

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
CÂMPUS GOIÂNIA
MESTRADO PROFISSIONAL EM TECNOLOGIA, GESTÃO E SUSTENTABILIDADE

JOAQUIM ALVES DA SILVA JÚNIOR

Modelagem da Geração de Resíduos Sólidos Urbanos Através de Regressão Geograficamente Ponderada: Um Estudo De Caso no Estado de Goiás e Distrito Federal

Goiânia, 2025.

TERMO DE AUTORIZAÇÃO PARA DISPONIBILIZAÇÃO NO REPOSITÓRIO DIGITAL DO IFG - ReDi IFG

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia de Goiás, a disponibilizar gratuitamente o documento no Repositório Digital (ReDi IFG), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IFG.

Identificação da Produção Técnico-Científica

☐	Tese	☐	Artigo Científico
☒	Dissertação	☐	Capítulo de Livro
☐	Monografia – Especialização	☐	Livro
☐	TCC - Graduação	☐	Trabalho Apresentado em Evento

Nome Completo do Autor: Joaquim Alves da Silva Junior

Matrícula: 20232011280298

Título do Trabalho: Dataset com a geração de resíduos sólidos urbanos e seus condicionantes nos municípios de Goiás e do Distrito Federal

Autorização - Marque uma das opções

(x) Autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso aberto);

() Autorizo disponibilizar meu trabalho no Repositório Digital do IFG somente após a data ____/____/____ (Embargo);

() Não autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso restrito).

Ao indicar a opção **2 ou 3**, marque a justificativa:

() O documento está sujeito a registro de patente.

() O documento pode vir a ser publicado como livro, capítulo de livro ou artigo.

() Outra justificativa: _____

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

- o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia de Goiás os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

_____, Goiânia, 16 / 11 / 2025.

gov.br
Documento assinado digitalmente
JOAQUIM ALVES DA SILVA JUNIOR
Data: 17/11/2025 14:23:16-0300
Verifique em <https://validar.ifg.gov.br>

Assinatura do Autor e/ou Detentor dos Direitos Autorais

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
CÂMPUS GOIÂNIA
MESTRADO PROFISSIONAL EM TECNOLOGIA, GESTÃO E SUSTENTABILIDADE

JOAQUIM ALVES DA SILVA JÚNIOR

Modelagem da Geração de Resíduos Sólidos Urbanos Através de Regressão Geograficamente Ponderada: Um Estudo De Caso no Estado de Goiás e Distrito Federal

Programa de Pós-Graduação *Stricto Sensu* em Tecnologia, Gestão e Sustentabilidade do Instituto Federal de Educação, Ciência e Tecnologia de Goiás - Dissertação de Mestrado Profissional. Área de Concentração: Tecnologia de Sistemas de Produção Limpa. Linha de Pesquisa: Modelagem de Sistemas.

Orientador: Prof. Dra. Regina Célia Bueno da Fonseca

Coorientador: Prof. Dr. Alex Mota dos Santos

Goiânia, 2025.

S586m Silva Junior, Joaquim Alves da.

Modelagem da geração de resíduos sólidos urbanos através de regressão geograficamente ponderada: um estudo de caso no Estado de Goiás e Distrito Federal / Joaquim Alves da Silva Junior. – Goiânia: Instituto Federal de Educação, Ciência e Tecnologia de Goiás, 2025.
104f.

Orientação: Prof. Dra. Regina Célia Bueno da Fonseca.

Dissertação (mestrado) – Programa de Pós-Graduação Stricto Sensu em Tecnologia, Gestão e Sustentabilidade, Instituto Federal de Educação, Ciência e Tecnologia de Goiás.
Inclui apêndices.

1. Resíduos sólidos. 2. Indicadores socioeconômicos. 3. Sustentabilidade. I. Fonseca, Regina Célia Bueno da (orientação). II. Instituto Federal de Educação, Ciência e Tecnologia de Goiás. III. Título.

CDD 628.445



INSTITUTO FEDERAL
Goiás

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
CÂMPUS GOIÂNIA

PARECER 28/2025 - GYN-CMTGS/GYN-GPPEX/CP-GOIANIA/IFG

**SERVIÇO PÚBLICO FEDERAL
INSTITUTO FEDERAL DE EDUCAÇÃO CIÊNCIA E TECNOLOGIA DE GOIÁS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
IFG CÂMPUS GOIÂNIA
MESTRADO EM TECNOLOGIA, GESTÃO E SUSTENTABILIDADE**

JOAQUIM ALVES DA SILVA JUNIOR

**MODELAGEM DA GERAÇÃO DE RESÍDUOS SÓLIDOS URBANOS ATRAVÉS DE REGRESSÃO
GEOGRAFICAMENTE PONDERADA: UM ESTUDO DE CASO NO ESTADO DE GOIÁS E DISTRITO FEDERAL**

Dissertação apresentada ao Programa de Pós-Graduação em Tecnologia,
Gestão e Sustentabilidade do Instituto Federal de Educação, Ciência e
Tecnologia de Goiás como requisito parcial à obtenção do título de Mestre.
Área de Concentração: Tecnologia de Sistemas de Produção Limpa.
Linha de Pesquisa: Modelagem de sistemas

Aprovação em 03 de outubro de 2025.

Banca examinadora:

Presidente e orientadora: Profa. Dra. Regina Célia Bueno da Fonseca - PPGTGS IFG

Coorientador: Prof. Dr. Alex Mota dos Santos - PPGTGS IFG

Avaliadora: Profa. Dra. Thamy Barbara Gioia - GAPI/UEL LAGICRIARTE/UFG

Avaliador: Prof. Dr. Carlos Fabrício Assunção da Silva - UFPE/Recife

Avaliadora: Profa. Dra. Lidiaine Maria dos Santos - PPGTGS/IFG

Documento assinado eletronicamente por:

- **Carlos Fabrício Assunção da Silva**, Carlos Fabricio Assunção da Silva - Docente - Universidade Federal de Pernambuco (24134488000108), em 17/11/2025 11:37:24.
- **Alex Mota dos Santos**, Alex Mota dos Santos - Docente - Ufg (01567601000143), em 17/10/2025 18:39:39.
- **Lidiaine Maria dos Santos**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 15/10/2025 20:02:37.
- **Thamy Barbara Gioia**, THAMY BARBARA GIOIA - Docente - Uel (78640489000153), em 15/10/2025 16:58:16.
- **Regina Celia Bueno da Fonseca**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 15/10/2025 13:50:39.

Este documento foi emitido pelo SUAP em 14/10/2025. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifg.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 703679

Código de Autenticação: a696b4ec12



Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Rua 75, nº 46, Centro, GOIÂNIA / GO, CEP 74055-110
Sem Telefones cadastrados

Dedicatória

Dedico este trabalho à minha família, pelo amor e pelo suporte que moldaram minha trajetória, e aos meus amigos, que com palavras de incentivo e gestos de amizade iluminaram meus dias mais difíceis. Dedico a todos que, de alguma forma, acreditaram em mim, me inspiraram e caminharam ao meu lado, pois sem vocês esta conquista não teria o mesmo significado. Que este esforço sirva como lembrança de que cada desafio pode ser superado com fé, dedicação e apoio daqueles que amamos.

Agradecimentos

Primeiramente, agradeço a Deus, por me conceder a oportunidade de trilhar este caminho e por me proporcionar perseverança, paciência, força, sabedoria e inteligência para superar cada desafio deste percurso. Aos meus pais, agradeço pelo apoio incondicional, cada um à sua maneira, que tornou possível minha caminhada acadêmica e pessoal. Aos meus orientadores, expresso minha gratidão pelo empenho, pelos ensinamentos e pela orientação que me guiaram ao longo desta jornada. Por fim, agradeço de coração aos meus amigos, que me ofereceram apoio, incentivo e reconhecimento, muitas vezes enxergando em mim o valor que eu mesmo ainda não sabia. A todos vocês, minha sincera e eterna gratidão.

São as pequenas coisas que os cidadãos fazem. É isso que fará a diferença. Minha pequena coisa é plantar árvores.

Wangari Maathai,
1940-2011.

Resumo

Título: Modelagem da Geração de Resíduos Sólidos Urbanos Através de Regressão Geograficamente Ponderada: Um Estudo De Caso no Estado de Goiás e Distrito Federal

Autor: Joaquim Alves da Silva Júnior

Orientador: Dra. Regina Célia Bueno da Fonseca

Coorientador: Prof. Dr. Alex Mota dos Santos

O estudo desenvolveu uma investigação aprofundada sobre a geração de resíduos sólidos urbanos (RSU) no estado de Goiás e no Distrito Federal, tendo como referência a crescente complexidade dos processos de urbanização e os desafios associados à gestão ambiental contemporânea. Partindo do reconhecimento de que a produção de resíduos constitui um fenômeno socioespacialmente heterogêneo, a pesquisa adotou como objetivo compreender como variáveis socioeconômicas, demográficas e ambientais se relacionam com os padrões de geração de resíduos, considerando sua distribuição desigual no território. Para tanto, foram utilizados dados oficiais recentes, abrangendo variáveis como densidade populacional, taxa de alfabetização, tamanho médio dos domicílios, Produto Interno Bruto (PIB) *per capita*, número de empregos formais, além de fatores climáticos, todos integrados em bases georreferenciadas. A modelagem foi conduzida em duas etapas: inicialmente aplicou-se a regressão linear múltipla global (*Ordinary Least Squares* - OLS) para identificar variáveis significativas e aferir problemas de multicolinearidade; posteriormente, empregou-se a regressão geograficamente ponderada (*Geographically Weighted Regression* - GWR), técnica capaz de revelar a não estacionariedade espacial dos parâmetros e oferecer estimativas locais mais precisas. Os resultados evidenciaram o superior desempenho da GWR, que explicou aproximadamente 99% da variabilidade na geração de resíduos, superando o modelo global e confirmando a pertinência da abordagem espacial. A análise revelou padrões regionais distintos: nas áreas metropolitanas de Goiânia e Brasília, densidade populacional e tamanho dos domicílios se mostraram fortemente relacionados à intensificação da produção de resíduos; no entorno de Brasília, os fluxos migratórios e as famílias numerosas exerceram papel relevante; em contrapartida, em regiões rurais, observou-se maior aderência a práticas tradicionais de reutilização e menor impacto do crescimento

demográfico sobre a geração de resíduos. Um achado particularmente expressivo foi a relação inversa entre PIB *per capita* e produção de RSU em diversos municípios, reflexo de economias agroexportadoras que elevam indicadores econômicos sem necessariamente ampliar o consumo urbano. Contudo, a variável que mais se destacou foi o número de empregos formais, que apresentou correlação universalmente positiva com a geração de resíduos em todos os municípios, indicando que a formalização do trabalho, ao ampliar a renda disponível, converte-se em maior consumo e descarte, independentemente da localização. Essa constatação reforça que o desenvolvimento econômico e o aumento do emprego devem caminhar em consonância com estratégias de mitigação ambiental, a fim de evitar sobrecargas nos sistemas de coleta e tratamento. Do ponto de vista metodológico, onde foi realizada uma revisão de literatura e a modelagem por meio da GWR, a pesquisa evidencia a importância de instrumentos analíticos capazes de captar heterogeneidades territoriais, enquanto, no plano aplicado, ressalta a necessidade de políticas regionais adaptadas às especificidades locais, que articulem desenvolvimento econômico e sustentabilidade. Nesse sentido, os achados fornecem subsídios estratégicos para gestores públicos, ao mesmo tempo em que ampliam o debate acadêmico sobre o uso de modelos espaciais avançados para a gestão de resíduos sólidos em realidades complexas e desiguais.

Palavras-chave

Variabilidade espacial; Indicadores socioeconômicos; Planejamento sustentável; Emprego formal; Governança ambiental.

Abstract

Title: Modeling Municipal Solid Waste Generation through Geographically Weighted Regression: A Case Study in the State of Goiás and the Federal District

Author: Joaquim Alves da Silva Júnior

Advisor: Dra. Regina Célia Bueno da Fonseca

Coadvisor: Prof. Dr. Alex Mota dos Santos

The study conducted an in-depth investigation into the generation of municipal solid waste (MSW) in the state of Goiás and the Federal District, taking as a reference the increasing complexity of urbanization processes and the challenges associated with contemporary environmental management. Starting from the recognition that waste production constitutes a socio-spatially heterogeneous phenomenon, the research aimed to understand how socioeconomic, demographic, educational, and environmental variables relate to waste generation patterns, considering their unequal distribution across the territory. For this purpose, recent official data were used, covering variables such as population density, literacy rate, average household size, GDP per capita, number of formal jobs, in addition to climatic factors, all integrated into georeferenced databases. The modeling was conducted in two stages: initially, multiple linear regression (OLS) was applied to identify significant variables and assess multicollinearity issues; subsequently, geographically weighted regression (GWR) was employed, a technique capable of revealing the spatial non-stationarity of parameters and providing more precise local estimates. The results demonstrated the superior performance of GWR, which explained approximately 99% of the variability in waste generation, surpassing the global model and confirming the pertinence of the spatial approach. The analysis revealed distinct regional patterns: in the metropolitan areas of Goiânia and Brasília, population density and household size were strongly related to the intensification of waste production; in the Brasília metropolitan fringe, migratory flows and large families played a relevant role; in contrast, in rural regions, adherence to traditional reuse practices and a weaker impact of demographic growth on waste generation were observed. A particularly significant finding was the inverse relationship between GDP per capita and MSW production in several municipalities, reflecting agro-export economies that elevate

economic indicators without necessarily increasing urban consumption. However, the variable that stood out the most was the number of formal jobs (EMPFOR), which showed a universally positive correlation with waste generation in all municipalities, indicating that job formalization, by increasing disposable income, translates into greater consumption and disposal regardless of location. This finding reinforces that economic development and employment growth must progress in harmony with environmental mitigation strategies to avoid overloading collection and treatment systems. From a methodological standpoint, the research highlights the importance of analytical instruments capable of capturing territorial heterogeneities, while at the applied level, it emphasizes the need for regional policies adapted to local specificities, articulating economic development and sustainability. In this sense, the findings provide strategic inputs for public managers while also broadening the academic debate on the use of advanced spatial models for solid waste management in complex and unequal realities.

Keywords

Spatial variability; Socioeconomic indicators; Sustainable planning; Formal employment; Environmental governance.

