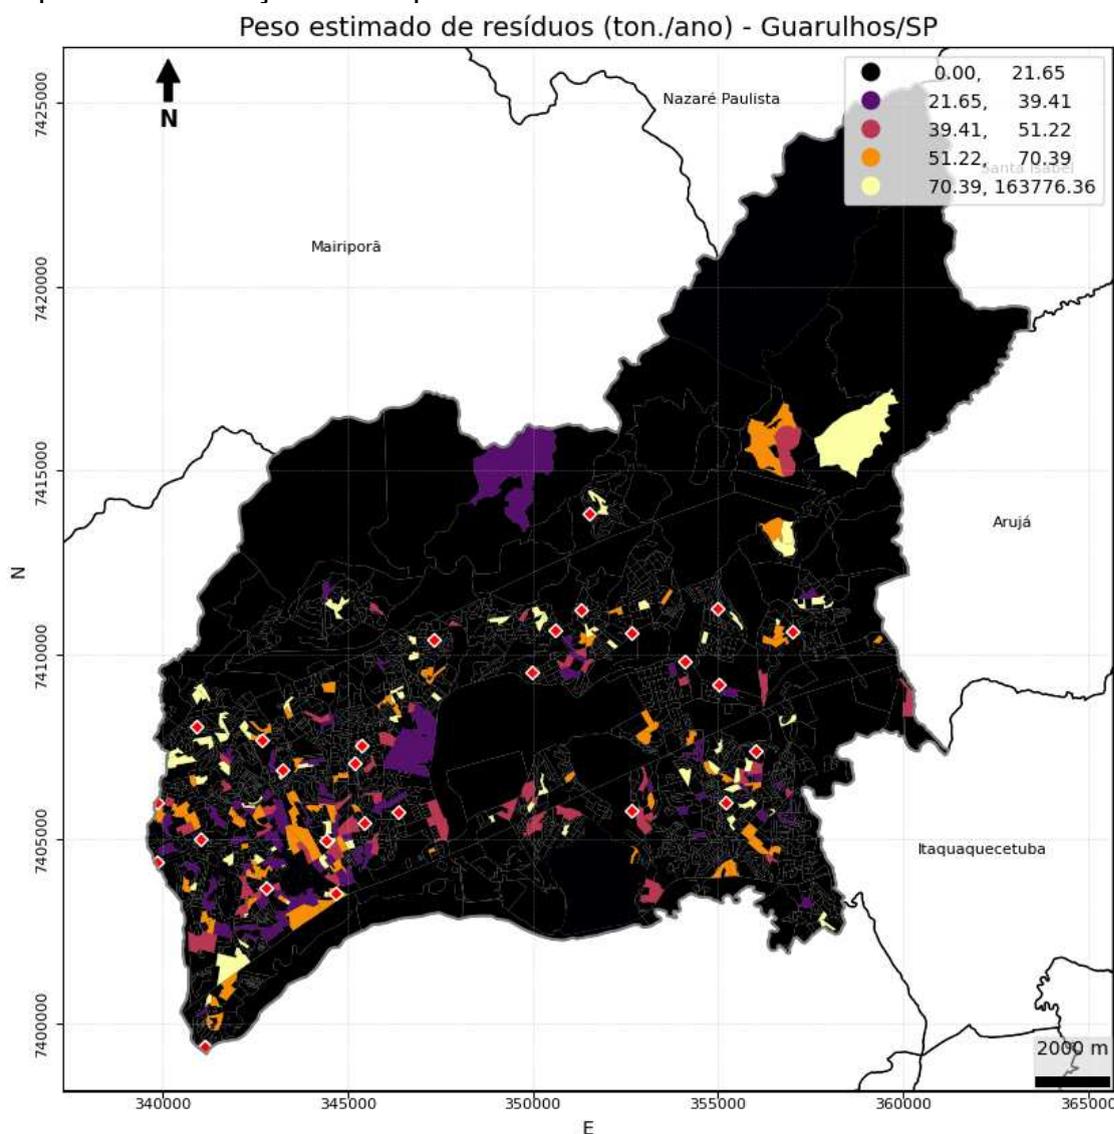
Figura 74 - Mapa preditivo gerado com o uso da equação de regressão linear múltipla utilizando setores censitários na cidade de Fortaleza/CE e a respectiva localização de ecopontos.



Fonte: Elaborado pelo autor (2024).

Por fim, o mapa de Guarulhos (Figura 75) indica que existem áreas ao sul e nordeste da cidade que estão sem cobertura adequada de ecopontos. A instalação de novos ecopontos nessas regiões potencialmente ajudaria a melhorar a gestão de resíduos em Guarulhos.

Figura 75 - Mapa preditivo gerado com o uso da equação de regressão linear múltipla utilizando setores censitários na cidade de Guarulhos/SP e a respectiva localização de ecopontos.

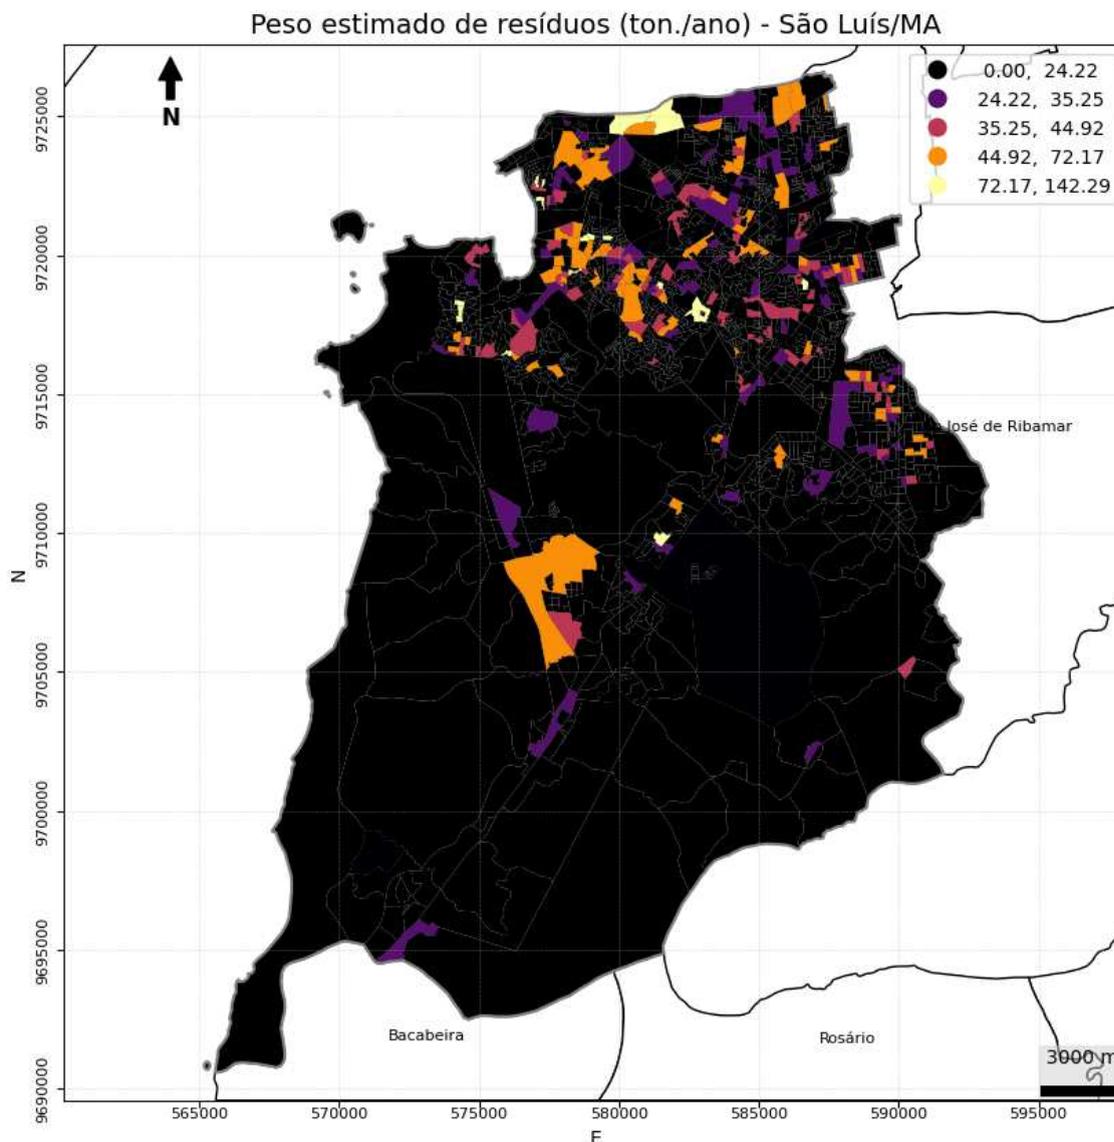


Fonte: Elaborado pelo autor (2024).

Além disso, também foi possível gerar mapas preditivos para qualquer cidade brasileira, mesmo que ela não tenha nenhum ecoponto em seu território. Como exemplo, foram gerados mapas para Recife/PE e São Luís/MA.

O mapa de São Luís (Figura 76) destaca uma área central e diversas áreas ao norte como locais prioritários para novos ecopontos, enquanto em Recife (Figura 77), as áreas centrais e a parte sul/sudeste da cidade mostram alta estimativa.

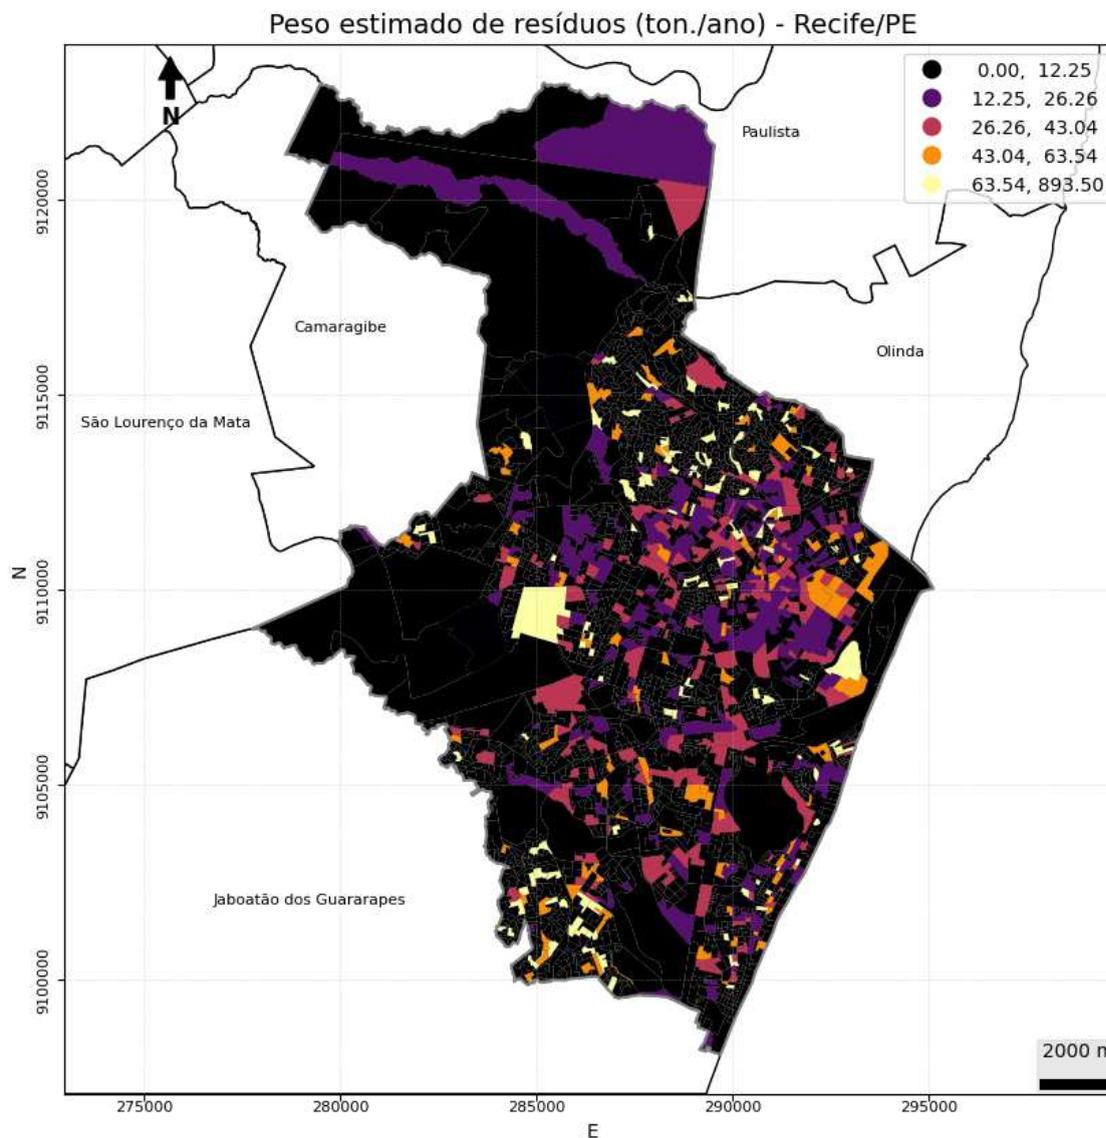
Figura 76 - Mapa preditivo gerado com o uso da equação de regressão linear múltipla utilizando setores censitários na cidade de São Luís/MA.



Fonte: Elaborado pelo autor (2024).

A análise dos mapas preditivos permite uma abordagem proativa na instalação de ecopontos, garantindo que as áreas com maior necessidade sejam atendidas de forma eficiente e prioritária.

Figura 77 - Mapa preditivo gerado com o uso da equação de regressão linear múltipla utilizando setores censitários na cidade de Recife/PE.



Fonte: Elaborado pelo autor (2024).

Esses mapas não apenas orientam a alocação de recursos, mas também ajudam a planejar intervenções futuras, considerando o crescimento populacional e mudanças nos padrões de geração de resíduos. Embora haja espaço para melhorias no modelo, como a inclusão de variáveis adicionais e a coleta de mais dados, os resultados obtidos até agora são promissores e demonstram o potencial do modelo para contribuir significativamente para a gestão sustentável de resíduos urbanos no Brasil.

6 CONSIDERAÇÕES FINAIS

6.1 Conclusões

Inicialmente, foi analisada a distribuição e eficiência dos ecopontos existentes nas cidades de Belo Horizonte, Fortaleza e Guarulhos. Foi observado que, dentre todas as variáveis analisadas, a densidade demográfica era a variável que possuía a maior influência na quantidade de resíduos coletados nos ecopontos, apresentando uma correlação positiva significativa. Em Fortaleza, por exemplo, a correlação foi de 0,61, indicando que áreas mais densamente povoadas tendiam a destinar mais resíduos aos ecopontos. Além disso, foram observadas correlações com o IDHM e o peso coletado, embora a intensidade e a natureza destas correlações demonstraram-se variáveis devido a características locais específicas de cada cidade.

O modelo determinístico foi desenvolvido com as variáveis densidade demográfica, proximidade de vias arteriais e IDHM, selecionadas a partir da estatística descritiva, e possibilita que o gestor crie cenários de contorno personalizados para classificar áreas da cidade com notas entre 0 e 10 de acordo com sua adequabilidade potencial para instalação de ecopontos.

A análise de simulações deste modelo nas três cidades demonstrou sua eficácia em identificar áreas adequadas, com potências moderadas (entre 1 e 2) proporcionando um balanço ideal entre granularidade e visão geral.

Em seguida, foi desenvolvido o modelo preditivo utilizando as variáveis densidade demográfica, declividade, densidade de vias e densidade de unidades de saúde, combinadas em uma equação de regressão linear múltipla. Este modelo apresentou um coeficiente de determinação de 58% e permitiu a criação de mapas preditivos que indicaram áreas com alta adequabilidade para a instalação de novos ecopontos.

Em todas as cidades do estudo, o coeficiente de correlação entre o peso efetivamente coletado e o peso estimado para determinada área foi acima de 0,45, assim como mais de 60% das observações foram consistentes ao comparar o peso coletado e estimado em relação a sua superioridade ou inferioridade à mediana. O modelo foi validado com dados da cidade de São Paulo a nível de subprefeitura, obtendo também uma elevada correlação (0,6) entre os valores observados e

estimados. Estas análises indicaram que o modelo foi capaz de estimar valores que condizem de forma satisfatória com a realidade para a maior parte das observações.

No entanto, no Brasil, há um baixo número de ecopontos e uma escassez de dados de peso coletado. Dados adicionais de outras cidades poderiam aumentar o R^2 final do modelo. Entretanto, alcançar um R^2 próximo de 1 é improvável devido a fatores não espacializados e não mensuráveis, como criminalidade, costumes locais e políticas locais.

A metodologia desenvolvida e proposta nestes dois modelos mostrou-se uma ferramenta eficaz e prática para gestores, permitindo uma abordagem baseada em dados na tomada de decisão para a instalação de novos ecopontos.

6.2 Sugestões para trabalhos futuros

- a) Realização de análise a nível de região metropolitana ao invés de nível municipal, com o intuito de avaliar as contribuições de municípios vizinhos.
- b) Incorporação de outras variáveis ambientais, sociais, econômicas e estruturais que possam influenciar no peso coletado em ecopontos para obtenção de um coeficiente de determinação maior no modelo de regressão linear.
- c) Avaliação de outras metodologias de previsão que utilizem aprendizado de máquina, como redes neurais artificiais e florestas de decisão aleatórias.
- d) Realização de uma análise de sustentabilidade econômica dos ecopontos em operação, com o objetivo de avaliar a eficiência da alocação atual de recursos financeiros municipais em termos de peso coletado de resíduos sólidos.
- e) Discussão relacionada à dificuldade de implementação de novos ecopontos por conta da resistência da população do entorno (fenômeno “não em meu quintal”, do inglês “not in my backyard” – NIMBY).

REFERÊNCIAS

ABDEL-SHAFY, Hussein I.; MANSOUR, Mona S.Mohamed.. Solid waste issue: sources, composition, disposal, recycling, and valorization. **Egyptian Journal of Petroleum**, [S.L.], v. 27, n. 4, p. 1275-1290, dez. 2018. Egyptian Petroleum Research Institute. <http://dx.doi.org/10.1016/j.ejpe.2018.07.003>.

ABRELPE. **Panorama dos Resíduos Sólidos no Brasil - 2022**. Disponível em: <https://abrelpe.org.br/panorama/>. Acesso em: 05 mai. 2024.

ADEWUMI, James R.; EJEH, Ocheje J.; LASISI, Kayode H.; AJIBADE, Fidelis O.. A GIS–AHP-based approach in siting MSW landfills in Lokoja, Nigeria. **Sn Applied Sciences**, [S.L.], v. 1, n. 12, 1 nov. 2019. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s42452-019-1500-6>.

ADHIKARI, Ram Chandra. Investigation on Solid Waste Management in Developing Countries. **Journal of Research and Development**, [S.L.], v. 5, n. 1, p. 42-52, 12 dez. 2022. Nepal Journals Online (JOL). <http://dx.doi.org/10.3126/jrdn.v5i1.50095>.

ALEXANDRE, Adriano Ricardo Almeida. **Análise da eficiência operacional e definição das áreas de influências locais dos ecopontos de Fortaleza-CE**. 2021. 173 f. Tese (Doutorado) - Curso de Doutorado em Engenharia Civil, Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará, Fortaleza, 2021.

ALFAIA, Raquel Greice de Souza Marotta; COSTA, Alyne Moraes; CAMPOS, Juacyara Carbonelli. Municipal solid waste in Brazil: a review. **Waste Management & Research: The Journal for a Sustainable Circular Economy**, [S.L.], v. 35, n. 12, p. 1195-1209, 1 nov. 2017. SAGE Publications. <http://dx.doi.org/10.1177/0734242x17735375>.

ALMEIDA, Ronei de; SOUZA, Roberta Guimarães de; CAMPOS, Juacyara Carbonelli. Lessons and challenges for the recycling sector of Brazil from the pandemic outbreak of COVID-19. **Waste Disposal & Sustainable Energy**, [S.L.], v. 3, n. 2, p. 145-154, jun. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s42768-021-00075-y>.