Lista de Figuras

Figura 1	– Síntese do procedimento metodológico.....	31
Figura 2	– Evolução da produção anual de artigos (2011–2022)	33
Figura 3	– Países com maior número de produção sobre o tema em estudo	34
Figura 4	– Rede de coautoria	35
Figura 5	– Rede de coocorrência de palavras-chave, cores indicam clusters colaborativos	36
Figura 6	– Mapa temático que associa a aplicação da GWR em estudos de resíduos sólidos	37
Figura 7	– Filiações acadêmicas mais relevantes	39
Figura 8	– Mapa detalhado do estado de Goiás com o Distrito Federal (DF)	49
Figura 9	– Fluxograma metodológico para modelagem da geração de resíduos sólidos urbanos por meio de regressão geograficamente ponde- rada no estado de Goiás e no Distrito Federal	56
Figura 10	– Distribuição espacial da qualidade do ajuste local (R^2) do modelo GWR nos municípios de Goiás e Distrito Federal	62
Figura 11	– Distribuição espacial dos coeficientes de densidade populaci- onal (POPDEN) nos municípios de Goiás e Distrito Federal.....	64
Figura 12	– Distribuição espacial dos coeficientes de tamanho médio dos domicílios (TAMDOM) nos municípios de Goiás e Distrito Federal	66
Figura 13	– Distribuição espacial dos coeficientes de taxa de alfabetização (TXALF) nos municípios de Goiás e Distrito Federal	69
Figura 14	– Distribuição espacial dos coeficientes de PIB <i>per capita</i> (PIBPCAPT) nos municípios de Goiás e Distrito Federal.....	71
Figura 15	– Distribuição espacial dos coeficientes de emprego formal (EMPFOR) nos municípios de Goiás e Distrito Federal	73

Lista de Tabelas

Tabela 1	– Definições e fontes das variáveis utilizadas.	50
Tabela 2	– Resultados do Modelo OLS: Significância ($\Pr(> t)$) e Multicolinearidade (VIF) das Variáveis Preditoras Iniciais	57
Tabela 3	– Resultados do modelo de regressão linear (OLS)	58
Tabela 4	– Testes de diagnóstico dos resíduos do modelo OLS.....	59
Tabela 5	– Resumo dos coeficientes estimados pelo modelo GWR.....	60
Tabela 6	– Indicadores globais e testes de diagnóstico do modelo GWR .	61

Lista de Símbolos

<i>OLS</i>	<i>Ordinary Least Squares</i>
<i>POPDEN</i>	Densidade populacional
<i>TAMDOM</i>	Tamanho dos domicílios
<i>TXALF</i>	Taxa de alfabetização
<i>TEMPM</i>	Temperatura média anual
<i>PRECIPM</i>	Precipitação média anual
<i>EMPFOR</i>	Emprego formal
<i>PIB</i>	Produto Interno Bruto
<i>PIBPCAPT</i>	PIB <i>per capita</i>
<i>TXFESC</i>	Taxa de frequência escolar bruta
<i>MEDEST</i>	Número médio de anos de estudo das pessoas com 11 anos ou mais
<i>VIF</i>	<i>Variance Inflation Factor</i>
<i>p</i>	p-valor
<i>AICc</i>	<i>kaike Information Criterion corrected</i>
R^2	Coefficiente de determinação
<i>GWR</i>	<i>Geographically Weighted Regression</i>
<i>RIDE – DF</i>	Região Integrada de Desenvolvimento do Distrito Federal e Entorno
<i>DF</i>	Distrito Federal
<i>DNIT</i>	Departamento Nacional de Infraestrutura de Transportes
<i>RSU</i>	Resíduos Sólidos Urbanos
<i>ASG</i>	Ambiental, Social e Governança
<i>LOESS</i>	<i>Locally Estimated Scatterplot Smoothing</i>
<i>SAR</i>	<i>Spatial Autoregressive</i>
<i>SEM</i>	<i>Spatial Error Models</i>
<i>Bx</i>	Pacote Bibliometrix
<i>IBGE</i>	Instituto Brasileiro de Geografia e Estatística
<i>IA</i>	Inteligência Artificial
<i>OMS</i>	Organização Mundial da Saúde
<i>PNRS</i>	Política Nacional de Resíduos Sólidos
<i>UTM</i>	<i>Universal Transverse Mercator</i>
<i>ABRELPE</i>	Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais
<i>MSW</i>	<i>Municipal Solid Waste</i>
<i>ABREMA</i>	Associação Brasileira de Resíduos e Meio Ambiente
<i>CKA</i>	Curva Ambiental de Kuznets

Sumário

1	Introdução	18
1.1	Contextualização	18
1.2	Estado da Arte	20
1.3	Problema de Pesquisa	22
1.4	Objetivos	22
1.4.1	Objetivo Geral	22
1.4.2	Objetivos Específicos	22
1.5	Metodologia da pesquisa	23
1.6	Perguntas da pesquisa	24
1.7	Relevância	24
1.8	Esboço da dissertação	24
2	Regressão Geograficamente Ponderada Aplicada às Pesquisas em Resíduos Sólidos: Uma Revisão de Literatura	26
2.1	Introdução	26
2.2	Procedimentos Metodológicos	29
2.3	Resultados e Discussões	32
2.4	Considerações Finais	41
3	Modelagem da Geração de Resíduos Sólidos Urbanos Através de Regressão Geograficamente Ponderada: Um Estudo de Caso no Estado de Goiás e Distrito Federal	43
3.1	Introdução	44
3.2	Procedimentos Metodológicos	48
3.2.1	Área de Estudo	48
3.2.2	Dados e Informações	49
3.2.3	Processamento dos Dados e Informações	51
3.2.4	Procedimentos Metodológicos	52
3.3	Resultados e Discussões	56
3.3.1	Qualidade do modelo GWR para estimativas de taxas de geração de RSU com base no R^2	61
3.3.2	Densidade Populacional (POPDEN)	63
3.3.3	Tamanho Médio dos Domicílios (TAMDOM)	65
3.3.4	Taxa de Alfabetização (TXALF)	68
3.3.5	PIB <i>per capita</i> (PIBPCAPT)	70
3.3.6	Empregos Formais (EMPFOR)	72
3.3.7	Discussão Integrada dos Resultados	75

3.4	Conclusão	77
4	Considerações finais	80
4.1	Contribuições da pesquisa	80
4.2	Limitações do estudo	81
4.3	Sugestões para pesquisas futuras	81
4.4	Conclusão	82
	Referências	84
	Apêndice A – Script em R - Pacote Bibliometrix	106
	Apêndice B – Mapa do Estado de Goiás e a localização de seus municípios	107

Introdução

1.1 Contextualização

O crescimento populacional acelerado e a urbanização desordenada representam alguns dos principais desafios ambientais contemporâneos, configurando-se como forças motrizes na intensificação da geração de resíduos sólidos urbanos em escala global (Zhang *et al.*, 2024). A rápida migração de populações rurais para centros urbanos tem escalado exponencialmente a demanda por recursos naturais como água, energia e alimentos, resultando em impactos ambientais significativos que comprometem a sustentabilidade dos ecossistemas urbanos (Sarwar; Junaid; Alvi, 2024).

Este fenômeno de urbanização acelerada, caracterizado pela concentração populacional em áreas metropolitanas, tem gerado pressões sem precedentes sobre os sistemas de gestão ambiental, particularmente no que se refere ao manejo adequado dos resíduos sólidos urbanos (Zhang *et al.*, 2024). As projeções indicam que a produção mundial de resíduos urbanos deve saltar de 2,2 bilhões de toneladas anuais em 2025 para 3,4 bilhões de toneladas anuais em 2050, evidenciando a magnitude do desafio que se apresenta para as próximas décadas. A população urbana mundial deve constituir aproximadamente 70% da população total até 2050, intensificando ainda mais as pressões sobre os sistemas de gestão de resíduos e infraestrutura urbana (Zhang *et al.*, 2024).

A gestão inadequada dos resíduos sólidos urbanos acarreta externalidades ambientais negativas que ultrapassam as fronteiras locais, manifestando-se por meio da contaminação de solos, corpos d'água e atmosfera, além da proliferação de vetores de doenças e degradação da qualidade de vida urbana (IEA Bioenergy, 2025). Os processos de decomposição natural dos resíduos sólidos municipais produzem gases de efeito estufa, principalmente dióxido de carbono e metano, contribuindo significativamente para as mudanças climáticas globais quando não adequadamente controlados (Zhang *et al.*, 2024).

A expansão descontrolada da infraestrutura urbana necessita da conversão de habitats naturais em ambientes construídos, resultando em perda de biodiversidade e fragmentação de ecossistemas, fatores que amplificam as pegadas ecológicas¹ das atividades humanas. As áreas urbanas geram vastas quantidades de resíduos, incluindo resíduos sólidos e águas residuais, que demandam recursos energéticos e financeiros substanciais para coleta, tratamento e disposição final adequada (Sarwar; Junaid; Alvi, 2024). A eficiência dos sistemas de coleta de resíduos sólidos municipais em países em desenvolvimento permanece significativamente inferior, atingindo apenas 40% em comparação aos 90% observados em países desenvolvidos (Zhang *et al.*, 2024).

As disparidades socioeconômicas entre nações desenvolvidas e em desenvolvimento evidenciam-se claramente nos padrões de gestão de resíduos sólidos urbanos, onde economias emergentes enfrentam deficiências estruturais na logística de coleta, transporte e tratamento adequado (Zhang *et al.*, 2024). A incerteza de políticas econômicas tem emergido como preocupação proeminente nos últimos anos, especialmente em economias emergentes, onde mudanças regulatórias e volatilidade política podem ter implicações abrangentes para o desenvolvimento sustentável (Sun *et al.*, 2025).

A qualidade ambiental, como indicador-chave de sustentabilidade de longo prazo, frequentemente torna-se vulnerável a tais incertezas, podendo resultar em políticas ambientais atrasadas ou inconsistentes e investimentos insuficientes em infraestrutura ambiental (Sun *et al.*, 2025). As pegadas ecológicas desempenham papel crucial na avaliação de como as atividades humanas impactam o meio ambiente, servindo como indicadores fundamentais para o monitoramento da sustentabilidade ambiental (Sarwar; Junaid; Alvi, 2024). A gestão inovadora de resíduos e a adoção de abordagens de gestão mais sustentáveis podem resultar em benefícios significativos para a sociedade, minimizando impactos adversos através da implementação de tecnologias limpas e práticas de economia circular (IEA Bioenergy, 2025).

O desenvolvimento de estratégias eficazes para a gestão sustentável de resíduos sólidos urbanos requer a integração de políticas públicas ambientais robustas, investimentos em tecnologias inovadoras e participação ativa da sociedade civil (Sun *et al.*, 2025). Os investimentos em sustentabilidade ambiental através de finanças verdes² servem para proteger contra condições econômicas adversas e melhorar

¹Pegada ecológica é um indicador ambiental que mede a quantidade de área biologicamente produtiva (terras e águas) necessária para sustentar o consumo de uma população ou atividade humana, incluindo a produção de recursos e a absorção de resíduos (WWF-Brasil, 2012).

²Finanças verdes ou *Green bonds* são títulos emitidos para a captação de recursos voltados a investimentos em projetos sustentáveis. Tais títulos são emitidos no âmbito dos padrões ASG (ambiental, social e governança) (MAPA, 2025).

a resiliência ecológica dos sistemas urbanos. As finanças verdes operam como moderador substancial nas relações entre incerteza econômica e qualidade ambiental, permitindo a redução de efeitos negativos através do direcionamento de recursos financeiros para projetos ambientalmente sustentáveis (Sun *et al.*, 2025). A compreensão aprofundada dos fatores socioeconômicos, demográficos e ambientais que influenciam a geração de resíduos sólidos urbanos torna-se fundamental para o desenvolvimento de modelos preditivos e estratégias de gestão adaptadas às especificidades regionais (Zhang *et al.*, 2024). A implementação de políticas ambientais integradas e o fortalecimento de mecanismos de financiamento verde representam elementos essenciais para a melhoria dos resultados ambientais em períodos de instabilidade econômica, particularmente em nações em desenvolvimento (Sun *et al.*, 2025).

1.2 Estado da Arte

A gestão de resíduos sólidos urbanos (RSU) é uma preocupação importante nas cidades que crescem rapidamente, impondo custos e impactos ambientais (Velis *et al.*, 2023). Para planejar e operar sistemas de manejo de forma eficaz, é importante estimar o volume de RSU gerado (Alzamora *et al.*, 2022). A dificuldade em obter dados de campo sobre a geração de RSU torna a previsão baseada em fatores sociais e econômicos uma alternativa necessária. Estudos globais indicam que o aumento populacional e o desenvolvimento econômico sugerem um crescimento contínuo na geração de RSU (He *et al.*, 2022).

Trabalhos identificam o Produto Interno Bruto (PIB), a renda e a população como elementos importantes que influenciam a quantidade de RSU (Alzamora *et al.*, 2022). Em países em desenvolvimento, o crescimento da economia e a expansão urbana são os principais fatores que moldam a geração de resíduos (Liu; Wu, 2011). Além disso, o aumento da população em áreas urbanas é reconhecido como o fator socioeconômico de maior impacto, especialmente em países grandes onde essa taxa de crescimento é notável (Chhay *et al.*, 2018).

A influência da renda na produção de resíduos varia bastante e nem sempre é positiva, o que gera resultados diversos. Na região de Anantapur, na Índia, o grupo com maior status socioeconômico é o que apresenta a maior geração de resíduos por pessoa (Donthi; Ramannagari, 2025). Da mesma forma, em Guwahati, a taxa de resíduos por pessoa é mais alta em grupos de alta renda do que nos de média ou baixa (Singh; Naik; Uppaluri, 2024). Entretanto, uma pesquisa em Chennai observou o oposto: residências de menor renda tendem a produzir um volume maior, possivelmente pelo uso frequente de produtos descartáveis (Deshpande *et al.*, 2024).

Métodos estatísticos comuns, como a Regressão Linear Múltipla, são utilizados por sua simplicidade, mas têm dificuldades em capturar as relações não lineares dos dados de RSU (Alzamora *et al.*, 2022). Por isso, modelos de Aprendizado de Máquina (ML) e Inteligência Artificial (IA) são cada vez mais usados para prever a geração de resíduos. O modelo *Random Forest Regressor* (RFR) apresentou a melhor precisão na previsão de vários tipos de resíduos em países da OCDE (Dunkel *et al.*, 2022). Além disso, o modelo híbrido otimizado MARS-CSA demonstrou resultados superiores a outros algoritmos de ML, como as Redes Neurais Artificiais (ANN) (Ghanbari; Kamalan; Sarraf, 2021).

Os avanços em Aprendizado Profundo, como o modelo *Long Short-Term Memory* (LSTM), têm mostrado ser o método mais preciso para prever a geração de RSU quando integrados com variáveis demográficas (Srivastava; Jha, 2023). A combinação de modelos, como o uso de *Stacked Denoising Autoencoder* (SDAE) com *bagging* (SDAE-B), também resulta em uma precisão maior na previsão da produção de RSU (Zhao; Li, 2023). No desenvolvimento de modelos de IA, identificar os fatores mais importantes é bem importante, e o método híbrido MI-SHAP tem sido utilizado para selecionar variáveis mais expressivas como população e renda (Nourani *et al.*, 2025).

A falta de confiabilidade nos dados globais sobre resíduos é um obstáculo para estabelecer um sistema de conhecimento mundial que seja consistente (He *et al.*, 2022). Por isso, é importante que as estratégias de gestão de resíduos sejam adaptadas ao contexto específico de cada localidade, considerando fatores socioeconômicos regionais (Kala; Bolia, 2020). Análises globais mostram que os índices de desenvolvimento socioeconômico do país são capazes de explicar grande parte da diferença de desempenho dos sistemas de gestão de RSU nas cidades (Velis *et al.*, 2023).

Para modelar a geração de RSU de forma mais detalhada, a literatura utiliza ferramentas de análise espacial, como a Regressão Geograficamente Ponderada (GWR) (Singh; Naik; Uppaluri, 2024). No decorrer do texto, usa-se a abreviação GWR (em inglês), que refere-se a ferramenta Regressão Geograficamente Ponderada (em português).

A GWR é considerada mais eficaz que a regressão linear simples, pois leva em conta como a relação entre os fatores socioeconômicos e a produção de resíduos muda em diferentes unidades geográficas (Alzamora *et al.*, 2022). Essa metodologia ajuda a entender que a influência de variáveis como a renda podem variar muito, dependendo da área analisada dentro da cidade, algo importante para o planejamento urbano (Liu; Wu, 2011).

Diante desse cenário, é importante compreender as variáveis que influen-

ciam a geração de resíduos sólidos urbanos, especialmente em contextos regionais com características socioeconômicas e ambientais específicas. Essa compreensão é importante para orientar o desenvolvimento de modelos preditivos eficientes e a formulação de políticas públicas que promovam uma gestão sustentável e adaptada às demandas locais. Assim, a investigação dos fatores que impactam a geração de resíduos sólidos urbanos emerge como um passo essencial para enfrentar os desafios apresentados e contribuir para a sustentabilidade dos sistemas urbanos.

1.3 Problema de Pesquisa

Quais são os fatores socioeconômicos, demográficos e climáticos que influenciam a geração de resíduos sólidos em Goiás e Distrito Federal e como esses fatores variam espacialmente em diferentes regiões do estado?

1.4 Objetivos

1.4.1 Objetivo Geral

Compreender como variáveis socioeconômicas, demográfica e ambientais se relacionam com os padrões de geração de resíduos urbanos no estado de Goiás e Distrito Federal por meio do modelo de regressão geograficamente ponderada.

1.4.2 Objetivos Específicos

- Obter os dados socioeconômicos do Censo Demográfico Brasileiro de 2022 na site do Instituto Brasileiro de Geografia e Estatística (IBGE);
- Identificar e selecionar as variáveis socioeconômicas e climáticas com maior potencial explicativo para a variação espacial da taxa de geração de resíduos sólidos;
- Analisar os padrões espaciais da taxa de geração de resíduos sólidos e sua relação com as variáveis;
- Discutir o papel das condições socioeconômicas e climáticas como determinantes espaciais da geração de resíduos sólidos, considerando as variações locais apontadas pelo modelo;
- Identificar e avaliar possíveis *clusters* para cada variável de entrada do modelo em relação ao resultado final;
- Usar o método Regressão Geograficamente Ponderada
- Aplicar dois testes estatísticos (Índice de Moran e Teste de Shapiro-Wilk) para validação dos dados.

1.5 Metodologia da pesquisa

A metodologia desta pesquisa foi composta por duas etapas principais, que se complementam na análise da geração de resíduos sólidos urbanos a partir de uma perspectiva espacial. A primeira etapa corresponde a uma revisão de literatura que integrou métodos bibliométricos e sistemáticos. Utilizou-se o pacote *Bibliometrix* no ambiente RStudio e a interface *Biblioshiny* para analisar publicações indexadas na base *Scopus* entre 2011 e 2022, a partir da expressão “*geographically weighted regression*” AND “*solid waste*”. Essa abordagem permitiu identificar tendências na produção científica, autores mais relevantes, temas centrais e lacunas metodológicas e regionais. Para aprofundar a análise qualitativa, foi utilizada a ferramenta de inteligência artificial NotebookLM, a fim de examinar métodos, dados e resultados dos estudos mapeados.

Na segunda etapa, foi aplicado o método *Geographically Weighted Regression* (GWR) nos 246 municípios do estado de Goiás e Distrito Federal. Inicialmente, realizou-se uma coleta de dados em fontes oficiais como o censo de 2022, compreendendo variáveis socioeconômicas, demográficas e climáticas. Após isso, foi feita a seleção de variáveis, iniciando-se pela regressão linear múltipla (*Ordinary Least Squares* - OLS) com verificação de multicolinearidade por meio do *Variance Inflation Factor* (VIF). Em seguida, foram aplicados os testes de Moran I e Shapiro-Wilk para o modelo OLS, com o objetivo de avaliar a presença de autocorrelação espacial e a normalidade dos resíduos. Depois dessa etapa, foi realizada a seleção da banda de vizinhança com base no *Akaike Information Criterion corrected* (AICc).

Na sequência, a GWR foi utilizada para identificar como os coeficientes das variáveis explicativas variam no espaço, revelando padrões locais na geração de resíduos sólidos urbanos. Após gerar o modelo GWR, também foram aplicados novamente os testes de Moran I e Shapiro-Wilk, para verificar o ajuste e o comportamento espacial do modelo resultante.

Para o desenvolvimento da dissertação, utilizou-se os procedimentos de Ismaila *et al.* (2015) que desenvolveram um modelo espacial para aprimorar a previsão e a gestão de resíduos sólidos urbanos (RSU) na Nigéria, com base em variáveis socioeconômicas, demográficas e climáticas, com a utilização do GWR para aprimorar a compreensão dos fatores que afetam a taxa de geração de RSU no país.

Muitas das variáveis socioeconômicas e demográficas da Nigéria (por exemplo, produção de petróleo bruto) diferenciam dessas variáveis que são utilizadas pelo IBGE³, na realização do Censo Demográfico no brasileiro.

³IBGE - Instituto Brasileiro de Geografia e Estatística, é um instituto público da administração federal brasileira. Este instituto é o principal provedor de dados e informações do território

1.6 Perguntas da pesquisa

Com respeito aos objetivos geral e específico, as perguntas dessa investigação sob a perspectiva metodológica são:

1. O método GWR consegue fornecer uma quantificação da relação espacial entre fatores socioeconômicos e a quantidade de resíduos sólidos urbanos gerados no estado de Goiás e no Distrito Federal?
2. Quais regiões concentram os estudos que aplicam GWR à problemática dos resíduos sólidos?
3. Como a qualidade e a disponibilidade dos dados espaciais influenciam os resultados e a confiabilidade dos estudos?
4. Que lacunas metodológicas e geográficas persistem, apontando direções para investigações futuras?
5. Os testes estatísticos (Índice de Moran e Teste de Shapiro-Wilk) conseguem validar os dados?

1.7 Relevância

A presente pesquisa se destaca por sua originalidade e atualidade ao utilizar, de forma pioneira, os dados do Censo Demográfico de 2022 para modelar a geração de resíduos sólidos urbanos (RSU) no estado de Goiás e Distrito Federal por meio da GWR. Até o momento, não se tem conhecimento de outros estudos que tenham explorado esse recorte espacial e temporal com essa metodologia no Brasil, o que evidencia uma significativa lacuna científica. Ao incorporar variáveis socioeconômicas, demográficas e de infraestrutura com alta granularidade, a dissertação preenche um vazio na literatura e fornece uma base robusta e inédita para compreensão das dinâmicas espaciais que influenciam a geração de RSU no contexto brasileiro. Essa abordagem é particularmente relevante em um cenário de crescente urbanização e desafios estruturais nos municípios, nos quais o planejamento da gestão de resíduos demanda ferramentas analíticas mais precisas e adaptadas às realidades regionais.

1.8 Esboço da dissertação

Esta dissertação está estruturada da seguinte forma: o Capítulo 2 está na forma de artigo, e descreve a revisão de literatura híbrida, com perspectivas bibli-

brasileiro, as quais atendem às necessidades dos mais diversos segmentos da sociedade civil, bem como dos órgãos das esferas governamentais federal, estadual e municipal.

ométrica e sistemática, para identificar a aplicação da Regressão Geograficamente Ponderada (*Geographically Weighted Regression* - GWR) em estudos sobre resíduos sólidos urbanos em escala global, no período de 2011 a 2022. O Capítulo 3 está escrito na forma de artigo, e é dedicado à condução da modelagem da geração de resíduos sólidos urbanos através do método regressão geograficamente ponderada, com foco no estado de Goiás e Distrito Federal. O Capítulo 4 apresenta as considerações da pesquisa, limitações do estudo, sugestões para pesquisas futuras e conclusões do trabalho, com reflexões sobre os resultados obtidos. No Apêndice A apresenta a descrição do *script* em R com o pacote bibliometrix, para realizar a revisão de literatura, com perspectiva bibliométrica. E no Apêndice B apresenta o mapa do estado de Goiás com a localização de seus municípios.

Regressão Geograficamente Ponderada Aplicada às Pesquisas em Resíduos Sólidos: Uma Revisão de Literatura

Resumo: O acelerado crescimento populacional, a urbanização desordenada e os padrões de consumo intensivo elevaram a geração de resíduos sólidos a um desafio global de saúde pública e sustentabilidade. Assim, é indispensável compreender não apenas “quanto” se descarta, mas “onde” e “por que” isso ocorre. Considerando esse contexto, a pesquisa tem como objetivo realizar uma revisão de literatura sobre o uso da Regressão Geograficamente Ponderada (*Geographically Weighted Regression* - GWR) em estudos relacionados aos resíduos sólidos. Adotou-se uma estratégia integrada: (i) análise bibliométrica, via pacote *Bibliometrix* no RStudio, a partir da *string* “*geographically weighted regression*” AND “*solid waste*” na *Scopus*; (ii) exploração dos metadados no Biblioshiny para mapear tendências temporais, países, autores e palavras-chave; e (iii) revisão sistemática qualitativa, realizada com o auxílio da IA NotebookLM, possibilitando o exame aprofundado de métodos, dados e resultados. Os achados revelam uma expansão média anual de 47% nas publicações, com pico em 2022 e predominância chinesa, e forte ênfase em temas como metais pesados, emissões de gases de aterro.

Palavras-chave: Modelos espaciais; Resíduos urbanos; Gestão ambiental; Políticas públicas; Análise bibliométrica

2.1 Introdução

A geração e a gestão de resíduos sólidos assumiram proporções críticas nas últimas décadas, impulsionadas pelo crescimento populacional, pela urbanização acelerada e pelos padrões de consumo intensivo. Os resíduos sólidos urbanos são os derivados do desenvolvimento urbano e são prejudiciais ao meio ambiente e à

saúde dos moradores (Liu *et al.*, 2019). Quanto maior a densidade populacional em uma região, maior o volume de lixo produzido e, consequentemente, a infraestrutura necessária para a gestão de resíduos (Voukkali *et al.*, 2024). Estima-se que, sem mudanças estruturais, a produção mundial de resíduos urbanos salte de 2,2 bilhões de toneladas/ano em 2025, para 3,4 bilhões toneladas/ano em 2050 (Kaza *et al.*, 2018). Esse avanço pressiona a infraestrutura urbana, compromete a saúde pública e intensifica a demanda por recursos naturais.

Nesse contexto, compreender onde e por que os resíduos se acumulam é tão crucial quanto quantificar o quanto se descarta. Os diagnósticos espaciais, portanto, tornam-se essenciais para orientar políticas públicas eficazes e sustentáveis (Akingbemisilu, 2024). A complexidade crescente na gestão de resíduos expõe disparidades marcantes entre países desenvolvidos e em desenvolvimento (Mazurek; Czapiewski, 2021). Enquanto nações de alta renda investem em tecnologias avançadas de reciclagem e remediação de aterros (OECD, 2022), economias emergentes enfrentam deficiências logísticas na coleta e no transporte (Nourqolipour *et al.*, 2015). Essas diferenças resultam em impactos ambientais, econômicos e sociais desiguais, que tendem a perpetuar injustiças territoriais.

Nos países desenvolvidos, legislações rigorosas coíbem aterros clandestinos, mas subsistem desafios em zonas periurbanas e industriais (Abdullah *et al.*, 2022). Políticas de incentivo fiscal à reciclagem fomentam cadeias de condicionamento de resíduos sólidos, reduzindo passivos ambientais (Jiao; Shuai; Li, 2024). Em contraste, centros urbanos de economias emergentes ainda destinam grande parte desses resíduos a aterros comuns, agravando a contaminação de solos e corpos d'água (Li *et al.*, 2019). Compreender a geografia dos resíduos, portanto, não é apenas exercício acadêmico, é requisito para justiça ambiental¹. As ferramentas de regressão local² desempenham um papel fundamental na identificação de áreas críticas, orientando a alocação eficiente de recursos em ações com maior potencial de impacto socioambiental (Antczak, 2019).

Essas evidências evidenciam a importância de análises que levem em conta as especificidades territoriais, uma vez que, sem essa perspectiva, políticas globais tendem a falhar diante da heterogeneidade dos contextos locais. Dessa forma, o uso de metodologias analíticas capazes de capturar variações espaciais torna-se imprescindível para embasar soluções adequadas à realidade de cada território. A

¹Justiça ambiental refere-se ao enfrentamento das disparidades sociais nas exposições ambientais e na saúde, com o objetivo de prevenir a injustiça ambiental nas comunidades (London *et al.*, 2011)

²Regressão Local, também conhecida como Regressão Localmente Ponderada ou LOESS (*Locally Estimated Scatterplot Smoothing*), é uma técnica estatística utilizada para modelar a relação entre variáveis em um conjunto de dados

ausência desse tipo de abordagem pode levar à adoção de políticas uniformes que, longe de resolver os problemas, acabam por acentuar desigualdades já existentes. Nesse cenário, a busca por métodos espaciais avançados surge como uma resposta estratégica. Compreender e explorar as heterogeneidades geográficas é essencial para o planejamento de políticas eficazes de reciclagem, remediação de áreas degradadas e coleta seletiva (Rybova, 2019).

Diversas metodologias avaliam a distribuição espacial da geração e do descarte de resíduos. Técnicas de interpolação, como a krigagem, estimam a intensidade de resíduos em superfícies contínuas, oferecendo mapas detalhados de concentração (Liu; Zhang; Shi, 2020). As análises de agrupamento revelam *hotspots* e padrões de produção de resíduos sólidos (Cui; Wei, 2024). Já as avaliações de múltiplos critérios espaciais difusos auxiliam na seleção de sítios de aterro (Kontos; Zevgolis, 2024).

As ferramentas de autocorrelação espacial, como o Moran's I, quantificam dependências entre variáveis socioeconômicas e ambientais, apontando *clusters* significativos (Cheng *et al.*, 2020). Modelos espaciais autorregressivos (*Spatial Autoregressive* - SAR) e de erro espacial (*Spatial Error Models* - SEM) avaliam a influência de fatores regionais na geração de resíduos, controlando a autocorrelação residual (Antczak, 2020; Suryowati *et al.*, 2021). Esses modelos ampliam a compreensão dos processos que moldam a distribuição dos resíduos, mas ainda pressupõem relações globais uniformes. Quando a heterogeneidade local é elevada, tais pressupostos podem distorcer resultados. Daí a necessidade de abordagens que permitam coeficientes variáveis no espaço, como a Regressão Geograficamente Ponderada (em inglês *Geographically Weighted Regression* - (GWR). No decorrer do texto, usa-se a abreviação GWR (em inglês), que refere-se a ferramenta Regressão Geograficamente Ponderada (em português).