ALZAMORA, Bruno Ribas; BARROS, Raphael Tobias de Vasconcelos; OLIVEIRA, Leise Kelli de; GONÇALVES, Sabrina Silveira. Forecasting and the influence of socioeconomic factors on municipal solid waste generation: a literature review. **Environmental Development**, [S.L.], v. 44, p. 100734, dez. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.envdev.2022.100734>.

ANGELI, Antreas; ZORPAS, Antonis. Quantifying the impact of volunteerism in the framework of waste management strategies in Cyprus. **16th International Conference on Environmental Science and Technology**. In: Rhodes, Greece, 2019.

ANGULO, Sérgio Cirelli; OLIVEIRA, Lidiane Santana; MACHADO, Leonardo Camara. **Pesquisa setorial ABRECON 2020: a reciclagem de resíduos de construção e demolição no Brasil**. Universidade de São Paulo. Escola Politécnica, 2022. DOI: <https://doi.org/10.11606/9786589190103>. Disponível em: www.livrosabertos.abcd.usp.br/portaldelivrosUSP/catalog/book/839. Acesso em 10 julho. 2024.

ARACAJU. Câmara Municipal de Aracaju. **Audiência Pública destaca importância e impactos dos Ecopontos em Aracaju**. 2023. Disponível em: <https://www.aracaju.se.leg.br/institucional/noticias/audiencia-publica-destaca-importancia-e-impactos-dos-ecopontos-em-aracaju>. Acesso em: 20 dez. 2023.

ARAÚJO, Kássia Karina; PIMENTEL, Angélica Kelly. A PROBLEMÁTICA DO DESCARTE IRREGULAR DOS RESÍDUOS SÓLIDOS URBANOS NOS BAIRROS VERGEL DO LAGO E JATIÚCA EM MACEIÓ, ALAGOAS. **Revista Gestão & Sustentabilidade Ambiental**, [S.L.], v. 4, n. 2, p. 626, 9 out. 2015. Anima Educação. <http://dx.doi.org/10.19177/rgsa.v4e22015626-668>.

AREMU, Adeniyi Saheed; ADELEKE, Oluwafemi; SULE, Bolaji Fatai. A GIS-Based Optimization Technique for Spatial Location of Municipal Waste Bins in a Developing City. **Ethiopian Journal of Environmental Studies and Management**, [S.L.], v. 4, n. 3, p. 65-72, 7 nov. 2011. African Journals Online (AJOL). <http://dx.doi.org/10.4314/ejesm.v4i3.9>.

ARIAS, David Mayorga; ROLDAN, Marlon Victor, Hugo Pazos; VÉLEZ, Martha Viviana Uvidia. Sistemas de información geográfica aplicados a la topografía. **Opuntia Brava**, v. 11, p. 370-374, 2019.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 10004**: Resíduos sólidos – Classificação. 2 ed. Rio de Janeiro: [s.n.], 2004. 71 p.

BABAYEMI, Joshua Olajire; DAUDA, Khadijah Tolulope. Evaluation of Solid Waste Generation, Categories and Disposal Options in Developing Countries: a case study of nigeria. **Journal of Applied Sciences and Environmental Management**, [S.L.], v. 13, n. 3, p. 83-88, 8 jun. 2010. African Journals Online (AJOL). <http://dx.doi.org/10.4314/jasem.v13i3.55370>.

BARUQUE-RAMOS, Julia; AMARAL, Mariana Correa; LAKTIM, Mariana Costa; SANTOS, Heloisa; ARAUJO, F B; ZONATTI, Welton Fernando. Social and economic importance of textile reuse and recycling in Brazil. **Iop Conference Series: Materials Science and Engineering**, [S.L.], v. 254, p. 192003, out. 2017. IOP Publishing. <http://dx.doi.org/10.1088/1757-899x/254/19/192003>.

BELO HORIZONTE. PREFEITURA DE BELO HORIZONTE. **BHGEO**. 2024a. Disponível em: <https://bhmap.pbh.gov.br/v2/mapa/idebhgeo>. Acesso em: 10 jan. 2024.

BELO HORIZONTE. Lei nº 10.522, de 24 de agosto de 2012. Institui o Sistema de Gestão Sustentável de Resíduos da Construção Civil e Resíduos Volumosos -

SGRCC - e o Plano Municipal de Gerenciamento Integrado de Resíduos da Construção Civil e Resíduos Volumosos - PMRCC, e dá outras providências. Belo Horizonte, 2012. Disponível em: <https://www.legisweb.com.br/legislacao/?id=244654>. Acesso em: 14 jan. 2024.

BELO HORIZONTE. Secretaria de Limpeza Urbana. **Relatório de Pesos Coletados nas Unidades de Recebimento de Pequenos Volumes - URPVs de Belo Horizonte**. 2024b. Belo Horizonte: SLU, 2024.

BELO HORIZONTE. Superintendência De Limpeza Urbana. **Unidades de Recebimento de Pequenos Volumes (URPVS)**. 2023. Disponível em: <https://prefeitura.pbh.gov.br/slu/informacoes/servicos/urpvs-enderecos>. Acesso em: 20 ago. 2023.

BERRY, William. **Understanding Regression Assumptions**. SAGE Publications, Inc., 1993.

BOA VISTA. **Ecopontos de Boa Vista: entenda o que são e como irão funcionar**. 2023. Disponível em: <https://boavista.rr.gov.br/noticias/2023/7/ecopontos-sao-espacos-para-destinacao-de-residuos-reaproveitaveis-e-garantia-de-geracao-de-renda>. Acesso em: 20 ago. 2023.

BOLSTAD, Paul. **GIS Fundamentals**. 6. ed. Minnesota: XanEdu Publishing Inc, 2019.

BOUGUERRA, Hamza; TACHI, Salah Eddine; BOUCHEHED, Hamza; GILJA, Gordon; ALOUI, Nadir; HASNAOUI, Yacine; ALICHE, Abdelmalek; BENMAMAR, Saâdia; NAVARRO-PEDREÑO, Jose. Integration of High-Accuracy Geospatial Data and Machine Learning Approaches for Soil Erosion Susceptibility Mapping in the Mediterranean Region: a case study of the Macta basin, Algeria. **Sustainability**, [S.L.], v. 15, n. 13, p. 10388, 30 jun. 2023. MDPI AG. <http://dx.doi.org/10.3390/su151310388>.

BRASIL. Conselho Nacional do Meio Ambiente (CONAMA). Resolução nº 307, de 5 de julho de 2002. Estabelece diretrizes, critérios e procedimentos para a gestão dos resíduos da construção civil. Diário Oficial [da] República Federativa do Brasil, Brasília, DF, 17 jul. 2002. Disponível em: https://cetesb.sp.gov.br/licenciamento/documentos/2002_Res_CONAMA_307.pdf. Acesso em: 5 abr. 2024.

BRASIL. Conselho Nacional do Meio Ambiente (CONAMA). Resolução nº 358, de 29 de abril de 2005. Dispõe sobre o tratamento e a disposição final dos resíduos dos serviços de saúde e dá outras providências. Diário Oficial [da] República Federativa do Brasil, Brasília, DF. Disponível em: <https://www.siam.mg.gov.br/sla/download.pdf?idNorma=5046>. Acesso em: 5 abr. 2024.

BRASIL. Decreto nº 10.936, de 12 de janeiro de 2022. Regulamenta a Lei nº 12.305, de 2 de agosto de 2010, que institui a Política Nacional de Resíduos Sólidos.

Brasília, DF, 12 jan. 2022. Disponível em:
https://www.planalto.gov.br/ccivil_03/_Ato2019-2022/2022/Decreto/D10936.htm#art91. Acesso em: 5 abr. 2024.

BRASIL. Lei nº 9.605, de 12 de fevereiro de 1998. Dispõe sobre as sanções penais e administrativas derivadas de condutas e atividades lesivas ao meio ambiente, e dá outras providências. Brasília, DF. Disponível em:
https://www.planalto.gov.br/ccivil_03/leis/l9605.htm. Acesso em: 5 abr. 2024.

BRASIL. Lei nº 12.305, de 2 de agosto de 2010. Institui a Política Nacional de Resíduos Sólidos; altera a Lei nº 9.605, de 12 de fevereiro de 1998; e dá outras providências. Brasília, 2010. Disponível em:
https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2010/lei/l12305.htm. Acesso em: 19 jan. 2024.

BRASIL. Lei nº 12.527, de 18 de novembro de 2011. Regula o acesso a informações previsto no inciso XXXIII do art. 5º, no inciso II do § 3º do art. 37 e no § 2º do art. 216 da Constituição Federal; altera a Lei nº 8.112, de 11 de dezembro de 1990; revoga a Lei nº 11.111, de 5 de maio de 2005, e dispositivos da Lei nº 8.159, de 8 de janeiro de 1991; e dá outras providências. 2011. Disponível em:
https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2011/lei/l12527.htm. Acesso em: 13 jan. 2024.

BRASIL. Lei nº 14.026, de 15 de julho de 2020. Atualiza o marco legal do saneamento básico e altera a Lei nº 9.984, de 17 de julho de 2000, para atribuir à Agência Nacional de Águas e Saneamento Básico (ANA) competência para editar normas de referência sobre o serviço de saneamento, a Lei nº 10.768, de 19 de novembro de 2003, para alterar o nome e as atribuições do cargo de Especialista em Recursos Hídricos, a Lei nº 11.107, de 6 de abril de 2005, para vedar a prestação por contrato de programa dos serviços públicos de que trata o art. 175 da Constituição Federal, a Lei nº 11.445, de 5 de janeiro de 2007, para aprimorar as condições estruturais do saneamento básico no País, a Lei nº 12.305, de 2 de agosto de 2010, para tratar dos prazos para a disposição final ambientalmente adequada dos rejeitos, a Lei nº 13.089, de 12 de janeiro de 2015 (Estatuto da Metrópole), para estender seu âmbito de aplicação às microrregiões, e a Lei nº 13.529, de 4 de dezembro de 2017, para autorizar a União a participar de fundo com a finalidade exclusiva de financiar serviços técnicos especializados. 2020. Disponível em: https://www.planalto.gov.br/ccivil_03/_Ato2019-2022/2020/Lei/L14026.htm. Acesso em: 13 jan. 2024.