A GWR calibra coeficientes localmente, superando a suposição de homogeneidade dos modelos globais (Chen *et al.*, 2022). Ao atribuir pesos espaciais aos dados, a GWR capta variações regionais, revelando como fatores socioeconômicos afetam a geração de resíduos em diferentes locais (Zhao; Fan; Zhou, 2021). A principal vantagem da GWR reside em mostrar como renda, densidade populacional e escolaridade impactam a geração de resíduos em escala local (Rybova; Burcin; Slavik, 2018). Modelos globais sugerem soluções padronizadas, potencialmente inadequadas para contextos heterogêneos. Em contrapartida, a GWR oferece evidências para políticas diferenciadas, respeitando especificidades territoriais (Wang; Zhang; Liu, 2022). Essa precisão é especialmente relevante em países emergentes, onde a infraestrutura de coleta é fragmentada e os recursos são limitados (Keser; Duzgun; Aksoy, 2012). Nos países desenvolvidos, a GWR auxilia no refinamento de políticas já consolidadas, apontando zonas onde a reciclagem enfrenta obstáculos persistentes.

tes (Antczak, 2020). Portanto, a técnica se mostra versátil e aplicável a múltiplos contextos.

Contudo, o acesso desigual a dados limita a adoção plena da GWR. Nações de alta renda contam com bancos de dados georreferenciados e séries históricas robustas, permitindo modelos sofisticados e abordagens multivariadas avançadas (Shao *et al.*, 2020; Zhang *et al.*, 2021). Economias emergentes, por sua vez, dependem de registros pontuais ou denúncias da população para localizar descarte ilegal (Yu *et al.*, 2014; Rehana *et al.*, 2020). Essa lacuna de informação reduz a confiabilidade dos modelos e restringe sua aplicabilidade. Iniciativas de coleta de dados colaborativos e sensores remotos surgem como alternativas promissoras (Abdullah *et al.*, 2022; Velez *et al.*, 2022). Ainda assim, a disparidade persiste, e superá-la é condição para ampliar o uso da GWR.

Diante da relevância sobre os preditores da produção de resíduos, das possibilidades da GWR e da ausência de pesquisas sobre o assunto em países em desenvolvimento, observa-se a necessidade de manipular dados e informações sobre os preditores da produção de resíduos sólidos. Por isso, esta pesquisa tem como objetivo realizar uma revisão de literatura sobre o uso da GWR em estudos relacionados aos resíduos sólidos. Ademais, busca responder às seguintes questões: quais regiões concentram os estudos que aplicam GWR à problemática dos resíduos sólidos? Como a qualidade e a disponibilidade dos dados espaciais influenciam os resultados e a confiabilidade dos estudos? Que lacunas metodológicas e geográficas persistem, apontando direções para investigações futuras? O artigo está estruturado em duas seções: a primeira apresenta a revisão sob a perspectiva bibliométrica; a segunda detalha metodologia e resultados sob a ótica sistemática.

2.2 Procedimentos Metodológicos

A revisão da literatura foi realizada de forma integrada, conjugando as abordagens bibliométrica e sistemática. Sob a perspectiva bibliométrica, que é quantitativa, empregou-se o pacote *Bibliometrix* (*Bx*) do software R para analisar diversos indicadores, em conformidade com a proposta de Aria e Cuccurullo (2017). Esse software, de código aberto, permite efetuar mapeamentos científicos completos e disponibiliza resultados objetivos, possibilitando identificar padrões de produção acadêmica, redes de cooperação, autores mais influentes e palavras-chave que caracterizam o campo investigado (Yalçıntaş *et al.*, 2023). Além disso, fornece uma série de indicadores quantitativos relacionados a um fluxo de pesquisa (Donthu *et al.*, 2021), com foco nas interconexões e centralidade dos estudos dentro de uma rede mais ampla.

Além de garantir transparência e reprodutibilidade, o uso do pacote *Bx* facilita futuras atualizações do levantamento, pois toda a rotina analítica pode ser compartilhada em *scripts* e aplicada sempre que novos registros forem incorporados. A seleção dos indicadores foi baseada no trabalho de Figueredo *et al.* (2020) e ajustada às necessidades específicas desta pesquisa. Desse modo, foram englobadas métricas como evolução anual das publicações, número médio de citações por artigo, principais países de origem, periódicos de maior impacto, além de informações sobre autores, afiliações e frequência de palavras-chave. Tais métricas oferecem uma visão multifacetada do campo, permitindo avaliar tanto a dinâmica temporal da produção científica quanto a sua distribuição geográfica e institucional.


Inicialmente, foi realizada a pesquisa nas bases *Scopus* e *Web of Science*, por meio da *string* de busca “*geographically weighted regression*” AND “*solid waste*”. Verificou-se que os poucos documentos provenientes da *Web of Science* já estavam incluídos no acervo recuperado na *Scopus*, razão pela qual se optou por manter exclusivamente esta última base e evitar duplicações desnecessárias (O’Dea *et al.*, 2021). A pesquisa, limitada ao período de 2011 a 2022, resultou em 179 registros, cujos metadados foram exportados no formato *bibtex* para posterior tratamento no RStudio.

A escolha desse intervalo temporal deve-se a quatro fatores complementares: (i) a revisão de literatura faz parte de uma pesquisa maior, que tem como objetivo um estudo de caso sobre a produção de resíduos sólidos no Brasil; (ii) o ano de 2011 corresponde ao primeiro ano completo após a promulgação e regulamentação da Política Nacional de Resíduos Sólidos (Lei N. 12.305/2010 e Decreto N. 7.404/2010), marco que intensificou a produção científica sobre gestão de resíduos no Brasil (Brasil, 2010); (iii) a partir de 2011 observa-se um salto nas aplicações da *Geographically Weighted Regression* (GWR) em estudos ambientais, impulsionado pela disponibilização do módulo GWR na versão 10 do ArcGIS e pela consequente difusão metodológica entre pesquisadores (Rosenshein; Scott; Pratt, 2011; Yang *et al.*, 2013); e (iv) o limite superior 2022 garante compatibilidade com os microdados socioeconômicos mais recentes divulgados pelo Censo Demográfico do Instituto Brasileiro de Geografia e Estatística (IBGE) de 2022.

O fluxo de trabalho replicou o modelo operacional de estudos que integram o *Bibliometrix* a revisões sistemáticas, como o descrito por Ndou e Rampedi (2022), que mapearam tendências globais na gestão de resíduos; Reis, Barreto e Capelari (2023) que relacionaram economia circular e manejo de resíduos sólidos; e Neto, Simões e Simoes (2024) que otimizaram a coleta de resíduos. Sendo assim, para fins de melhor entendimento estabeleceram-se algumas etapas, conforme apresentado na Figura 1. Na Etapa 1: definição das *strings* de busca usando palavras-chave

em inglês, obtenção dos documentos em formato .bibtex das bases de dados *web of science* e *scopus*, e exportação dos metadados; Etapa 2: limpeza e eliminação de duplicatas e criar listas para análises por meio de um *script* em R, usando a interface RStudio; Etapa 3: exportação de dados para a produção de tabelas dos resultados (indicadores contemplados) e suas visualizações gráficas geradas pela ferramenta web do *Bibliometrix*, denominada *Biblioshiny*. Etapa 4: revisão sistemática com o apoio de Inteligência Artificial (IA) utilizando a plataforma Google NotebookLM; e Etapa 5: síntese qualitativa dos documentos elegíveis.

Figura 1 – Síntese do procedimento metodológico



Fonte: Elaborada pelo autor.

Assim, na Etapa 1 (Figura 1) foi definida como *string* "geographically weighted regression" AND "solid waste", realizada busca por meio do Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), através do sistema da Comunidade Acadêmica (CAFe) das bases de dados *Web of Science* (WoS) e *Scopus* (Sco). Na Etapa 2, para a limpeza e eliminação de artigos duplicados, e criar listas para análises, utilizou-se um *script* em R (ver Apêndice A) com o pacote *bibliometrix*, e compilado na interface RStudio, versão 4.2.

A Etapa 3 seguiu os procedimentos propostos por Aria e Cuccurullo (2017), onde os dados obtidos na interface RStudio são redirecionados e abertos no navegador Microsoft Edge do Sistema Operacional Windows, na página web do *Biblioshiny*, com recursos do pacote *Bibliometrix*. Nesta página web do *Biblioshiny* são obtidos os gráficos, mapas, nuvens de palavras, entre outros, dos dados quantitativos dos indicadores bibliométricos, e também exportar as planilhas eletrônicas desses dados, em formatos .xlsx e .csv (Aria; Cuccurullo, 2017).

Na Etapa 4, a abordagem sistemática foi desenvolvida sobre todos os documentos quantitativos mapeados pela bibliometria, selecionados na Etapa 3. Pela análise sistemática, observou-se, então, os objetivos dos estudos, os aspectos metodológicos, com foco na análise de como a disponibilidade dos dados espaciais influencia os resultados e a confiabilidade dos estudos, as escalas de análise e os principais achados. Para essa etapa, empregou-se a ferramenta online Google NotebookLM, a fim de identificar aspectos qualitativos sobre o tema em análise. O Google NotebookLM³ é uma plataforma com tecnologia de IA, e desenvolvida pelo Google Labs, com arquitetura Gemini (Google, 2023), viabilizando a análise automaticamente os documentos enviados e fará um resumo do conteúdo a extração automatizada de trechos relevantes e a organização temática dos conteúdos analisados.

Na Etapa 5, procedeu-se à síntese qualitativa dos documentos elegíveis, com base nos resultados obtidos pela revisão sistemática anterior. Essa etapa teve como objetivo integrar os achados centrais dos estudos selecionados, agrupando-os em categorias temáticas recorrentes, tais como: objetivos de pesquisa, variáveis analisadas, fontes de dados espaciais, estratégias metodológicas adotadas e principais conclusões. A sistematização qualitativa permitiu identificar lacunas na literatura, tendências emergentes e oportunidades para futuras investigações no campo da modelagem espacial aplicada à gestão de resíduos sólidos. Essa fase conclusiva assegurou uma visão abrangente e crítica do panorama científico analisado, contribuindo diretamente para o embasamento teórico e metodológico da pesquisa.

2.3 Resultados e Discussões


Da perspectiva bibliométrica foi possível observar o crescimento no número das publicações da temática analisada no período de 2011 a 2022. Observou-se que entre 2014 e 2016 houve uma estabilidade, com poucos registros de publicações, inclusive uma leve queda em 2016. A partir de 2017, o número de documentos sobe para 8, salta para 17 em 2019 e praticamente dobra em 2020, atingindo 26 publicações. Esse ritmo de crescimento atinge o biênio seguinte, alcançando 39 estudos em 2021 e o pico de 59 em 2022. Esse comportamento representa um crescimento médio anual de cerca de 47% nos últimos cinco anos (Figura 2).

A tendência de crescimento constante do número de publicações pode sugerir o amadurecimento do tema na comunidade científica ou uma intensificação da relevância do assunto nos últimos anos. A maturidade do campo reflete-se na

³Para usar o NotebookLM é preciso ter uma conta Google e acessar a plataforma pelo link: <https://notebooklm.google.com>

elevação das citações médias por artigo após 2019, superando trinta menções anuais, limiar que sinaliza consolidação teórica (Hoz-M; Fernandez-Gómez; Mendes, 2022). Esse cenário pode ser associado à difusão de pacotes estatísticos de código aberto, do barateamento de imagens de satélite e da pressão de organismos multilaterais por diagnósticos espaciais refinados. Ademais, tais fatores reduziram barreiras técnicas e financeiras para grupos de pesquisa de médio porte, impulsionando a adoção da GWR como ferramenta padrão na análise ambiental (Agyeman *et al.*, 2022).

Figura 2 – *Evolução da produção anual de artigos (2011–2022)*




Fonte: Elaborada pelo autor.

No que diz respeito à distribuição espacial da produção analisada, observa-se o protagonismo da China e dos Estados Unidos da América (Figura 3). Por outro lado, partes da Europa e Oceania exibem menor número de documentos publicados nas plataformas consultadas. A África e América do Sul apresentaram produção modesta, apenas um e dois países publicaram, respectivamente, nas plataformas analisadas.

A proeminência da China, responsável pelo maior número de artigos e citações. Esse dado vai ao encontro do que Li, Han e Lu (2018) já apontavam, dizendo que a rápida industrialização e urbanização chinesas, questões como a geração de resíduos e a contaminação do solo têm despertado o interesse de pesquisadores e autoridades locais (Li *et al.*, 2019). O fato de muitas publicações virem de grupos de pesquisa internos, isto é, com pouca coautoria internacional, pode refletir tanto

Figura 3 – Países com maior número de produção sobre o tema em estudo

Distribuição de Artigos por País (n = 166)



Fonte: Elaborada pelo autor.

a urgência de soluções locais quanto a disponibilidade de dados governamentais que nem sempre são compartilhados globalmente (Xu *et al.*, 2021).

Em linhas gerais, pode-se elencar alguns fatores-chave para entender esse crescimento expressivo: primeiramente, no contexto político, o governo chinês passou a enfatizar a “civilização ecológica”, conceito formalizado no 13º Plano Quinquenal (2016–2020), que estabeleceu metas concretas para a redução de impactos ambientais e aprimoramento da gestão de resíduos (Zhao, 2016). Essa política estimulou tanto o financiamento de pesquisas acadêmicas quanto o desenvolvimento de tecnologias focadas no tratamento e na disposição de resíduos (Bleischwitz *et al.*, 2022), resultando em um ambiente propício para o avanço de estudos que empregam técnicas de análise espacial, como a GWR.

Além disso, a adoção de políticas de importação e processamento de resíduos – incluindo a chamada Política da Espada Nacional (*National Sword Policy*), implementada em 2018 – aumentou a necessidade de estratégias internas de manejo de resíduos, impulsionando a demanda por pesquisas que auxiliassem na compreensão e enfrentamento do problema (Li; Mu, 2024).


Nos Estados Unidos, a GWR serve para refinar sistemas de reciclagem em metrópoles extensas, permitindo calibrar tarifas e localizar centrais de triagem conforme critérios de equidade ambiental (Gilbert; Chakraborty, 2011). O foco recai na heterogeneidade intraurbana, onde disparidades socioeconômicas influenciam padrões de geração e descarte, exigindo diagnósticos de alta resolução (Grineski; Collins; Olvera, 2015)

Portanto, o salto na produção acadêmica chinesa não é fruto de um

único fator, mas do conjunto de políticas ambientais mais ambiciosas, aumento de financiamento à pesquisa, colaboração internacional e consolidação de novas metodologias para análise de dados espaciais (Bleischwitz *et al.*, 2022). A combinação desses elementos proporcionou um ambiente fértil para publicações científicas sobre a aplicação da GWR na gestão de resíduos sólidos, tornando a China referência no tema nos últimos anos (Yang *et al.*, 2023).