BRIGUGLIO, Marie; DELANEY, Liam; WOOD, Alex. Voluntary recycling despite disincentives. **Journal of Environmental Planning and Management**, [S.L.], v. 59, n. 10, p. 1751-1774, out. 2016. Informa UK Limited.
<http://dx.doi.org/10.1080/09640568.2015.1086323>.

CAMPINAS. Departamento de Limpeza Urbana. **Limpeza Urbana (DLU)**. 2023. Disponível em: <https://campinas.sp.gov.br/secretaria/servicos-publicos/pagina/limpeza-urbana-dlu->. Acesso em: 20 ago. 2023.

CAMPO GRANDE. Secretaria Municipal de Meio Ambiente e Desenvolvimento Urbano. **Ecopontos**. 2023. Disponível em: <https://www.campogrande.ms.gov.br/semadur/residuos-solidos/ecopontos/>. Acesso em: 20 ago. 2023.

CEARÁ. Lei Estadual nº 16.302, de 20 de junho de 2016. Institui a Política Estadual de Resíduos Sólidos no âmbito do Estado do Ceará. 2016. Disponível em: <https://mpce.mp.br/wp-content/uploads/2015/12/Lei-Estadual-nº16.032-2016-Institue-a-Política-Estadual-de-Resíduos-Sólidos-no-Estado-do-Ceará.pdf>. Acesso em: 19 jan. 2024.

CHABUK, Ali Jalil; AL-ANSARI, Nadhir; HUSSAIN, Hussain Musa; KNUTSSON, Sven; PUSCH, Roland. GIS-based assessment of combined AHP and SAW methods for selecting suitable sites for landfill in Al-Musayib Qadhaa, Babylon, Iraq. **Environmental Earth Sciences**, [S.L.], v. 76, n. 5, p. 209, mar. 2017. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12665-017-6524-x>.

CHANG, Kang-Tsung. Geographic Information System. In: RICHARDSON, Douglas; CASTREE, Noel; GOODCHILD, Michael; KOBAYASHI, Audrey; LIU, Weidong; MARSTON, Richard (org.). **International Encyclopedia of Geography: people, the earth, environment, and technology**. Malden: John Wiley & Sons Ltd, 2017. p. 1-9.

CHEN, Feng-Wen; LIU, Chen-Wuing. Estimation of the spatial rainfall distribution using inverse distance weighting (IDW) in the middle of Taiwan. **Paddy and Water Environment**, [S.L.], v. 10, n. 3, p. 209-222, 25 fev. 2012. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10333-012-0319-1>.

CHEN, Li; MAO, Yiyang; ZHAO, Ruotong. GIS application in environmental monitoring and risk assessment. **2022 3Rd International Conference On Geology, Mapping And Remote Sensing (Icgmrs)**, [S.L.], p. 908-917, 22 abr. 2022. IEEE. <http://dx.doi.org/10.1109/icgmrs55602.2022.9849269>.

CHOUÉIRY, George; SALAMEH, Pascale. Automating Data Analysis Methods in Epidemiology. **Journal of Data Science**, [S.L.], p. 55-80, 24 fev. 2021. School of Statistics, Renmin University of China. [http://dx.doi.org/10.6339/jds.201901_17\(1\).0003](http://dx.doi.org/10.6339/jds.201901_17(1).0003).

CHU, Zhujie; WU, Yunga; ZHOU, An; HUANG, Wei-Chiao. Analysis of influence factors on municipal solid waste generation based on the multivariable adjustment. **Environmental Progress & Sustainable Energy**, [S.L.], v. 35, n. 6, p. 1629-1633, 25 jun. 2016. Wiley. <http://dx.doi.org/10.1002/ep.12399>.

COELHO, Juliana Vogado; COSTA, Tancio Gutier Ailan; IWATA, Bruna de Freitas. QUALIDADE AMBIENTAL DO SOLO SOB A ÁREA DO ATERRO CONTROLADO DO MUNICÍPIO DE CORRENTE-PI. **Cadernos Cajuína**, [S.L.], v. 1, n. 1, p. 63-72, 22 mar. 2016. Cadernos Cajuína. <http://dx.doi.org/10.52641/cadcaj.v1i1.14>.

CURITIBA. **Ecopontos - Descarte Correto de Resíduos**. 2023. Disponível em: <https://www.curitiba.pr.gov.br/servicos/ecopontos-descarte-correto-de-residuos/716>. Acesso em: 20 ago. 2023.

D'AMATO, Alessio; MAZZANTI, Massimiliano; NICOLLI, Francesco. Waste Sustainability, Environmental Management and Mafia: analysing geographical and economic dimensions. **Ssrn Electronic Journal**, [S.L.], 2011. Elsevier BV. <http://dx.doi.org/10.2139/ssrn.1947303>.

DAS, Gopal; TALPUR, Mir Aftab Hussain; KOMAL; CHANDIO, Imtiaz Ahmed. Municipal Solid Waste Management using GIS Analysis: a case study of sehwan city. **Sir Syed University Research Journal of Engineering & Technology**, [S.L.], v. 13, n. 1, p. 17-23, 28 jun. 2023. Sir Syed University of Engineering and Technology. <http://dx.doi.org/10.33317/ssurj.515>.

DAS, Pallab; TIWARI, Pankaj. Valorization of packaging plastic waste by slow pyrolysis. **Resources, Conservation and Recycling**, [S.L.], v. 128, p. 69-77, jan. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.resconrec.2017.09.025>.

DEEPAK, Kanwar. Remote Sensing & GIS-based Site Identification for Solid Waste Management of Amritsar Municipal Corporation, Punjab, India. In: SINGH, Ripudaman (Ed.). **Re-envisioning Advances in Remote Sensing: Urbanization, Disasters and Planning**. 1. ed. Boca Raton: CRC Press, 2022, p. 187–204.

DEUS, Rafael Mattos; BATTISTELLE, Rosane Aparecida Gomes; SILVA, Gustavo Henrique Ribeiro. Scenario evaluation for the management of household solid waste in small Brazilian municipalities. **Clean Technologies and Environmental Policy**, [S.L.], v. 19, n. 1, p. 205-214, 19 maio 2016. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10098-016-1205-0>.

DIAS, Pablo; PALOMERO, João; CENCI, Marcelo Pilotto; SCARAZZATO, Tatiana; BERNARDES, Andréa Moura. Electronic waste in Brazil: generation, collection, recycling and the covid pandemic. **Cleaner Waste Systems**, [S.L.], v. 3, p. 100022, dez. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.clwas.2022.100022>.

DISTRITO FEDERAL. Serviço de Limpeza Urbana do Distrito Federal. **Papa-Entulho**. 2023. Disponível em: <https://www.slu.df.gov.br/papa-entulho/>. Acesso em: 20 ago. 2023.

ECO NORDESTE. **Ecopontos de Fortaleza recebem mais de 270 mil ton de recicláveis em cinco anos**. 2020. Disponível em: <https://agenciaeconordeste.com.br/ecopontos-de-fortaleza-recebem-mais-de-270-mil-ton-de-reciclaveis-em-cinco-anos/>. Acesso em: 20 mai. 2024.

ELKHRACHY, Ismail. Solid Waste Assessment and Management Using Remote Sensing Data and GIS Tools: a case study of najran city, ksa. **Iop Conference Series: Earth and Environmental Science**, [S.L.], v. 1026, n. 1, p. 012041, 1 maio 2022. IOP Publishing. <http://dx.doi.org/10.1088/1755-1315/1026/1/012041>.

FARHAN, Firda Islamaya; ADI, Ahmad Cahyono. Forecasting Flood Vulnerability in Pontianak using Multiple Linear Regression and Geospatial Information Systems (GIS). **Innovation in Research of Informatics (Innovatics)**, [S.L.], v. 5, n. 1, p. 9-13, 14 mar. 2023. LPPM-PMP Universitas Siliwangi Tasikmalaya. <http://dx.doi.org/10.37058/innovatics.v5i1.6567>.

FERREIRA, João Alberto; ANJOS, Luiz Antonio dos. Aspectos de saúde coletiva e ocupacional associados à gestão dos resíduos sólidos municipais. **Cadernos de Saúde Pública**, [S.L.], v. 17, n. 3, p. 689-696, jun. 2001. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0102-311x2001000300023>.

FERRONATO, Navarro; TORRETTA, Vincenzo. Waste Mismanagement in Developing Countries: a review of global issues. **International Journal of Environmental Research and Public Health**, [S.L.], v. 16, n. 6, p. 1060, 24 mar. 2019. MDPI AG. <http://dx.doi.org/10.3390/ijerph16061060>.

FITZ, Paulo Roberto. **Geoprocessamento sem complicação**. São Paulo: Oficina de Textos, 2008. 160 p.

FLORIANÓPOLIS. Secretaria Municipal do Meio Ambiente. **Gestão de Resíduos (SMMA)**. 2023. Disponível em: <https://www.pmf.sc.gov.br/entidades/residuos/index.php?cms=ecopontos+da+smma&menu=4&submenuid=150>. Acesso em: 20 ago. 2023.

FORTALEZA. **Ecopontos**. 2023a. Disponível em: <https://urbanismoemeioambiente.fortaleza.ce.gov.br/infocidade/402-ecopontos>. Acesso em: 12 fev. 2024.

FORTALEZA. **Fortaleza em Mapas**. 2024a. Disponível em: <https://mapas.fortaleza.ce.gov.br/>. Acesso em: 10 jan. 2024.

FORTALEZA. Secretaria de Urbanismo e Meio Ambiente. **Ecopontos**. 2023b. Disponível em: <https://catalogodeservicos.fortaleza.ce.gov.br/categoria/urbanismo-meio-ambiente/servico/324>. Acesso em: 20 ago. 2023.

FORTALEZA. **Recicla Fortaleza**. 2023c. Disponível em: <https://catalogodeservicos.fortaleza.ce.gov.br/categoria/urbanismo-meio-ambiente/servico/122#outros>. Acesso em: 12 fev. 2024.

FORTALEZA. Secretaria Municipal de Conservação e Serviços Públicos. **Relatório de Gestão de Resíduos Sólidos de Fortaleza**. 2024b. Fortaleza: SCSP, 2024.

FORTALEZA. Prefeitura Municipal. Lei nº 10.340, de 28 de abril de 2015. Altera os arts. 1º ao 33º da Lei 8.408, de 24 de dezembro de 1999, e dá outras providências. 2015. Disponível em: <https://diariooficial.fortaleza.ce.gov.br/?num-diario=15517&content-diario=&anodiario=&mes-diario=04#t=>. 2014. Acesso em: 13 jan. 2024.

GAHRAMANOV, Etibar; GAHRAMANOV, Elvin; BADALOVA, Aytaj. Application of GIS in Solid Waste Management in Gara Garayev Avenue, Nizami District, Baku City. **Ssrn Electronic Journal**, [S.L.], set. 2022. Elsevier BV. <http://dx.doi.org/10.2139/ssrn.4214080>.

GHANBARI, Forough; KAMALAN, Hamidreza; SARRAF, Amirpouya. An evolutionary machine learning approach for municipal solid waste generation estimation utilizing socioeconomic components. **Arabian Journal of Geosciences**, [S.L.], v. 14, n. 2, jan. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12517-020-06348-w>.

GIEL, Robert; DABROWSKA, Alicja. Estimating Time Spent at the Waste Collection Point by A Garbage Truck with A Multiple Regression Model. **Sustainability**, [S.L.], v. 13, n. 8, p. 4272, 12 abr. 2021. MDPI AG. <http://dx.doi.org/10.3390/su13084272>.

GOIÂNIA. Companhia de Urbanização de Goiânia. **Prefeitura de Goiânia tem 5 Ecopontos para descarte de pneus no combate à dengue**. 2023. Disponível em: <https://comurg.com.br/prefeitura-de-goiania-tem-5-ecopontos-para-descarte-de-pneus-no-combate-a-dengue/>. Acesso em: 20 ago. 2023.

GOMES, Stéfano Bruno Vieira; ROCHA, Marcelo Borges. ESTUDO SOBRE GESTÃO DE RESÍDUOS SÓLIDOS E EDUCAÇÃO AMBIENTAL EM UNIDADES DE CONSERVAÇÃO DO ESTADO DO RIO DE JANEIRO. **Revista Gestão & Sustentabilidade Ambiental**, [S.L.], v. 10, n. 2, p. 230, 30 jun. 2021. Anima Educação. <http://dx.doi.org/10.19177/rgsa.v10e22021230-244>.

GOUVEIA, Nelson. Resíduos sólidos urbanos: impactos socioambientais e perspectiva de manejo sustentável com inclusão social. **Ciência & Saúde Coletiva**, [S.L.], v. 17, n. 6, p. 1503-1510, jun. 2012. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1413-81232012000600014>.

GUARNIERI, Patricia; CERQUEIRA-STREIT, Jorge A.; BATISTA, Luciano C.. Reverse logistics and the sectoral agreement of packaging industry in Brazil towards a transition to circular economy. **Resources, Conservation and Recycling**, [S.L.], v. 153, p. 104541, fev. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.resconrec.2019.104541>.

GUARULHOS. **GuaruGEO**. 2024a. Disponível em: <https://guarugeo.guarulhos.sp.gov.br/guarugeo/>. Acesso em: 13 mai. 2024.

GUARULHOS, Prefeitura Municipal de. Lei nº 8.271, de 29 de abril de 2024. Dispõe sobre a criação de Ecoponto de Resíduos Recicláveis, Inservíveis e Inertes no Município de Guarulhos e dá outras providências. 2024b. Disponível em: https://www.guarulhos.sp.gov.br/06_prefeitura/leis/leis_download/08271lei.pdf. Acesso em: 13 mai. 2024.

GUARULHOS, Prefeitura Municipal de. **Relatório de pesos coletados por ecopontos**. 2024c. Belo Horizonte: Secretaria de Serviços Públicos, 2024.

GUARULHOS, Prefeitura Municipal de. Secretaria de Serviços Públicos. **Ecoponto**. 2023. Disponível em: <https://www.guarulhos.sp.gov.br/ecoponto>. Acesso em: 20 ago. 2023.

GUJARATI, Damodar N. **Linear Regression: A Mathematical Introduction**. Thousand Oaks: SAGE Publications, Inc, 2019.

GUTAMA, Hatta; IRESHA, Fajri Mulya. Evaluation of solid waste management effectiveness in Indonesia from 2019-2021: a geographic information system analysis. **Iop Conference Series: Earth and Environmental Science**, [S.L.], v. 1263, n. 1, p. 012067, 1 nov. 2023. IOP Publishing. <http://dx.doi.org/10.1088/1755-1315/1263/1/012067>.

GUTIÉRREZ, Javier Alfonso Cárdenas; CARRASCAL, Jose Leonardo Jacome; ORTEGA, Mawency Vergel. V Determination of average annual rainfall in the Aguablanca stream watershed using GIS and IDW method. **Revista Boletín Redipe**, [S.L.], v. 10, n. 5, p. 199-207, 1 maio 2021. Red Iberoamericana de Pedagogia. <http://dx.doi.org/10.36260/rbr.v10i5.1297>.

HAMAD, Jaouda R. Jaouda; HANAFIAH, Marlia M.; ABDULLAH, Shardy. Problems and Current Practices of Solid Waste Management In The City Of Al-marj, Libya. **Journal Cleanwas**, [S.L.], v. 1, n. 1, p. 1-5, 10 jan. 2017. Zibeline International Publishing. <http://dx.doi.org/10.26480/jcleanwas.01.2017.01.05>.

HOLANDA, Lucas N.. An analysis of the Brazilian experience of plastic recycling taxation. **Green Deals in the Making**, [S.L.], p. 158-169, 19 ago. 2022. Edward Elgar Publishing. <http://dx.doi.org/10.4337/9781803926780.00023>.

HORNIK, Jacob; CHERIAN, Joseph; MADANSKY, Michelle; NARAYANA, Chem. Determinants of recycling behavior: A synthesis of research results. **The Journal of Socio-Economics**, v. 24, n. 1, p. 105–127, 1995.

HOURAN, Nouriddine; RAOUI, Hicham Ait; MANAAN, Mehdi; AABI, Ayoub; SIMOU, Mohamed Rabii; RHINANE, Hassan. USING GIS DATA AND MACHINE LEARNING FOR MINERAL MAPPING. STUDY CASE, BOU SKOUR EASTERN ANTI-ATLAS, MOROCCO. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, [S.L.], v. -4/6-2022, p. 423-430, 9 fev. 2023. Copernicus GmbH. <http://dx.doi.org/10.5194/isprs-archives-4lviii-4-w6-2022-423-2023>.

IBGE. **Belo Horizonte - Panorama**, 2024a. Disponível em: <https://cidades.ibge.gov.br/brasil/mg/belo-horizonte/panorama>. Acesso em: 13 jan. 2024.

IBGE. **Censo Demográfico 2010**, 2010. Disponível em: <https://censo2010.ibge.gov.br/>. Acesso em: 16 abr. 2024.

IBGE. **Censo Demográfico 2022**, 2023. Disponível em: <https://censo2022.ibge.gov.br/>. Acesso em: 16 abr. 2024.

IBGE. **Fortaleza - Panorama**, 2024b. Disponível em: <https://cidades.ibge.gov.br/brasil/ce/fortaleza/panorama>. Acesso em: 13 jan. 2024.

IBGE. **Guarulhos - Panorama**, 2024c. Disponível em: <https://cidades.ibge.gov.br/brasil/sp/guarulhos/panorama>. Acesso em: 13 jan. 2024.

IBIAPINA, Iveltyma Roosemalen Passos; LEOCADIO, Aurio; LAZARO, Jose Carlos; ROMERO, Claudia Buhamra Abreu. The Culture and Personal Disposal Practices of University Students: a qualitative study in brazil and germany. **Journal of Education For Sustainable Development**, [S.L.], v. 15, n. 1, p. 51-71, mar. 2021. SAGE Publications. <http://dx.doi.org/10.1177/09734082211002436>.

ISWA. **Global Waste Management Outlook 2024**. 2024. Disponível em: <https://www.iswa.org/wp-content/uploads/2024/05/15-May-IFAT-GWMO-2024-Session-Note-final.pdf>. Acesso em: 30 mai. 2024.

ITO, Marcia Harumi; COLOMBO, Renata. Resíduos volumosos no município de São Paulo: gerenciamento e valorização. **Urbe. Revista Brasileira de Gestão Urbana**, [S.L.], v. 11, 2019. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/2175-3369.011.e20180117>.

JASIM, Ali Kareem; WALLI, Hazim Abed. Analysis of Hotspots and Inverse Distance Weighting (IDW) of Polluted Habitats using ArcGIS Pro.: a case study in the sea of najaf and surrounding terrestrial area. **Iop Conference Series: Earth and Environmental Science**, [S.L.], v. 1215, n. 1, p. 012005, 1 jul. 2023. IOP Publishing. <http://dx.doi.org/10.1088/1755-1315/1215/1/012005>.

JIANG, Xiaolu; ZOU, Bin; FENG, Huihui; TANG, Jingwen; TU, Yulong; ZHAO, Xiuge. Spatial distribution mapping of Hg contamination in subclass agricultural soils using GIS enhanced multiple linear regression. **Journal of Geochemical Exploration**, [S.L.], v. 196, p. 1-7, jan. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.gexplo.2018.10.002>.

JUMAAH, Huda Jamal; AMEEN, Mohammed Hashim; KALANTAR, Bahareh; RIZEEI, Hossein Mojaddadi; JUMAAH, Sarah Jamal. Air quality index prediction using IDW geostatistical technique and OLS-based GIS technique in Kuala Lumpur, Malaysia. **Geomatics, Natural Hazards And Risk**, [S.L.], v. 10, n. 1, p. 2185-2199, 1 jan. 2019. Informa UK Limited. <http://dx.doi.org/10.1080/19475705.2019.1683084>.

JUNDIAÍ. **Ecopontos**. 2023. Disponível em: <https://jundiai.sp.gov.br/infraestrutura-e-servicos-publicos/limpeza-publica/ecopontos/>. Acesso em: 12 fev. 2024.

KARIM, Mohammed Abdul; WETTERHAN, John Taylor. A comparative study of solid waste management in the United States, Europe and Asia. **Annals Of Civil And Environmental Engineering**, [S.L.], v. 4, n. 1, p. 003-011, 17 abr. 2020. Heighten Science Publications Corporation. <http://dx.doi.org/10.29328/journal.acee.1001019>.