Relacionado à predominância dos estudos na China, destaca-se o *cluster* (cor vermelha) liderado por Wang X. e Zhang H. (Figura 4), cujos grupos se especializam em contaminação por metais pesados e que atua como ponte entre o núcleo principal e outros grupos, ampliando levemente a coesão da rede. Apesar desse agrupamento interno na China, observam-se agrupamentos isolados e menores da Europa e Oriente Médio.

Figura 4 – Rede de coautoria



Fonte: Elaborada pelo autor.


Os autores mais relevantes nesta pesquisa são chineses. Isso ocorre, pois a China, ao expandir a cooperação científica e tecnológica, buscou respostas conjuntas para problemas ambientais, incentivando redes de pesquisadores que compartilham métodos, dados e publicações (Shi; Yang; Du, 2020). Nesse cenário, a GWR surgiu como ferramenta relevante para analisar a distribuição espacial dos resíduos sólidos e suas correlações com variáveis socioeconômicas e ambientais, evidenciando padrões locais e fornecendo subsídios para ações de planejamento e mitigação (Zhang *et al.*, 2015).

A centralização favorece a profundidade temática, mas reduz a diversidade de abordagens. Teorias de redes indicam que estruturas fechadas geram inovação

incremental, sendo que a inserção de novos atores pode catalisar saltos conceituais (Zhou, 2022). Seus estudos empregam amostragens densas de solo e água em megacidades industriais, calibrando coeficientes locais da GWR em escala de quarteirão (Zhang e Yang, 2020), metodologia replicada por grupos menores na Índia e no Chile (Li *et al.*, 2019).

A rede de coocorrência (Figura 5) evidencia dois grandes *clusters* temáticos interligados por linhas cinzas, com protagonismo da China. O *cluster* na cor azul mostra a concentração de palavras-chave relacionadas à contaminação por metais pesados (“heavy metal”, “lead”, “cadmium”, “soil pollution”, “health risk”) com a “China” funcionando como *hub* central, conectando quase todos esses termos. O *cluster* na cor vermelha agrupa expressões de análise espacial urbana (“municipal solid waste”, “waste management”, “regression analysis”, “GIS”, “remote sensing”, “urbanization”), indicando forte correlação entre modelagem estatística e estudos sobre resíduos em ambientes metropolitanos.

Figura 5 – Rede de coocorrência de palavras-chave, cores indicam clusters colaborativos




Fonte: Elaborada pelo autor.

A revisão de literatura pela perspectiva bibliométrica apresenta um mapa temático (Figura 6) que evidencia a aplicação da GWR e dos resíduos sólidos atualmente impulsionada por um núcleo de pesquisa fortemente voltado ao monitoramento ambiental. Esse mapa temático identifica a relevância e o grau de desenvolvimento de diferentes temas de pesquisa, e é dividido em quatro quadrantes principais, definidos pelos eixos. O eixo vertical, denominado por Grau de desenvolvimento (densidade), indica quão especializado, consolidado e internamente coeso está o tema. E o eixo horizontal, denominado por Grau de relevância (centralidade), in-

dica a importância do tema na rede de conhecimento geral (conexões externas com outros temas).

No quadrante superior à direita (*Motor Themes* ou Temas Motores), apresenta um *cluster* (cor laranja) evidencia os seguintes temas “*environmental monitoring*, “*risk assessment*” e “*heavy metal*”. Estes temas são altamente desenvolvidos e muito relevantes para a área. Tendem a ser centrais, guiam a pesquisa e estruturam o campo de estudo. No contexto, indica que o monitoramento ambiental e avaliação de riscos com metais pesados são eixos dominantes da pesquisa. Apresenta alta centralidade e densidade, indicando um campo já bem consolidado na pesquisa, que ancora a maior parte das discussões. Esses temas possuem alto grau de desenvolvimento e alta relevância, sinalizando forte centralidade no campo científico.

Figura 6 – Mapa temático que associa a aplicação da GWR em estudos de resíduos sólidos



Fonte: Biblioshiny website.

No quadrante superior à esquerda (*Niche Themes* ou Temas de Nicho), apresenta um *cluster* (cor azul claro) que evidencia os seguintes temas “*land use*”, “*environmental protection*” e “*urbanization*”. Estes temas são bem desenvolvidos, mas com uma relevância moderada. Eles estão em uma fase avançada de pesquisa, mas ainda não são tão centrais no campo. Esses achados revelam oportunidades para articular mudanças de uso do solo e dinâmicas urbanas à modelagem espacial de resíduos, ampliando a utilidade da GWR para a formulação de políticas territoriais.

No quadrante inferior à esquerda (*Emerging or Declining Themes* ou Temas Emergentes ou em Declínio) na Figura 6, observa-se que os temas "*waste management*", "*economic development*" e "*carbon dioxide*". Esses temas têm uma baixa relevância e baixo desenvolvimento, sugerindo que a pesquisa nesses tópicos estão diminuindo ou se tornando menos central. Esses temas mesclam baixa centralidade e densidade, indicando lacunas importantes que podem representar tanto áreas emergentes (novas pesquisas ainda em formação), quanto áreas em declínio (perdendo relevância na literatura). Neste caso, resíduos sólidos e desenvolvimento econômico aparecem com baixa conexão.


Entre o quadrante inferior à direita (*Basic Themes* ou Temas Básicos) e o quadrante superior à direita, observa-se os temas "*China*", "*article*" e "*human*". Estes temas são relevantes, mas ainda pouco desenvolvidos ou genéricos. Apresentam grande visibilidade bibliométrica, porém menor profundidade conceitual. Esse padrão sugere que parte expressiva da produção ainda se concentra em estudos de caso descritivos, principalmente chineses, funcionam como fundamentais para a pesquisa, mas carecem de aprofundamento conceitual/metodológico, ou seja, ainda não estão densamente consolidados.

A Figura 6 ainda revela que com relação ao eixo da relevância de centralidade, os estudos de temas como "*Regression analysis*", "*spatial analysis*" e "*population density*" aparecem próximos ao eixo vertical central (cor verde claro). Isso sugere que, apesar de relevantes, eles possuem uma ligação mais específica ou limitada com outros temas.

Sobre as afiliações acadêmicas dos autores dos trabalhos (Figura 7), destacam-se as universidades asiáticas. Nesse caso, a Wuhan University (China), que lidera com 10 artigos, enquanto Duy Tan University (Vietnã) e East China Normal University (China) dividem a segunda posição. A presença ainda de instituições chinesas como Henan, Lanzhou e Shandong evidencia um polo de pesquisa concentrado no leste asiático.

Fora dessa região, apenas a Pontifícia Universidade Católica de Chile (5 artigos) aparece no topo, indicando participação latino-americana. Apesar disso, esse panorama institucional converge com a análise de autores e palavras-chave: grande parte dos estudos nasce em universidades chinesas, muitas vezes em colaboração doméstica, o que reforça a necessidade de ampliar parcerias transnacionais para diversificar métodos e contextos de aplicação da GWR.

Da perspectiva sistemática, foram observados os objetivos dos estudos, os aspectos metodológicos, com foco na análise de como a disponibilidade dos dados espaciais influenciam os resultados e a confiabilidade dos estudos, as escalas de análise e os principais resultados.

Figura 7 – *Filiações acadêmicas mais relevantes*

Fonte: Elaborada pelo autor.

Os resultados da revisão, sob a perspectiva sistemática, mostram que os estudos possuem objetivos variados. No entanto, eles convergem para esclarecer os fatores locais que influenciam a geração, a disposição e a contaminação por resíduos sólidos (Keser; Duzgun; Aksoy, 2012; Antczak, 2020; Cheng *et al.*, 2020; Agyeman *et al.*, 2021; Alzamora *et al.*, 2022; Wang; Zhang; Liu, 2022). Há uma ênfase em grandes centros urbanos, especialmente na China, onde a urbanização acelerada impõe fortes pressões ambientais (Liang; Wang; Li, 2019; Naqvi *et al.*, 2021; Zhao; Fan; Zhou, 2021; Fang; Chang, 2022).

Observa-se ainda expressiva incidência de investigações sobre metais pesados e avaliação de riscos à saúde, que empregam a GWR para identificar pontos críticos de exposição (Liu *et al.*, 2020; Zhang *et al.*, 2021). A aplicação de dados espaciais de alta resolução combinados a regressões locais permite capturar variações intraurbanas ou regionais, subsidiando políticas de gestão mais granulares (Cui *et al.*, 2019; Wang; Zhu; Zhang, 2021). Além disso, alguns autores, como por exemplo Chen *et al.* (2020), Ntajal *et al.* (2020), Kuziemska *et al.* (2021), Yang *et al.* (2021), discutem a fragilidade das colaborações transnacionais, refletida nos baixos índices de coautoria e na concentração dos estudos em poucos países, ao mesmo tempo em que defendem o fortalecimento de redes globais para troca de métodos e dados.

Do ponto de vista metodológico, predominam abordagens que contrastam modelos globais, como a regressão linear ordinária (*Ordinary Least Squares* - OLS)

e os modelos espaciais de dependência global, o Modelo Autorregressivo Espacial (*Spatial Autoregressive Model* - SAR) e o Modelo de Erro Espacial (*Spatial Error Model* - SEM) (Keser; Duzgun; Aksoy, 2012; Liang; Wang; Li, 2019; Lin *et al.*, 2020), com a GWR, registrando ganhos consistentes de ajuste estatístico quando os coeficientes passam a variar no espaço (Antczak, 2020; Zhang *et al.*, 2021). A maior parte dos trabalhos integra a GWR a Sistemas de Informação Geográfica e a imagens de sensoriamento remoto de média a alta resolução, estratégia que eleva o poder explicativo dos modelos em escalas sub municipais (Wang; Zhang; Liu, 2022; Katebikord; Sadeghi; Singh, 2022).

Quando o foco recai sobre contaminação, campanhas de amostragem de solo ou água são combinadas à modelagem espacial para validar empiricamente os padrões estimados (Liu *et al.*, 2020). Também se destaca o uso de indicadores socioeconômicos multiescalares, como renda, densidade populacional, cobertura de coleta seletiva e vulnerabilidade hídrica, como variáveis explicativas, reforçando a natureza interdisciplinar da pesquisa (Mazurek; Czapiewski, 2021; Kuziemska *et al.*, 2021). Estudos mais recentes relatam, ainda, a adoção de ferramentas de inteligência artificial para triagem bibliográfica, reduzindo o viés humano e acelerando a codificação temática (Mahmood *et al.*, 2019; Pandey *et al.*, 2021; Sahani; Ghosh, 2021; Aminzadegan *et al.*, 2022).

Quanto às escalas de análise, 59% dos artigos concentram-se em níveis intraurbanos, bairros ou distritos inferiores a 5 km², 29% operam na esfera provincial ou estadual e apenas 12% abrangem recortes nacionais. Essa análise detalhada revela uma forte heterogeneidade espacial. Em megacidades chinesas, a elasticidade entre renda e geração de resíduos varia de -0,12 a +0,45, indicando que o crescimento econômico só aumenta a produção de resíduos quando não há infraestrutura adequada (Wang; Zhang; Liu, 2022).

Em estudos de metais pesados, concentrações de Pb ultrapassam em até 3,8 vezes os limites da Organização Mundial da Saúde (OMS), valor-guia provisório de 0,01 mg L⁻¹ (10 μg L⁻¹) para chumbo em água potável segundo as Edition (2011) em áreas industriais do nordeste da China, enquanto zonas residenciais permaneceram dentro dos padrões, legitimando a criação de zonas específicas (Li *et al.*, 2020). Análises de vulnerabilidade hídrica indicam incremento de 25% no risco ao aquífero em células de 1 km² que contêm lixões a céu aberto, evidenciando a urgência de intervenções pontuais de remediação (Mirzaei *et al.*, 2020).

Em conjunto, esses achados confirmam que diagnósticos locais fundamentados em GWR aprimoram a formulação de rotas de coleta diferenciadas, a priorização da remediação de solos contaminados e o desenho de incentivos à reciclagem, reforçando a necessidade de investimentos em bases de dados abertas e em cooperação

internacional para que benefícios semelhantes se estendam a regiões com menor disponibilidade de informação (Antczak, 2019; Wen *et al.*, 2022).

Pesquisas futuras devem agregar variáveis de infraestrutura, como densidade de ecopontos, para quantificar sobreposição entre contaminação e falhas de coleta. Essa interface operacional permitiria direcionar recursos a áreas onde risco ambiental e ineficiência logística convergem, elevando custo-benefício das intervenções (Fang; Chang, 2022).

2.4 Considerações Finais

A investigação acerca da aplicação da Regressão Geograficamente Ponderada em estudos sobre resíduos sólidos forneceu contribuições valiosas para compreender as variáveis que influenciam a geração, o descarte e a contaminação dos resíduos em escala local. A pesquisa teve ênfase na evolução temporal das publicações (2011 a 2022), nos principais métodos adotados para análise espacial e na distribuição geográfica dos estudos. Constatou-se um crescimento contínuo do interesse pelo tema, especialmente na última década, evidenciando a ampliação do debate acadêmico sobre questões relacionadas a políticas públicas e sustentabilidade na gestão de resíduos.

Destacam-se os conjuntos de dados espaciais, em especial aqueles obtidos por meio de sistemas de informação geográfica, sensoriamento remoto e plataformas colaborativas, que vêm subsidiando análises robustas em GWR (Bujanda; Fullerton, 2017). Esses dados são muitas vezes processados e integrados a modelos de estatística espacial, oferecendo diagnósticos mais precisos sobre pontos críticos de descarte irregular, ocorrência de aterros inadequados e variações significativas nos fatores socioeconômicos que afetam a produção de resíduos (Liu *et al.*, 2020; Lin *et al.*, 2022).

Verificou-se que a maior parte dos estudos se concentra em países populosos, com destaque para a China, resultado de políticas ambientais mais restritivas e do rápido processo de urbanização observado nesse contexto (Xiao *et al.*, 2020). A presença de grandes universidades e o aporte de instituições governamentais ou consórcios acadêmicos impulsionam o desenvolvimento de pesquisas em GWR voltadas à gestão de resíduos sólidos (Yang *et al.*, 2023). No entanto, ainda há carência de cooperação internacional efetiva, o que reforça a importância de colaborações para pesquisadores de diferentes regiões que desejem aprofundar esses estudos (Kut; Pietrucha-Urbanik, 2024).

O exame das publicações evidenciou a relevância de abordagens multiescala, envolvendo desde levantamentos em nível local até a análise de grandes áreas

metropolitanas (Durán; Messina, 2019). Em alguns artigos, observou-se a associação entre a GWR e variáveis como renda, densidade populacional e acesso a serviços de coleta seletiva, revelando padrões específicos de geração e descarte que, sem análises espaciais, passariam despercebidos (Keser; Duzgun; Aksoy, 2012; Ismaila *et al.*, 2015; Antczak, 2020). Em países emergentes, por exemplo, a deficiência de infraestrutura e as lacunas na fiscalização tornam ainda mais urgente a adoção de metodologias como a GWR para embasar decisões governamentais (Olivo; Prietto; Korf, 2021).