KASSAMBARA, Alboukadel. **Machine Learning Essentials: Practical Guide in R**. STHDA, 2018. 209 p.

KERBER, Jaqueline Carneiro; SOUZA JÚNIOR, Henrique Rogério Antunes de; HASSEMER, Maria Eliza Nagel; BOUZON, Marina. Preliminary study for implementation of voluntary delivery points of expanded polystyrene: a case in southern brazil. **Production**, [S.L.], v. 30, 2020. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0103-6513.20190069>.

KHANAL, Ashish. Forecasting municipal solid waste generation using linear regression analysis: a case of kathmandu metropolitan city, nepal. **Multidisciplinary Science Journal**, [S.L.], v. 5, n. 2, p. 2023019, 8 abr. 2023. Malque Publishing. <http://dx.doi.org/10.31893/multiscience.2023019>.

LAEEQUDDIN, Mohammed; ABDUL, Waheed Kareem; SAHAY, Vinita; TIWARI, Aviral Kumar. Factors That Influence the Safe Disposal Behavior of E-Waste by Electronics Consumers. **Sustainability**, [S.L.], v. 14, n. 9, p. 4981, 21 abr. 2022. MDPI AG. <http://dx.doi.org/10.3390/su14094981>.

LEDERER, Simone; HESKES, Tom; VAN HEERINGEN, Simon J.; ALBERS, Cornelis. Investigating the effect of dependence between conditions with Bayesian Linear Mixed Models for motif activity analysis. **Plos One**, [S.L.], v. 15, n. 5, p. 1-25, 1 maio 2020. Public Library of Science (PLoS). <http://dx.doi.org/10.1371/journal.pone.0231824>.

LIMA, Francisco de Paula Antunes; GONÇALVES, Juliana Teixeira; CAMPOS, Larissa Sousa; SILVA, Diogo Tunes Alvares da; SOUZA, Marcelo Alves de. Elementos Operacionais de Modelos de Coleta Seletiva. In: GONÇALVES-DIAS, Sylmara; ZIGLIO, Luciana; CSEH, Amanda (Eds.). **Coleta Seletiva de Resíduos Sólidos Urbanos: Experiências Internacionais e Nacionais**. [s.l.]: Editora Blucher, 2022, p. 51–74

LISBOA, Ana Catharina Nobre; BELEZA, Tatiana De Nazaré Moraes; CARDOSO, Ana Tereza Amorim; SOUSA, Ellen Thaís Nunes de; ARAÚJO, Ana Regina da Rocha; SOUSA, Luiz Augusto Silva de. PLANO DE GESTÃO DE RESÍDUOS SÓLIDOS PARA A UNIVERSIDADE FEDERAL RURAL DA AMAZÔNIA CAMPUS BELÉM. **Agromazon**, v. 1, n. 2, p. 205–220, 2022.

LYNHAM, Paul. From data to information. In: MOTTRAM, Toby (Ed.). **Digital Agritechnology: Robotics and Systems for Agriculture and Livestock Production**. [s.l.]: Elsevier, 2022, p. 11–47.

LU, Mingzhen; ZHOU, Chuanbin; WANG, Chenghao; JACKSON, Robert B.; KEMPES, Christopher P.. Worldwide scaling of waste generation in urban systems. **Nature Cities**, [S.L.], v. 1, n. 2, p. 126-135, 17 jan. 2024. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s44284-023-00021-5>.

MACAPÁ. **Saiba onde fazer o descarte correto de materiais recicláveis e lixo eletrônico nos Ecopontos de Macapá**. 2023. Disponível em: <https://macapa.ap.gov.br/saiba-onde-fazer-o-descarte-correto-de-materiais-reciclaveis-e-lixo-eletronico-nos-ecopontos-de-macapa/>. Acesso em: 20 ago. 2023.

MACEDO, Luciana Alves Rodrigues; LANGE, Liséte Celina; FERREIRA, Cynthia Fantoni Alves; GUTIÉRREZ, Ricardo Alberto. Proposal of a sustainability index for intermunicipal cooperation on waste management. **Waste Management & Research: The Journal for a Sustainable Circular Economy**, [S.L.], v. 41, n. 11, p. 1674-1683, 2 jun. 2023. SAGE Publications.
<http://dx.doi.org/10.1177/0734242x231166307>.

MACEIÓ. **Prefeitura de Maceió disponibiliza cinco ecopontos para descarte correto de resíduos**. 2023. Disponível em:
<https://maceio.al.gov.br/noticias/alurb/prefeitura-de-maceio-disponibiliza-cinco-ecopontos-para-descarte-correto-de-residuos>. Acesso em: 20 ago. 2023.

MANICA, Everton Josué; JOHANN, Liana. Avaliação do conhecimento de alunos do ensino médio sobre o destino dos resíduos sólidos domésticos. **Revista Brasileira de Educação Ambiental (Revbea)**, [S.L.], v. 14, n. 4, p. 74-86, 4 dez. 2019. Universidade Federal de Sao Paulo.
<http://dx.doi.org/10.34024/revbea.2019.v14.9672>.

MATTSON, Mark D.; GODFREY, Paul Jos. Identification of road salt contamination using multiple regression and GIS. **Environmental Management**, v. 18, n. 5, p. 767–773, 1994.

MAYES-RAMÍREZ, Martha María; GÁLVEZ-SÁNCHEZ, Francisco Jesús; RAMOS-RIDAO, Ángel Fermín; MOLINA-MORENO, Valentín. Urban Waste: visualizing the academic literature through bibliometric analysis and systematic review. **Sustainability**, [S.L.], v. 15, n. 3, p. 1846, 18 jan. 2023. MDPI AG.
<http://dx.doi.org/10.3390/su15031846>.

MERRY, Krista; BETTINGER, Pete; CROSBY, Michael; BOSTON, Kevin. Geographic information systems. In: **Geographic Information System Skills for Foresters and Natural Resource Managers**. [s.l.]: Elsevier, 2023, p. 1–23.

MEYER, Hanna; PEBESMA, Edzer. Predicting into unknown space? Estimating the area of applicability of spatial prediction models. **Methods In Ecology And Evolution**, [S.L.], v. 12, n. 9, p. 1620-1633, 26 jul. 2021. Wiley.
<http://dx.doi.org/10.1111/2041-210x.13650>.

Ministério do Meio Ambiente; ICLEI - Governos Locais pela Sustentabilidade. **Planos de gestão de resíduos sólidos: manual de orientação**. Brasília: Ministério do Meio Ambiente, 2012.

NASA JPL. **NASADEM Merged DEM Global 1 arc second V001**. 2021. Disponível em: <https://doi.org/10.5069/G93T9FD9>. Acesso em: 01 fev. 2024.

NASA. **GIS at NASA: Expanding the Understanding of Earth Science**. 2023. Disponível em: <https://www.earthdata.nasa.gov/learn/gis>. Acesso em: 20 out. 2023.

NATAL. **Ecopontos**. 2023. Disponível em:
<https://www.natal.rn.gov.br/urbana/ecopontos>. Acesso em: 20 ago. 2023.

ONU, 2014. **System of Environmental-Economic Accounting 2012—Central Framework**. Disponível em:

https://unstats.un.org/unsd/envaccounting/seearev/seea_cf_final_en.pdf. Acesso em: 25 out. 2023.

OYEDELE, Akintunde; OMOSEKEJI, Ayobami E.; AYENI, Olusola; EWUMI, Taofeek; OGUNLANA, Funmilola Olusola. Delineation of Landfill Sites for Municipal Solid Waste Management using GIS. **Journal of Human, Earth, and Future**, [S.L.], v. 3, n. 3, p. 321-332, 1 set. 2022. Ital Publication. <http://dx.doi.org/10.28991/hef-2022-03-03-05>.

PALMAS. **FMA inicia reforma de ecopontos da Capital**. 2023. Disponível em: <https://www.palmas.to.gov.br/portal/noticias/fma-inicia-reforma-de-ecopontos-da-capital/36343/>. Acesso em: 20 ago. 2023.

PAN, Xiaoduo; NAKAMURA, Hiroyuki; TAMOTSU, Nozaki; NAN, Zhuotong. A GIS-based landslide hazard assessment by multiple regression analysis. **Spie Proceedings**, [S.L.], 10 jun. 2007. SPIE. <http://dx.doi.org/10.1117/12.764899>.

PARÁ. Secretaria de Meio Ambiente e Sustentabilidade. **Semas entrega 4º Ecoponto e incentiva uso da moeda verde na Cabanagem, em Belém**. 2023. Disponível em: <https://www.semas.pa.gov.br/2023/02/02/semas-entrega-4o-ecoponto-e-incentiva-uso-da-moeda-verde-na-cabanagem-em-belem/>. Acesso em: 20 ago. 2023.

PAZ, Diogo Henrique Fernandes da; LAFAYETTE, Kalinny Patrícia Vaz; SOBRAL, Maria do Carmo. GIS-based planning system for managing the flow of construction and demolition waste in Brazil. **Waste Management & Research: The Journal for a Sustainable Circular Economy**, [S.L.], v. 36, n. 6, p. 541-549, 18 maio 2018. SAGE Publications. <http://dx.doi.org/10.1177/0734242x18772096>.

PIERCE, Francis J.; CLAY, David (Orgs.). **GIS Applications in Agriculture**. [s.l.]: CRC Press, 2007.

PISANO, Viviane; DEMAJOROVIC, Jacques; BESEN, Gina Rizpah. The Brazilian National Solid Waste Policy: perspectives of the waste pickers ∴ cooperative networks. **Ambiente & Sociedade**, [S.L.], v. 25, 2022. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/1809-4422asoc20210151r1ft>.

PNUD. Atlas do Desenvolvimento Humano no Brasil. **Bases do Censo e das UDHS por Regiões Metropolitanas**. 2024. Disponível em: <http://www.atlasbrasil.org.br/acervo/biblioteca>. Acesso em: 10 jan. 2024.

PNUD; FUNDAÇÃO JOÃO PINHEIRO; IPEA (Orgs.). **O Índice de Desenvolvimento Humano Municipal Brasileiro**. Brasília, Distrito Federal: PNUD, 2013. 96p.

PORTO ALEGRE. Departamento Municipal de Limpeza Urbana. **Destino Certo (Ecopontos)**. 2023. Disponível em: <https://prefeitura.poa.br/dmlu/projetos/destino-certo-ecopontos>. Acesso em: 20 ago. 2023.

POSIT, 2024. Posit Software, PBC. **RStudio: Integrated Development Environment for R**. Disponível em: <http://www.posit.co/>. Acesso em: 5 jan. 2024.

QGIS, 2024a. QGIS Association. **QGIS 3.34. Geographic Information System User Guide**. Disponível em: https://docs.qgis.org/3.34/en/docs/user_manual/index.html/. Acesso em: 1 mai. 2024.

QGIS, 2024b. QGIS Association. **QGIS Geographic Information System**. Disponível em: <http://www.qgis.org/>. Acesso em: 5 jan. 2024.

QIAO, Pengwei; YANG, Sucai; WEI, Wenxia; LI, Peizhong; CHENG, Yanjun; LIANG, Shuang; LEI, Mei; CHEN, Tongbin. Effectiveness of predicting spatial contaminant distributions at industrial sites using partitioned interpolation method. **Environmental Geochemistry and Health**, [S.L.], v. 43, n. 1, p. 23-36, 22 jul. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10653-020-00673-5>.

RAHEJA, Hemant; GOEL, Arun; PAL, Mahesh. Assessment and Modeling of Groundwater Quality Using GIS and Machine Learning Techniques for Drinking Purpose. **World Environmental and Water Resources Congress 2023**, [S.L.], p. 1092-1112, 18 maio 2023. American Society of Civil Engineers. <http://dx.doi.org/10.1061/9780784484852.100>.

RANDAZZO, Luciana; CUSUMANO, Antonio; OLIVERI, Giuseppe; STEFANO, Pietro di; RENDA, Pietro; PERRICONE, Marcella; ZARCONE, Giuseppe. LANDFILL SITE SELECTION FOR MUNICIPAL SOLID WASTE BY USING AHP METHOD IN GIS ENVIRONMENT: waste management decision-support in sicily (italy). **Detritus**, [S.L.], v. 2, n. 1, p. 78, 2018. Eurowaste SRL. <http://dx.doi.org/10.31025/2611-4135/2018.13656>.

RECIFE. Secretaria de Infraestrutura e Serviços Urbanos. **Conheça as Ecoestações**. 2023. Disponível em: <https://recifelimpa.recife.pe.gov.br/conheca-as-ecoestacoes/>. Acesso em: 20 ago. 2023.

RIBEIRÃO PRETO. **Ecopontos**. 2024. Disponível em: <https://www.ribeiraopreto.sp.gov.br/recicla/ecopontos>. Acesso em: 12 fev. 2024.

RIO BRANCO. **Prefeitura de Rio Branco realiza abertura da Semana de Educação Ambiental na capital**. 2023. Disponível em: <https://www.riobranco.ac.gov.br/?p=87040>. Acesso em: 20 ago. 2023.

RIO DE JANEIRO. Companhia Municipal de Limpeza Urbana. **Comlurb inaugura três Ecopontos na Zona Oeste da cidade**. 2023. Disponível em: <https://prefeitura.rio/comlurb/comlurb-inaugura-tres-ecopontos-na-zona-oeste-da-cidade/>. Acesso em: 20 ago. 2023.

RIO DE JANEIRO. Lei nº 4.191, de 30 de setembro de 2003. Estabelece diretrizes para a gestão dos resíduos sólidos no Estado do Rio de Janeiro. Diário Oficial [do] Estado do Rio de Janeiro, Rio de Janeiro, RJ, 1 out. 2003. Disponível em: https://www.rio.rj.gov.br/dlstatic/10112/1017211/DLFE-229310.pdf/Lei4.1.9.1._PoliticaEstadualRS.pdf. Acesso em: 5 abr. 2024.

RODRIGUES, Mikael T.; RODRIGUES, Bruno T.; MONTE, Benicio E. O. APRECIÇÃO DE MÉTODOS DE INTERPOLAÇÃO EM DADOS PLUVIOMÉTRICOS E SUA DISTRIBUIÇÃO ESPACIAL. **Revista Brasileira de Engenharia de Biosistemas**, v. 6, n. 1, p. 01–07, 2012.

ROJAS-AVELLANEDA, D. Spatial interpolation techniques for estimating levels of pollutant concentrations in the atmosphere. **Revista mexicana de física**, v. 53, n. 6, p. 447–454, 2007.

ROY, Debananda; TARAFDAR, Abhrajyoti. Solid Waste Management and Landfill in High-Income Countries. **Circular Economy In Municipal Solid Waste Landfilling: Biomining & Leachate Treatment**, [S.L.], p. 1-23, 2022. Springer International Publishing. http://dx.doi.org/10.1007/978-3-031-07785-2_1.

RUTKOWSKI, Jacqueline; RUTKOWSKI, Emília. Recycling in Brasil: paper and plastic supply chain. **Resources**, [S.L.], v. 6, n. 3, p. 43, 29 ago. 2017. MDPI AG. <http://dx.doi.org/10.3390/resources6030043>.

SADOUN, Balqies. GIS Applications to City Planning Engineering: In: GHAOUI, Claude (Org.). **Encyclopedia of Human Computer Interaction**. [s.l.]: IGI Global, 2006, p. 234–241.

SAIKH, Nur Islam; MONDAL, Prolay. GIS-based machine learning algorithm for flood susceptibility analysis in the Pagla river basin, Eastern India. **Natural Hazards Research**, [S.L.], v. 3, n. 3, p. 420-436, set. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.nhres.2023.05.004>.

SAKANYI, Gift. Managing Municipal Solid Waste Issues; Sources, Composition, Disposal, Recycling, and Volarization, Chililabombwe District, Zambia. **Texila International Journal of Public Health**, [S.L.], p. 42-54, 29 dez. 2022. Texila International Marketing Management. <http://dx.doi.org/10.21522/tijph.2013.10.04.art005>.

SALVADOR. Empresa de Limpeza Urbana de Salvador. **Ecoponto**. 2023. Disponível em: <https://limpurb.salvador.ba.gov.br/ecoponto/>. Acesso em: 20 ago. 2023.

SÃO LUÍS. Comitê Gestor de Limpeza Urbana. **Ecopontos**. 2023. Disponível em: <https://saoluis.ma.gov.br/comitedelimpeza/conteudo/2165>. Acesso em: 20 ago. 2023.

SÃO PAULO. **Ecopontos**. 2023a. Disponível em: https://www.prefeitura.sp.gov.br/cidade/secretarias/spregula/residuos_solidos/ecopontos/index.php?p=4626. Acesso em: 20 ago. 2023.

SÃO PAULO. Secretaria Executiva de Limpeza Urbana. **Pontos de Entrega Voluntária (PEV's)**. 2023b. Disponível em:

https://www.prefeitura.sp.gov.br/cidade/secretarias/subprefeituras/secretaria_executiva_de_limpeza_urbana/?p=350659. Acesso em: 12 fev. 2024.

SÃO PAULO. Lei nº 12.300, de 16 de março de 2006. Institui a Política Estadual de Resíduos Sólidos e define princípios e diretrizes. Diário Oficial [do] Estado de São Paulo, São Paulo, SP, 17 mar. 2006. Disponível em:

<https://www.al.sp.gov.br/repositorio/legislacao/lei/2006/lei-12300-16.03.2006.html>. Acesso em: 5 abr. 2024.

SCHMIDT, Amand F.; FINAN, Chris. Linear regression and the normality assumption. **Journal of Clinical Epidemiology**, [S.L.], v. 98, p. 146-151, jun. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.jclinepi.2017.12.006>.

SELURB. **Índice de Sustentabilidade da Limpeza Urbana – ISLU | edição 2022**.

Disponível em: <https://www.abrema.org.br/wp-content/uploads/2022/10/ISLU-2022a.pdf>. Acesso em 1 mai. 2024.

SEN, Archana. SOLID WASTE MANAGEMENT ISSUES AND CHALLENGES. **Pollution Research**, [S.L.], v. 41, n. 04, p. 1240-1245, 2022. EM International, Publishers of Quality International Journals. <http://dx.doi.org/10.53550/pr.2022.v41i04.015>.

SHARMA, Raj Kumar; JAILIA, Manisha. Regression Analysis of Garbage Management System for Smart Cities. **Proceedings of the 4th International Conference on Information Management & Machine Intelligence**, [S.L.], p. 1-8, 23 dez. 2022. ACM. <http://dx.doi.org/10.1145/3590837.3590910>.

SHEPARD, Donald. A two-dimensional interpolation function for irregularly-spaced data. **Proceedings of the 1968 23Rd Acm National Conference On -**, [S.L.], 1968. ACM Press. <http://dx.doi.org/10.1145/800186.810616>.

SILVA, Augusto Azevedo da; TEIXEIRA, Bernardo Arantes do Nascimento. ECOPONTOS: estudo de caso dos equipamentos urbanos para a gestão de resíduos sólidos. **Revista Aidis de Ingeniería y Ciencias Ambientales. Investigación, Desarrollo y Práctica**, [S.L.], v. 13, n. 2, p. 218, 6 ago. 2020. Universidad Nacional Autónoma de México. <http://dx.doi.org/10.22201/iingen.0718378xe.2020.13.2.62412>.

SILVA, Jonnathan Vinicius Lopes; SANTOS NETO, Narciso Ferreira dos. Location of ecopoints through integration p-medians model with geographical information system. **Gestão & Produção**, [S.L.], v. 27, n. 4, 2020. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0104-530x4011-20>.

SILVA, Veridiana Torres da; XAVIER, Antônio Roberto; KANIKADAN, Andrea Yumi Sugishita; AMORIM, Aiala Vieira; PINTO, Olienaide Ribeiro de Oliveira; TAVARES, Rosalina Semedo de Andrade; MUNIZ, Karla Renata de Aguiar; FONSECA, Michella Rita Santos; LIMA, Maria Vandia Guedes; CYSNE, Marcus Rodney Portela. Urban

Solid Waste in Brazil: concept, characterization and regulation. **International Journal of Advanced Engineering Research and Science**, [S.L.], v. 9, n. 7, p. 061-071, 2022. AI Publications. <http://dx.doi.org/10.22161/ijaers.97.6>.