Estes achados contribuem para o aprimoramento do conhecimento acerca da heterogeneidade espacial na gestão de resíduos, oferecendo subsídios para ações de monitoramento, prevenção e remediação (Papale *et al.*, 2023). Tanto em nações ricas, que já contam com legislações ambientais consolidadas, quanto em países de renda mais baixa, a análise local detalhada pode auxiliar no encaminhamento de soluções personalizadas, sobretudo para minimizar contaminações ambientais e riscos à saúde (Nkwunonwo *et al.*, 2024).

O diferencial desta revisão é que, além dos aspectos quantitativos obtidos pela análise bibliométrica, foram consideradas as abordagens qualitativas oriundas da revisão sistemática apoiada por inteligência artificial. Desse modo, pôde-se identificar não apenas quem produz e onde se produzem os estudos, mas também quais métodos específicos e bases de dados se mostram mais inovadores ou recentes. Verificou-se, por exemplo, a crescente adoção de dados abertos e ferramentas colaborativas que tornam as investigações mais acessíveis a grupos de pesquisa diversos, inclusive em escala global (Massarelli; Uricchio, 2024).

Por fim, a soma das evidências apresentadas demonstra que o uso da GWR no contexto dos resíduos sólidos se fortalece como um instrumento estratégico para a compreensão de padrões espaciais e temporais, promovendo o desenvolvimento de políticas públicas eficientes, baseadas em dados e orientadas para a sustentabilidade. A tendência é que, com maior padronização metodológica e incentivos à cooperação internacional, futuros estudos ampliem a adoção de técnicas espaciais, levando a avanços significativos na mitigação dos impactos sociais e ambientais decorrentes da geração e destinação de resíduos sólidos.

Modelagem da Geração de Resíduos Sólidos Urbanos Através de Regressão Geograficamente Ponderada: Um Estudo de Caso no Estado de Goiás e Distrito Federal

Resumo: O crescimento populacional e a urbanização desordenada têm contribuído significativamente para o aumento da geração de resíduos sólidos urbanos em todo o mundo, e o Brasil acompanha essa tendência. Nesse contexto, torna-se essencial compreender os fatores socioeconômicos, demográficos e climáticos que influenciam a produção de resíduos, bem como suas variações espaciais. Diante disso, esta pesquisa teve como objetivo investigar os fatores determinantes da geração de resíduos sólidos urbanos nos municípios do Estado de Goiás e Distrito Federal e modelar como essas relações se distribuem espacialmente. A metodologia envolveu a coleta de dados referentes à produção de resíduos nos 246 municípios goianos mais o Distrito Federal, bem como de nove variáveis explicativas, abrangendo aspectos socioeconômicos, ambientais e de infraestrutura. Inicialmente, foi aplicado o modelo de regressão linear múltipla *Ordinary Least Squares* (OLS) para identificar, de forma global, as variáveis com maior poder preditivo. Em seguida, foi realizada a verificação da multicolinearidade por meio do *Variance Inflation Factor* (VIF) e a seleção de variáveis pelo *Akaike Information Criterion corrected* (AICc). Após essa etapa, foi utilizada a Regressão Geograficamente Ponderada (*Geographically Weighted Regression* - GWR) para analisar como as relações entre as variáveis variam no espaço. Os resultados da regressão global indicaram que cinco variáveis explicam aproximadamente 98% da variabilidade na geração de resíduos sólidos urbanos nos municípios goianos: densidade demográfica, média de moradores por domicílio, taxa de alfabetização da população com 15 anos ou mais, número de empregos formais e Produto Interno Bruto (PIB) *per capita*, a preços correntes. Já a análise local,

realizada com a GWR, revelou que essas mesmas variáveis explicam cerca de 98% da produção de resíduos sólidos nas áreas urbanas dos municípios, demonstrando um ganho significativo com o uso da modelagem espacial. Adicionalmente, observou-se que a variável de empregos formais apresentou a maior correlação com a geração de resíduos sólidos urbanos no estado de Goiás e Distrito Federal entre os fatores analisados.

Palavras-Chave: Resíduos urbanos; Modelagem geográfica; Regressão geograficamente ponderada; Geoprocessamento.

3.1 Introdução

O fenômeno da urbanização acelerada representa uma das transformações socioespaciais mais significativas do último século, reconfigurando paisagens e modos de vida em escala global (Unidas, 2019). No Brasil, esse processo ocorreu de forma intensa e desacompanhada de planejamento adequado, resultando em metrópoles e cidades médias com complexos desafios de gestão (IBGE - Instituto Brasileiro de Geografia e Estatística, 2023). Um dos resultados mais evidentes desse crescimento urbano não planejado é a intensificação da geração de Resíduos Sólidos Urbanos¹ (RSU), um problema ambiental e de saúde pública que demanda atenção urgente (ABRELPE, 2023).

Essa urgência se justifica pelos graves impactos ambientais decorrentes da disposição inadequada dos resíduos, como a contaminação do solo e da água, além da emissão de gases de efeito estufa, pelos riscos à saúde pública, especialmente em áreas periféricas, e pela sobrecarga nos sistemas municipais de coleta e tratamento, que muitas vezes não acompanham o ritmo da geração de resíduos. O aumento do poder de consumo, aliado à cultura de produtos descartáveis, contribui exponencialmente para o volume de materiais descartados nas cidades brasileiras (Freitas; Pires; Benincá, 2024).

A gestão inadequada desses resíduos acarreta externalidades negativas, como poluição do solo, água e ar, proliferação de vetores de doenças e degradação estética urbana (IEA Bioenergy, 2025). A complexidade logística e os altos custos associados à coleta, transporte, tratamento e disposição final dos RSU impõem barreiras adicionais, especialmente para municípios de menor porte (Novais; Tavares,

¹De acordo com a Política Nacional de Resíduos Sólidos (PNRS), Lei N. 12.305/2010, resíduos sólidos são todos os materiais, sólidos ou semissólidos, descartados resultantes de atividades humanas (PNRS, 2010)

2025). Diante desse cenário, a Política Nacional de Resíduos Sólidos (PNRS), instituída pela Lei N. 12.305/2010, representou um marco legal fundamental, estabelecendo princípios, objetivos e instrumentos para o manejo ambientalmente adequado dos resíduos (Brasil, 2010).

A PNRS (2010) introduziu conceitos como responsabilidade compartilhada pelo ciclo de vida dos produtos, logística reversa e priorização da não geração, redução, reutilização, reciclagem e tratamento dos resíduos, relegando a disposição final em aterros sanitários como última opção (Brasil, 2010). Regulamentações posteriores, como o Decreto N. 10.936/2022 e o Plano Nacional de Resíduos Sólidos (PNRS - Planares), buscaram detalhar e fortalecer as diretrizes da PNRS (Brasil (Decreto nº 10.936/2022), 2022; Brasil (Decreto nº 11.043/2022), 2022). Contudo, a implementação efetiva da PNRS ainda enfrenta obstáculos consideráveis em diversas regiões do país (Freitas; Pires; Benincá, 2024).

O panorama da geração e destinação de RSU no Brasil revela um quadro preocupante. Dados da ABRELPE (2023) indicam que, embora a geração *per capita* de RSU tenha se mantido relativamente estável na última década, o volume total de resíduos gerados no país aumentou continuamente, impulsionado pelo crescimento populacional (ABRELPE, 2023). O Censo Demográfico de 2022 apontou um aumento de 6,45% na população brasileira entre 2010 e 2022, o que exerce pressão constante sobre os sistemas de gestão de resíduos (IBGE - Instituto Brasileiro de Geografia e Estatística, 2023). Em 2022, aproximadamente 61% dos RSU coletados foram destinados a aterros sanitários, considerados a forma ambientalmente adequada de disposição final (Freitas; Pires; Benincá, 2024). No entanto, os 39% restantes ainda foram encaminhados para lixões ou aterros controlados, formas inadequadas que representam sérios riscos à saúde pública e ao meio ambiente (ABRELPE, 2023).

A região Centro-Oeste apresentou aumento na taxa de destinação adequada de RSU entre 2021 e 2022, passando de 68,1% para 68,8% (ABRELPE, 2023). O estado de Goiás e Distrito Federal reflete as tendências e desafios observados no cenário nacional da gestão de RSU (Colvero *et al.*, 2017). Com forte dinâmica agropecuária e crescente urbanização, especialmente em torno da cidade de Goiânia e do eixo da BR-153, enfrenta pressões significativas relacionadas ao aumento da geração de resíduos (Colvero *et al.*, 2017). A gestão dos RSU em Goiás e Distrito Federal são de responsabilidade dos municípios e da capital federal, que devem elaborar seus Planos Municipais de Gestão Integrada de Resíduos Sólidos (PMGIRS) e Plano Distrital de Gestão Integrada de Resíduos Sólidos (PDGIRS), respectivamente, em consonância com a Política Estadual e Distrital de Resíduos Sólidos (GDF, 2017; Goiás, 2023).

Estudos recentes demonstram a complexidade da gestão de RSU no estado (Morais *et al.*, 2021; Oliveira *et al.*, 2024). Moraes *et al.* (2021) investigaram a eficácia de estratégias educativas no descarte adequado de resíduos sólidos urbanos no sul do estado, evidenciando a necessidade de abordagens integradas que combinem infraestrutura e educação ambiental. A compreensão dos fatores que impulsionam a geração de RSU no contexto goiano é crucial para subsidiar políticas públicas mais eficazes (Colvero *et al.*, 2017; Oliveira *et al.*, 2024). Oliveira *et al.* (2024) destacam a importância da regionalização como estratégia para otimizar a gestão de resíduos sólidos urbanos em Goiás e no Distrito Federal.

Nesse contexto, a modelagem da geração de RSU surge como ferramenta estratégica para o planejamento e gestão eficiente dos sistemas de limpeza urbana (Mapunda; Kimwaga; Kassuwi, 2024). Modelos preditivos permitem estimar quantidades e tipos de resíduos gerados em diferentes áreas e períodos, auxiliando no dimensionamento de rotas de coleta, alocação de equipamentos, previsão de custos operacionais e planejamento de infraestruturas (Kolekar; Hazra; Chakrabarty, 2016). A capacidade de antecipar volumes de RSU é fundamental para otimizar recursos, evitar sobrecargas no sistema e garantir a continuidade dos serviços (Rosecky *et al.*, 2021). A modelagem contribui para a avaliação de cenários futuros, considerando projeções de crescimento populacional, mudanças nos padrões de consumo e implementação de políticas de redução e reciclagem (Miezah *et al.*, 2015).

A geração de RSU é um fenômeno complexo, influenciado por fatores inter-relacionados que variam significativamente no espaço e no tempo (Ismaila *et al.*, 2015). A literatura científica tem identificado e quantificado a influência de variáveis socioeconômicas, demográficas, culturais, climáticas e de infraestrutura urbana sobre os padrões de geração de resíduos (Antczak, 2019; Alzamora *et al.*, 2022; Daoud *et al.*, 2025). Estudos demonstram que fatores como nível de renda familiar, Produto Interno Bruto *per capita*, tamanho e composição dos domicílios, densidade populacional, nível de escolaridade e hábitos de consumo estão associados às quantidades de RSU geradas (Rybova, 2019; Daoud *et al.*, 2025). Variáveis climáticas, como temperatura e precipitação, também influenciam a geração e composição dos resíduos, especialmente da fração orgânica (Gichamo; Gökçekuş, 2019).

Contudo, a relação entre esses fatores e a geração de RSU frequentemente não é linear nem homogênea no espaço, exibindo considerável heterogeneidade espacial (Antczak, 2019). O impacto de variáveis como renda pode ser diferente em áreas urbanas centrais e periféricas, ou entre cidades com diferentes níveis de desenvolvimento (Madden *et al.*, 2019). Em alguns contextos, maior poder aquisitivo pode levar a maior consumo e descarte (Blagoeva; Georgieva; Dimova, 2023),

enquanto em outros, pode estar associado a maior conscientização ambiental e adesão a programas de reciclagem (Páramo-Telle; Vence, 2025). Essa variabilidade espacial invalida pressupostos de modelos de regressão globais tradicionais, que assumem relações constantes em toda a área de estudo (Sartika; Suryani, 2020).

Entre as abordagens que permitem explorar a heterogeneidade espacial, a ferramenta Regressão Geograficamente Ponderada (*Geographically Weighted Regression* - GWR) tem ganhado destaque em estudos ambientais (Cheng *et al.*, 2024; Fan *et al.*, 2024; Zhang *et al.*, 2025) e de gestão de resíduos sólidos (Mapunda; Kimwaga; Kassuwi, 2024). No decorrer do texto, usa-se a abreviação GWR (em inglês), que refere-se a ferramenta Regressão Geograficamente Ponderada (em português).

A GWR é uma técnica de regressão local que permite que os coeficientes variem espacialmente, calibrando um modelo específico para cada localidade, ponderado pela proximidade geográfica das observações vizinhas (Chen *et al.*, 2022). Ao contrário dos modelos globais, como a *Ordinary Least Squares* (OLS), que estimam um único conjunto de coeficientes para toda a região, a GWR produz coeficientes locais para cada variável independente, permitindo mapear como a relação entre variáveis explicativas e dependente muda no espaço (Cheng *et al.*, 2024).

A aplicação da GWR em estudos sobre RSU tem se mostrado promissora para desvendar dinâmicas locais que influenciam os padrões de geração (Yin *et al.*, 2024). Daoud *et al.* (2025) analisaram fatores socioeconômicos que influenciam o comportamento de reciclagem nos Emirados Árabes Unidos, constatando que fatores como consciência ambiental apresentavam influências espacialmente variáveis. Madden *et al.* (2019) empregaram GWR na Austrália para investigar a relação entre indicadores socioeconômicos e geração de RSU, identificando variações significativas nos coeficientes locais. Antczak (2019) utilizou GWR na Polônia para demonstrar como densidade populacional e renda *per capita* impactaram de forma não uniforme a geração de RSU. Rybova (2019) aplicou GWR na República Tcheca para analisar a geração de recicláveis, revelando que nível educacional e poder de compra influenciavam distintamente os municípios.

Apesar da crescente aplicação da GWR em estudos de RSU internacionalmente, observa-se lacuna significativa na literatura brasileira, especificamente no estado de Goiás e Distrito Federal. Embora existam estudos nacionais que abordam a geração de RSU utilizando modelos de regressão globais (Leal *et al.*, 2023; Terra, 2024), são escassas as pesquisas que incorporam a dimensão espacial por meio de técnicas como a GWR. A maior parte dos estudos sobre RSU em Goiás e Distrito Federal focam em aspectos de gestão ou estudos de caso pontuais, sem análise espacial abrangente dos fatores que influenciam a geração de resíduos em escala estadual (Moraes *et al.*, 2021; Oliveira *et al.*, 2024).