SINGHAL, Brij Bhusan Saran; GUPTA, Ravi P. Geographical Information System (GIS). In: SINGHAL, Brij Bhusan Saran; GUPTA, Ravi P. (Eds.). **Applied Hydrogeology of Fractured Rocks**. Dordrecht: Springer Netherlands, 2010, p. 95–113.

SOUZA, Fernando da Silva; MENDES, Júlia Castro; MORAIS, Lya Júlia Barbosa; SILVA, Jônatas Santos; PEIXOTO, Ricardo André Fiorotti. Mapping and recycling proposal for the construction and demolition waste generated in the Brazilian Amazon. **Resources, Conservation and Recycling**, [S.L.], v. 176, p. 105896, jan. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.resconrec.2021.105896>.

SOUZA, Luana Lima; LOBO, Ronilson Rosário; MOREIRA, Darci Augusto; BRITO, Rodolfo Pereira; PEREIRA JÚNIOR, Antônio. Estudo da viabilidade técnica de reutilização dos rejeitos da construção civil e reforma. **Research, Society and Development**, [S.L.], v. 10, n. 9, 24 jul. 2021. Research, Society and Development. <http://dx.doi.org/10.33448/rsd-v10i9.17842>.

SOUZA, Ricardo Gabbay. E-waste situation and current practices in Brazil. In: PRASAD, Majeti Narasimha Vara; VITHANAGE, Meththika; BORTHAKUR, Anwasha (Eds.). **Handbook of Electronic Waste Management**. [s.l.]: Elsevier, 2020, p. 377–396.

STAMP, Laurence Dudley. **The Geography of Life and Death**. Ithaca: Cornell University Press, 1964. 160 p.

STARBUCK, Craig. Predictive Modeling. In: STARBUCK, Craig (Ed.). **The Fundamentals of People Analytics**. Cham: Springer International Publishing, 2023, p. 239–260.

SUBEDI, Shukra Raj; POUDEL, Jiban M; SUBEDI, Madhusudan; SHARMA, Bigyan; SUBEDI, Sunil; NEUPANE, Bhim P; LAMICHHANE, Basanta L; NEUPANE, Badri N; BOHARA, Krishna K; SHRESTHA, Gopi L. Challenges of Consumer Culture and Solid-waste to the Environment Protection in Pokhara Metropolitan City, Nepal. **Research Square**, [S.L.], 2023. Research Square Platform LLC. <http://dx.doi.org/10.21203/rs.3.rs-2124991/v2>.

SUKHOLTHAMAN, Pitchayanin; CHANVARASUTH, Pisit; SHARP, Alice. Analysis of waste generation variables and people's attitudes towards waste management system: a case of bangkok, thailand. **Journal of Material Cycles And Waste Management**, [S.L.], v. 19, n. 2, p. 645-656, 16 dez. 2015. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10163-015-0456-x>.

SUMATHI, V.R.; NATESAN, Usha; SARKAR, Chinmoy. GIS-based approach for optimized siting of municipal solid waste landfill. **Waste Management**, [S.L.], v. 28, n.

11, p. 2146-2160, nov. 2008. Elsevier BV.
<http://dx.doi.org/10.1016/j.wasman.2007.09.032>.

SUPER DATA SCIENCE. **Assumptions of Linear Regression**. 2022. Disponível em: <https://www.superdatascience.com/blogs/assumptions-of-linear-regression>. Acesso em 15 mai. 2024.

SUZUKI, Toru. Application of Multiple Regression Analysis to Extract Promising Areas of Kuroko Deposits in the Hokuroku Area, Akita pref., Japan. **Shigen-to-Sozai**, v. 119, n. 4/5, p. 149–154, 2003.

TANG, Kuok Ho Daniel. Valorization of Plastic Waste through Incorporation into Construction Materials. **Civil and Sustainable Urban Engineering**, [S.L.], v. 2, n. 2, p. 96-109, 6 dez. 2022. Tecno Scientifica Publishing.
<http://dx.doi.org/10.53623/csue.v2i2.141>.

TEIXEIRA, Amandio; MATIAS, Lindon; NOAL, Rosa Elena; MORETTI, Edmar. Qual a melhor definição de SIG. **Fator GIS**, Curitiba, n.11, p.20-24, 1995.

THIVES, Liseane Padilha; GHISI, EneDir; THIVES JÚNIOR, Juarez Jonas. Assessment of disposal and recycling of waste tyres in Brazil. **Ciência e Natura**, [S.L.], v. 44, 18 abr. 2022. Universidade Federal de Santa Maria.
<http://dx.doi.org/10.5902/2179460x68822>.

TIMLETT, R.E.; WILLIAMS, Ian D.. The impact of transient populations on recycling behaviour in a densely populated urban environment. **Resources, Conservation and Recycling**, [S.L.], v. 53, n. 9, p. 498-506, jul. 2009. Elsevier BV.
<http://dx.doi.org/10.1016/j.resconrec.2009.03.010>.

TOHIT, Nor Faiza Mohd.; HASSAN, Noor Artika; FARHAN, Mohammad; AIDID, Edre Mohammad; RUS, Razman Mohd. SOLID WASTE: its implication for health and risk of vector borne diseases. **Journal of Wastes and Biomass Management**, [S.L.], v. 1, n. 2, p. 14-17, 30 dez. 2019. Zlbeline International Publishing.
<http://dx.doi.org/10.26480/jwbm.02.2019.14.17>.

USGS. **What is a geographic information system (GIS)?**. 2023. Disponível em: <https://www.usgs.gov/faqs/what-geographic-information-system-gis>. Acesso em: 20 out. 2023.

VAN FAN, Yee; KLEMES, Jiří Jaromír; LEE, Chew Tin; TAN, Raymond R.. Demographic and socio-economic factors including sustainability related indexes in waste generation and recovery. **Energy Sources, Part A: Recovery, Utilization, and Environmental Effects**, [S.L.], p. 1-14, 9 set. 2021. Informa UK Limited.
<http://dx.doi.org/10.1080/15567036.2021.1974610>.

VELIS, Costas A.; WILSON, David C.; GAVISH, Yoni; GRIMES, Sue M.; WHITEMAN, Andrew. Socio-economic development drives solid waste management performance in cities: a global analysis using machine learning. **Science of The Total Environment**, [S.L.], v. 872, p. 161913, maio 2023. Elsevier BV.
<http://dx.doi.org/10.1016/j.scitotenv.2023.161913>.

VIEIRA, Bárbara de Oliveira; GUARNIERI, Patricia; SILVA, Lucio Camara e; ALFINITO, Solange. Prioritizing Barriers to Be Solved to the Implementation of Reverse Logistics of E-Waste in Brazil under a Multicriteria Decision Aid Approach. **Sustainability**, [S.L.], v. 12, n. 10, p. 4337, 25 maio 2020. MDPI AG. <http://dx.doi.org/10.3390/su12104337>.

VIEIRA, Davi de Melo; LIMA, Mayara da Silva; BASTOS, Juceline Batista dos Santos; FARIAS, Teresa Raquel Lima. Contribuições aos estudos sobre a aplicação do Resíduo de Construção e Demolição (RCD) na composição de camadas de pavimentos no Brasil. **Revista Tecnologia**, [S.L.], v. 42, n. 2, p. 14, 2 set. 2022. Fundação Edson Queiroz. <http://dx.doi.org/10.5020/23180730.2022.12133>.

VILLARROYA, Sebastian; VIQUEIRA, Jose R. R.; COTOS, Jose M.; TABOADA, Jose A.. Enabling Efficient Distributed Spatial Join on Large Scale Vector-Raster Data Lakes. **Ieee Access**, [S.L.], v. 10, p. 29406-29418, 2022. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/access.2022.3157405>.

VINCENZI, Ticiana Braga de; PIAO, Roberta Souza; VAZQUEZ-BRUST, Diego; CARVALHO, Marly M. de. The Coordination of Packaging Recycling Chain in Brazil. **Springer Proceedings in Mathematics & Statistics**, [S.L.], p. 421-433, 2021. Springer International Publishing. http://dx.doi.org/10.1007/978-3-030-78570-3_32.

VITÓRIA. **Estação Bota-Fora é instalada em antigo ponto irregular de lixo de Santa Lúcia**. 2023. Disponível em: <https://m.vitoria.es.gov.br/noticias/estacao-bota-fora-e-instalada-em-antigo-ponto-irregular-de-lixo-de-santa-lucia-11721>. Acesso em: 20 ago. 2023.

WAHID, Wewin Wira Cornelis; SETYONO, Jawoto Sih. The Urban Environment and Public Health: associations between covid-19 cases and urban factors in semarang city, central java, indonesia. **Iop Conference Series: Earth and Environmental Science**, [S.L.], v. 1111, n. 1, p. 012067, 1 dez. 2022. IOP Publishing. <http://dx.doi.org/10.1088/1755-1315/1111/1/012067>.

WANG, Ziyuan. Spatial Differentiation Characteristics of Rural Areas Based on Machine Learning and GIS Statistical Analysis—A Case Study of Yongtai County, Fuzhou City. **Sustainability**, [S.L.], v. 15, n. 5, p. 4367, 1 mar. 2023. MDPI AG. <http://dx.doi.org/10.3390/su15054367>.

WIKURENDRA, Edza; SYAFIUDDIN, Achmad; HERDIANI, Novera; NURIKA, Globila. Forecast of Waste Generated and Waste Fleetusing Linear Regression Model. **Polish Journal of Environmental Studies**, [S.L.], v. 32, n. 2, p. 1867-1876, 9 fev. 2023. HARD Publishing Company. <http://dx.doi.org/10.15244/pjoes/158779>.

XIE, Xiyu. Analysis on the Application of Linear Regression in Various Fields. **2020 3rd International Conference on Economic Management and Green Development**, p. 134–137, 2020.

ZHOU, Gui Liang; ZHU, Yan Ru; MAO, Li Na. Design of the Electronic Waste Recycle Network System Based on GIS. **Applied Mechanics and Materials**, v. 518, p. 381–386, 2014.

ZAMBRANO-MONSERRATE, Manuel A.; RUANO, Maria Alejandra; ORMEÑO-CANDELARIO, Vanessa. Determinants of municipal solid waste: a global analysis by countries ∴ income level. **Environmental Science and Pollution Research**, [S.L.], v. 28, n. 44, p. 62421-62430, 1 jul. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11356-021-15167-9>.