Diante do exposto, considerando a relevância da gestão de RSU como desafio ambiental (Deus; Battistelle; Silva, 2015), a complexidade dos fatores que influenciam sua geração (Daoud *et al.*, 2025), a importância de considerar a heterogeneidade espacial (Sartika; Suryani, 2020) e a lacuna na aplicação de modelos espaciais de maiores escalas no contexto goiano, esta pesquisa tem como objetivo principal investigar os fatores socioeconômicos, demográficos e climáticos que influenciam a geração de RSU no estado de Goiás e Distrito Federal, e como esses fatores podem variar espacialmente. Busca-se, por meio da GWR, desenvolver um modelo espacial que capture a não estacionariedade das relações entre as variáveis preditoras e a taxa de geração de RSU *per capita* nos municípios goianos. É esperado que os resultados forneçam *insights* valiosos sobre as dinâmicas locais da geração de RSU, identifiquem áreas prioritárias para intervenção e subsidiem a formulação de estratégias de gestão de RSU mais eficazes e adaptadas às especificidades de Goiás e do Distrito Federal.


3.2 Procedimentos Metodológicos

3.2.1 Área de Estudo

O estudo foi realizado no estado de Goiás e Distrito Federal (Figura 8), localizados na região Centro-Oeste do Brasil, entre as coordenadas geográficas 12°23'46"e 19°29'42"de latitude Sul e 45°54'23"e 53°14'32"de longitude Oeste. O estado possui uma área territorial de 340.242,854 km^2 e é composto por 246 municípios, já o Distrito Federal possui uma área de 5.779,784 km^2 . Goiás faz divisa com os estados de Tocantins ao norte, Bahia a nordeste, Minas Gerais a leste e sudeste, Mato Grosso do Sul ao sul e Mato Grosso a oeste, além de englobar o Distrito Federal (IBGE, 2022). A Figura 8 mostra o mapa detalhado do estado de Goiás e Distrito Federal.

A população do estado de Goiás em 2022 era de 7.056.495 habitantes, com uma densidade demográfica de 20,74 hab/ km^2 , por sua vez, o Distrito Federal possuía em 2022 uma população de 2.817.381 habitantes com uma densidade demográfica de 489,06 hab/ km^2 (IBGE, 2022). A escolha destes locais como área de estudo justifica-se pela sua representatividade no cenário nacional em termos de desenvolvimento econômico e crescimento populacional, fatores que influenciam diretamente na geração de resíduos sólidos urbanos (Oliveira *et al.*, 2024). Segundo o Instituto Mauro Borges (IMB, 2024), o estado apresenta expressiva diversidade socioeconômica entre os municípios que o compõem, o que permite uma análise espacial mais robusta dos fatores que influenciam a geração de resíduos sólidos

Figura 8 – *Mapa detalhado do estado de Goiás com o Distrito Federal (DF)*



Fonte: Elaborado pelos autores.

urbanos (Freitas; Pires; Benincá, 2024).

3.2.2 Dados e Informações

Os dados e informações utilizados neste estudo foram obtidos em fontes oficiais (Tabela 1), compreendendo variáveis socioeconômicas, demográficas e climáticas. Para este estudo, a variável dependente representada pela geração de Resíduos Sólidos Urbanos (RSU), foi estimada considerando uma taxa de geração de 1,04 kg por pessoa por dia, multiplicada pela população de cada município, resultando em uma medida expressa em kg/município/ano. Os dados referentes à geração de resíduos sólidos urbanos foram obtidos junto à Associação Brasileira de Resíduos e Meio Ambiente (ABREMA) (ABRELPE, 2023).

Tabela 1 – Definições e fontes das variáveis utilizadas.

Variável Dependente	Definição	Unidade	Fonte
RSU	Resíduos Sólidos Urbanos	kg/município/ano	Abrema, (ABRELPE, 2023)

Variável Independente	Definição	Unidade	Fonte
POPDEN	Densidade Populacional	Hab/km ²	SIDRA, (IBGE, 2022)
TAMDOM	Média de moradores em domicílios particulares permanentemente ocupados	Número	SIDRA, (IBGE, 2022)
TXALF	Taxa de alfabetização das pessoas de 15 anos ou mais de idade	%	SIDRA, (IBGE, 2022)
TEMPM	Temperatura média anual	°C	(NASA, 2025)
PRECIPM	Precipitação média anual	mm	(NASA, 2025)
EMPFOR	Número de Empregos Formais	Número	RAIS, (MTE, 2024)
PIBPCAPT	Produto Interno Bruto <i>per capita</i> , a preços correntes	Real	(IBGE, 2022)
TXFESC	Taxa de frequência escolar bruta	%	SIDRA, (IBGE, 2022)
MEDEST	Número médio de anos de estudo das pessoas com 11 anos ou mais de idade	Número	SIDRA, (IBGE, 2022)

As variáveis explicativas (Tabela 1) foram selecionadas com base na literatura especializada e em estudos anteriores que identificaram fatores potencialmente influentes na geração de resíduos sólidos urbanos (Ismaila *et al.*, 2015; Antczak, 2019; Alzamora *et al.*, 2022; Daoud *et al.*, 2025). Segundo Arbulú, Lozano e Rey-Maqueira (2016), fatores como densidade populacional, nível de escolaridade, renda *per capita* e infraestrutura viária têm demonstrado correlação significativa com a geração de resíduos sólidos urbanos em diferentes contextos geográficos. Ghinea *et al.* (2016) destacam ainda a importância de considerar variáveis climáticas, como temperatura e precipitação, que podem influenciar os padrões de consumo e, consequentemente, a geração de resíduos. Assim, procurou-se garantir coerência com estudos anteriores e relevância para a análise proposta. A seleção também considerou trabalhos que destacam a importância desses fatores em diferentes contextos e também fossem coerentes com o local de análise desta pesquisa. Entre outros trabalhos considerados estão (KristýnaRybová, 2016; Madden *et al.*, 2019; Paulauskaite-Taraseviciene; Raudonis; Sutiene, 2022; Chen *et al.*, 2023; Velis *et al.*, 2023; Yao *et al.*, 2023).

Estas variáveis foram obtidas no site do Sistema IBGE de Recuperação Automática (IBGE, 2022), sendo que o ano de 2022 é o ano mais atual em relação ao censo nacional, complementadas por dados do IBGE de 2021 para o campo de PIB *per capita*, visto que até a publicação desta pesquisa este dado não havia sido atualizado para um ano mais recente, informação do Departamento Nacional de Infraestrutura de Transportes (DNIT) para as rodovias estaduais e federais, da plataforma NASA POWER para variáveis climáticas, e da Relação Anual de Informações Sociais (RAIS) para dados de emprego formal.

3.2.3 Processamento dos Dados e Informações

Os limites administrativos dos 246 municípios de Goiás e do Distrito Federal foram obtidos em formato *shapefile* do Instituto Brasileiro de Geografia e Estatística (IBGE), Sistema de Referência Geocêntrico para as Américas (SIRGAS2000) e projetados em Universal Transverso de Mercator (*Universal Transverse Mercator* – UTM), Zona 22 Sul. Todas as variáveis (dependente e explicativas) foram compiladas em planilhas eletrônicas e posteriormente incorporadas como atributos à camada de limites municipais por meio do ArcMap, versão para estudante, permitindo a análise espacial integrada dos dados. O ArcMap foi utilizado ainda para o processamento espacial dos dados e informação e para a criação de mapas temáticos para visualização dos resultados.

Para o processamento e análises estatísticas e modelagens dos dados e informações, foram utilizados códigos em R. O *software* R (versão 4.4.2) foi empregado para a análise estatística, incluindo o ajuste do modelo de regressão linear múltipla

Ordinary Least Squares (OLS), testes de multicolinearidade, cálculo do *Variance Inflation Factor* (VIF), seleção de variáveis pelo *Akaike Information Criterion corrected* (AICc), execução do modelo de *Geographically Weighted Regression* (GWR), para avaliação, os testes de do Índice de Moran I e o teste de Shapiro-Wilk.

3.2.4 Procedimentos Metodológicos

O processo metodológico foi estruturado em cinco etapas principais: (1) ajuste do modelo *Ordinary Least Squares* (OLS) (Eq. 1) e verificação da significância estatística das variáveis; (2) análise de multicolinearidade por meio do Fator de Inflação da Variância (*Variance Inflation Factor* – VIF); (3) seleção de variáveis com base no *Akaike Information Criterion corrected* (AICc); (4) modelagem por *Geographically Weighted Regression* (GWR); e aplicação dos testes de Moran I para avaliação da autocorrelação espacial e o teste de Shapiro-Wilk para a avaliação da normalidade dos resíduos.

A abordagem de regressão geograficamente ponderada permite modelar relações que variam espacialmente, fornecendo uma compreensão mais detalhada dos processos subjacentes à geração de resíduos sólidos urbanos em diferentes contextos geográficos (Comber *et al.*, 2013; Chen *et al.*, 2024). Na primeira etapa, realizou-se o ajuste de um modelo de regressão linear múltipla para identificar as variáveis com significância estatística na explicação da geração de resíduos sólidos urbanos.

O modelo OLS pode ser expresso por:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \varepsilon \quad (1)$$

onde y é a variável dependente (RSU), β_0 é o intercepto, β_p são os coeficientes de regressão para cada variável explicativa x_p , e ε é o termo de erro aleatório (Yu, 2025). Este modelo foi ajustado utilizando a função `lm()` no *software* R, considerando inicialmente todas as variáveis explicativas selecionadas.

A significância estatística de cada variável foi avaliada com base no valor- p , considerando um nível de significância de 5% ($\alpha = 0,05$) (Daoud *et al.*, 2025). Apenas as variáveis com valor- $p < 0,05$ foram consideradas estatisticamente significativas e mantidas para as análises subsequentes. Segundo Bivand, Pebesma e Gomez-Rubio (2008), esta etapa é fundamental para identificar as variáveis que têm uma relação estatisticamente significativa com a variável dependente, reduzindo a complexidade do modelo e facilitando sua interpretação.

Na segunda etapa, procedeu-se à verificação de multicolinearidade entre as variáveis explicativas estatisticamente significativas, utilizando o VIF (Eq. 2). A multicolinearidade ocorre quando duas ou mais variáveis explicativas em um modelo

de regressão são altamente correlacionadas, o que pode levar a estimativas imprecisas dos coeficientes e dificultar a interpretação dos resultados (Daoud *et al.*, 2025).

O VIF para cada variável explicativa é calculado por:

$$\text{VIF}(j) = \frac{1}{1 - R^2(j)}, \quad (2)$$

onde $R^2(j)$ é o coeficiente de determinação obtido quando a j -ésima variável explicativa é regredida contra todas as outras variáveis explicativas no modelo (Yu, 2025). Para eliminar problemas de multicolinearidade, foram removidas as variáveis com VIF (Eq. 2) superior a 7,5, conforme recomendado por Dormann *et al.* (2018) e validado por estudos recentes (Chen *et al.*, 2024). Este procedimento foi executado no *software* R, utilizando a função `vif()` do pacote *car*, aplicada ao modelo de regressão linear múltipla com as variáveis estatisticamente significativas. A escolha do limiar de 7,5 para o VIF baseou-se em estudos que demonstraram que valores acima deste limite podem indicar problemas sérios de multicolinearidade, comprometendo a estabilidade e a interpretabilidade do modelo (Salmerón; García; García, 2018; Freitas; Pires; Benincá, 2024).

Na terceira etapa, para as variáveis que apresentaram significância estatística no modelo OLS e VIF abaixo de 7,5, foi aplicado o critério AICc para selecionar o melhor conjunto de variáveis para o modelo GWR, ou seja, a largura de banda (*bandwidth*). O critério AIC é uma medida de qualidade relativa de modelos estatísticos, que considera tanto a qualidade do ajuste quanto a complexidade do modelo, penalizando modelos com muitos parâmetros (Hurvich; Simonoff; Tsai, 2018; Chen *et al.*, 2024). Este critério é calculado por:

$$\text{AICc} = -2\ln(L) + 2K + \frac{2K(K+1)}{n-K-1}, \quad (3)$$

onde $\ln(L)$ é o logaritmo natural da função de verossimilhança do modelo, K é o número de parâmetros estimados (incluindo o intercepto) e n é o tamanho da amostra. O modelo com menor valor de AICc (Eq. 3) é considerado o mais adequado.

Após a seleção das variáveis pelo critério AICc, foi aplicado o modelo de GWR (Eq. 4), que é uma técnica estatística espacial que permite modelar relações que variam espacialmente, superando as limitações dos modelos de regressão global, que assumem homogeneidade espacial nas relações entre variáveis (Comber *et al.*, 2013; Oshan *et al.*, 2019; Yu, 2025).

O modelo GWR é definido por:

$$y_i = \beta_0(u_i, v_i) + \sum_{k=1}^p \beta_k(u_i, v_i) x_{ik} + \varepsilon_i, \quad (4)$$

onde y_i é o valor da variável dependente na localização i , (u_i, v_i) são as coordenadas geográficas da localização i , $\beta_0(u_i, v_i)$ é o intercepto específico para a localização i , $\beta_k(u_i, v_i)$ é o coeficiente local da k -ésima variável explicativa, x_{ik} é o valor da k -ésima variável explicativa na localização i , e ε_i é o termo de erro aleatório (Chen *et al.*, 2024).

A implementação do modelo GWR (Eq. 4) foi realizada no *software* R, utilizando o pacote *spgwr*. Para determinar a largura de banda (*bandwidth*) ideal, que define a extensão da influência espacial, foi utilizado o método adaptativo com a função de ponderação do *kernel bisquare* (Eq. 5), que ajusta a largura de banda de acordo com a densidade dos dados, garantindo um número consistente de observações vizinhas em cada estimativa local (Lu *et al.*, 2014; Yu, 2025).

O *kernel bisquare* foi selecionado por sua capacidade de atribuir pesos que diminuam gradualmente com a distância até um ponto de corte, além do qual os pesos são zero, reduzindo a influência de observações muito distantes (Oshan *et al.*, 2019; Freitas; Pires; Benincá, 2024). A largura de banda tem papel essencial no desempenho do modelo, pois define o alcance da influência espacial de cada ponto sobre os coeficientes locais. Valores muito pequenos podem gerar estimativas instáveis e superajustadas, enquanto valores muito grandes tendem a suavizar excessivamente os resultados, aproximando o modelo de uma regressão global. Dessa forma, a escolha adequada da largura de banda é fundamental para equilibrar a sensibilidade local e a generalização do modelo.

A função de ponderação do *kernel bisquare* é dada por:

$$w_{ij} = \begin{cases} \left[1 - \left(\frac{d_{ij}}{b} \right)^2 \right]^2, & \text{se } d_{ij} < b \\ 0, & \text{se } d_{ij} \geq b, \end{cases} \quad (5)$$

onde w_{ij} é o peso atribuído à observação j na estimativa para a localização i , d_{ij} é a distância entre as localizações i e j , e b é a largura de banda. No método adaptativo, b varia de acordo com a densidade dos dados, sendo menor em áreas com maior densidade de observações e maior em áreas com menor densidade (Chen *et al.*, 2024). A seleção da largura de banda ótima foi baseada no critério AICc (Eq. 3) (Daoud *et al.*, 2025).

Após a estimação dos modelos OLS (Eq. (1)) e GWR (Eq. (4)), foi realizada a análise dos seus respectivos resíduos. Essa análise buscou verificar a presença de autocorrelação espacial e a aderência dos resíduos a uma distribuição normal. Para a verificação da autocorrelação espacial, utilizou-se o Índice de Moran I (Moran,

1950), definido por:

$$I = \frac{n}{S_0} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad (6)$$

onde: n é o número total de unidades espaciais (observações); x_i e x_j são os valores do resíduo nas unidades espaciais i e j , respectivamente; $\bar{x}$ é a média de todos os valores dos resíduos; w_{ij} é o peso espacial que define a relação de vizinhança entre as unidades i e j ; e S_0 é a soma de todos os pesos espaciais ($S_0 = \sum_i \sum_j w_{ij}$), um fator de normalização (Anselin, 1995).

O Índice de Moram (Eq. (6)) mede o grau de dependência espacial entre os resíduos, indicando se valores semelhantes tendem a se agrupar no espaço (autocorrelação positiva), se valores dissimilares estão próximos (autocorrelação negativa), ou se não existe um padrão de dependência espacial (aleatoriedade) (Almeida, 2012; Monteiro *et al.*, 2004).

Os valores do Índice de Moram I próximos a $+1$ indicam autocorrelação espacial positiva, enquanto valores próximos a -1 sugerem autocorrelação negativa. Um valor de I próximo de zero aponta para uma distribuição espacial aleatória dos resíduos, que é uma das condições para a adequação de modelos de regressão.

Para avaliar a normalidade dos resíduos, foi empregado o teste de Shapiro-Wilk (Shapiro; Wilk, 1965). A premissa de normalidade nos resíduos é um componente dos modelos de regressão linear, e o não cumprimento dessa condição pode afetar a inferência estatística sobre os coeficientes do modelo (Field, 2020). O teste de Shapiro-Wilk avalia o quão provável é que a amostra de resíduos tenha sido extraída de uma população com distribuição normal, sendo reconhecido por seu bom desempenho em diferentes cenários (Razali; Wah *et al.*, 2011). A estatística do teste de Shapiro-Wilk é denominada por W , e definida por:


$$W = \frac{(\sum_{i=1}^n a_i x_{(i)})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad (7)$$

onde: $x_{(i)}$ representa o i -ésimo valor do resíduo na amostra ordenada (do menor para o maior); x_i é o i -ésimo valor do resíduo (não ordenado); $\bar{x}$ é a média dos resíduos; e a_i são coeficientes constantes específicos do teste, calculados a partir das covariâncias, variâncias e médias esperadas dos valores de uma amostra normal de mesmo tamanho (Shapiro; Wilk, 1965). O valor da estatística W (Eq. (7)) está definido no intervalo entre 0 e 1. Os valores de W próximos a 1, associados a um valor- p superior ao nível de significância adotado (geralmente 0,05), indicam que não há evidências para rejeitar a hipótese de que os resíduos seguem uma distribuição normal (Ghasemi; Zahediasl, 2012).

Para complementar e ilustrar a análise, foram criados mapas temáticos dos coeficientes locais estimados pelo modelo GWR. Os mapas temáticos permitem visualizar como a influência de cada variável explicativa na geração de resíduos sólidos urbanos varia ao longo do espaço geográfico, fornecendo indicadores para a gestão de resíduos sólidos em diferentes regiões do estado de Goiás e Distrito Federal (Freitas; Pires; Benincá, 2024).

A Figura 9 apresenta um fluxograma metodológico que sintetiza as etapas do estudo, desde a coleta e preparação dos dados até a análise e interpretação dos resultados do modelo GWR, visando facilitar a compreensão do processo metodológico adotado e sua replicação em estudos futuros.

Figura 9 – *Fluxograma metodológico para modelagem da geração de resíduos sólidos urbanos por meio de regressão geograficamente ponderada no estado de Goiás e no Distrito Federal*



Fonte: Elaborada pelo autor.

3.3 Resultados e Discussões

A análise pelo (*Ordinary Least Squares* - OLS)² considerando nove variáveis explicativas (Tabela 1), sendo elas denotadas por POPDEN, TAMDOM, TXALF, TEMPM, PRECIPM, EMPFOR, PIBPCAPT, TXFESC, MEDEST. Os resultados do OLS indicaram um R^2 (0,991) ajustado elevado, porém, a análise de significância individual dos coeficientes ($\Pr(>|t|)$) revelou 4 variáveis não estatisticamente significantes (nível de significância de 5%) para a análise, sendo elas: TEMPM, PRECIPM, TXFESC e MEDEST (Tabela 2), dentre as 9 variáveis explicativas utilizadas (Tabela 1).

²Em português, Mínimos Quadrados Ordinários - MQO.

A prática de depender exclusivamente de limiares de p-valor para seleção de variáveis tem sido amplamente criticada por poder levar à exclusão de preditores potencialmente relevantes ou à inclusão de preditores espúrios, sendo fundamental considerar a plausibilidade teórica e a magnitude dos efeitos (Wasserstein; Schirm; Lazar, 2019; Amrhein; Trafimow; Greenland, 2019). Contudo, seguindo uma abordagem conservadora em análises exploratórias, optou-se por prosseguir apenas com as variáveis que demonstraram significância estatística no modelo global.

A presença de alta correlação entre variáveis preditoras pode inflar os erros padrão das estimativas, comprometendo a inferência sobre a contribuição individual de cada fator (Daoud *et al.*, 2025). Constatou-se que todas as dez variáveis iniciais apresentaram valores de VIF (Eq. 2) consideravelmente baixos (Tabela 2), afastando preocupações significativas quanto à multicolinearidade neste conjunto de dados específico. A combinação dos critérios de significância ($p < 0,05$) e baixo VIF ($< 7,5$) resultou na seleção de cinco variáveis para a modelagem GWR (Eq. 4), sendo elas: POPDEN, TAMDOM, TXALF, EMPFOR e PIBPCAPT (Tabela 2).

Tabela 2 – *Resultados do Modelo OLS: Significância ($Pr(>|t|)$) e Multicolinearidade (VIF) das Variáveis Preditoras Iniciais*

Variável	Probabilidade ($Pr(> t)$)	VIF	Decisão
POPDEN	$< 2e-16$	1.289	Manter
TAMDOM	0.00301	1.743	Manter
TXALF	0.03948	3.429	Manter
TEMPM	0.19131	2.814	Excluir (p)
PRECIPM	0.49081	2.319	Excluir (p)
EMPFOR	$< 2e-16$	1.235	Manter
PIBPCAPT	0.00269	1.216	Manter
TXFESC	0.59645	2.034	Excluir (p)
MEDEST	0.97477	3.075	Excluir (p)

A Tabela 3 apresenta as variáveis selecionadas para o modelo, os coeficientes de regressão, o erro padrão e a significância dos coeficientes. As variáveis escolhidas para o modelo são: densidade populacional, média de moradores em domicílios particulares permanentemente ocupados, taxa de alfabetização das pessoas de 15 anos ou mais de idade, número de empregos formais e PIB *per capita*. Todas as variáveis foram significativas (valor de $p < 0,05$).

Foi observado que os coeficientes estimados para as variáveis densidade populacional, tamanho médio dos domicílios, taxa de alfabetização e número de empregos formais foram positivos, ou seja, há uma associação positiva com a geração de resíduos sólidos. Portanto, em teoria, quanto maiores os valores destas variáveis, maior a média de geração de resíduos sólidos urbanos. Em contrapartida, a variável

Tabela 3 – *Resultados do modelo de regressão linear (OLS)*

Variável	Estimativa	Erro Padrão	t-valor	Pr(> t)
(Intercept)	-8.285e+07	2.987e+07	-2.774	0.00598
POPDEN	2.135e+04	1.897e+03	11.256	< 2e-16
TAMDOM	1.721e+07	4.046e+06	4.255	3.01e-05
TXALF	5.917e+05	2.858e+05	2.071	0.03948
EMPFOR	8.327e+02	5.875e+00	141.750	< 2e-16
PIBPCAPT	-4.723e+01	1.557e+01	-3.033	0.00269
Estatísticas do modelo:				
Erro padrão residual:		7.445e+06 (237 gl)		
R ² ajustado:		0.9909		
F-estatístico:		2989 (9 e 237 gl), p-valor < 2.2e-16		

PIB *per capita* fornece um coeficiente negativo, o que implica que quanto maior o valor dessa variável, menor a geração de RSU.

O R^2 ajustado³ (Tabela 3) indicou que o modelo global foi capaz de explicar cerca de 99% da geração total da geração de RSU nas regiões em estudo. No entanto, Os testes aplicados ao modelo OLS (Tabela 4) indicam limitações na sua capacidade de representar os padrões espaciais da variável dependente. O teste do Índice de Moran I (Tabela 4) apresentou valor de -0,0352 e *p-valor* de 0,8627, apontando ausência de autocorrelação espacial significativa nos resíduos. Por outro lado, a Tabela 4 apresenta o valor do teste de Shapiro-Wilk ($W = 0,7165$; $p < 2,2e-16$).

³O R^2 estatístico, ou coeficiente de determinação, é uma métrica que indica a proporção da variância na variável dependente que é explicada pelas variáveis independentes em um modelo de regressão. Este coeficiente de determinação mede quanto do erro de previsão é eliminado (Salmerón; García; García, 2018).

Este resultado mostrou que os resíduos não seguem uma distribuição normal. Esse resultado sugere que o modelo OLS não consegue captar variações locais e pode estar sendo influenciado por heterogeneidade espacial nas relações entre as variáveis (Hoover; Tate, 2025).

Tabela 4 – *Testes de diagnóstico dos resíduos do modelo OLS*

Teste	Estatística	Valor-p
Moran I	-0.0352	0.8627
Shapiro-Wilk	W = 0.7165	< 2.2e-16

Segundo Fotheringham, Brunson e Charlton (2009), essa limitação é comum em modelos globais, que assumem que os coeficientes são constantes no espaço. Assim, a utilização do GWR é adequada, pois permite estimar coeficientes específicos para cada local, considerando a variação espacial e proporcionando resultados mais ajustados às características regionais (Li *et al.*, 2019).

A determinação da largura de banda (*bandwidth*), utilizando-se do método AICc (Eq. 3) para o modelo GWR resultou na indicação de 99 vizinhos mais próximos. Este procedimento garante que um número constante de observações seja considerado para cada ponto de calibração, adaptando-se à densidade variável dos municípios goianos e do Distrito Federal, proporcionando estimativas locais mais estáveis.

O modelo GWR resultante demonstrou um ajuste significativamente superior ao modelo OLS global. O R^2 ajustado da GWR alcançou valor 0,9895, indicando que quase 99% da variação na geração de resíduos sólidos urbanos municipais foi explicada pelas seis variáveis selecionadas (POPDEN, TAMDOM, TXALF, EMPFOR, PIBPCAPT). Este resultado representa uma melhoria substancial em relação ao modelo OLS, que apresentou R^2 ajustado de 0,995. Adicionalmente, o valor do *Akaike Information Criterion corrected* (AICc) da GWR (8.407,293) foi menor que o do OLS (8.523,859), reforçando a superioridade do modelo GWR em capturar a estrutura dos dados (Lu *et al.*, 2014; Hurvich; Simonoff; Tsai, 2018). Esses indicadores confirmam a existência de não estacionariedade espacial, ou seja, as relações entre a geração de resíduos sólidos urbanos e seus determinantes variam significativamente ao longo do território goiano, justificando plenamente a aplicação da GWR.

A Tabela 5 mostra o resumo dos coeficientes estimados pelo modelo GWR. Esse modelo permite ver como as variáveis se comportam de maneira diferente em cada região. Ao contrário do modelo OLS, que apresenta apenas um valor geral para

todo o estado, o GWR mostra variações locais, revelando que cada região possui suas próprias características que influenciam a geração de resíduos. Isso ajuda a entender melhor onde cada fator tem mais ou menos influência. Por exemplo, o número de empregos formais mantém relação positiva em toda a região de estudo, enquanto o PIB *per capita* demonstra valores negativos em todas as regiões. Dessa forma, o GWR apresenta uma resultados mais detalhados e próximos da realidade regional.

Tabela 5 – *Resumo dos coeficientes estimados pelo modelo GWR*

Variável	Mínimo	1 ^o Quartil	Mediana	3 ^o Quartil	Máximo
Intercept	-2.9584e+08	-1.1575e+08	-7.8943e+07	-4.3022e+07	1.2769e+07
POPDEN	-2.9169e+04	2.1155e+04	4.2778e+04	5.6925e+04	9.5358e+04
TAMDOM	-4.1494e+06	1.6404e+06	5.7299e+06	1.7502e+07	5.6654e+07
TXALF	-9.8220e+04	2.4983e+05	6.4673e+05	1.0366e+06	1.9395e+06
PIBPCAPT	-9.7917e+01	-3.7101e+01	-2.3800e+01	-1.0112e+01	7.2641e+01
EMPFOR	6.5986e+02	6.9198e+02	8.2881e+02	8.9483e+02	1.6565e+03

Os resultados dos resíduos do modelo GWR, demonstrados na Tabela 6 mostram que a autocorrelação espacial foi quase eliminada, com valor de Moran I igual a -0,073 e p-valor de 0,9929. Isso indica que o modelo local conseguiu ajustar bem as relações espaciais, distribuindo os resíduos de forma aleatória e reduzindo padrões de dependência que não haviam sido capturados antes. Já o teste de Shapiro-Wilk apontou que os resíduos não seguem uma distribuição normal ($W = 0,6997$, $p < 2,2e-16$), o que sugere a existência de heterogeneidade nos dados, algo que modelos globais não conseguem representar adequadamente.

As seções a seguir apresentam o comportamento dos valores do coeficiente de determinação (R^2), que é uma medida estatística que indica o grau de explicação de um modelo sobre a variabilidade dos dados dependentes e das variáveis selecionadas nos municípios do estado de Goiás e Distrito Federal.

Para fins de referência, a localização geográfica de cada município mencionado pode ser consultada no mapa do estado de Goiás e do Distrito Federal (ver Apêndice B).

É importante destacar que os coeficientes estimados pela GWR não possuem um valor único para todo o território, mas variam localmente, refletindo a magnitude e a direção da influência de cada variável explicativa em cada município. Enquanto a regressão global assume efeitos homogêneos, a GWR permite capturar

Tabela 6 – *Indicadores globais e testes de diagnóstico do modelo GWR*

Indicador/Teste	Valor
AICc	8407.293
Soma dos quadrados dos resíduos	6.486e+15
R^2 ajustado	0.9949
Moran I	-0.0732 (p = 0.9929)
Shapiro-Wilk	W = 0.6997 (p < 2.2e-16)


heterogeneidades regionais, atribuindo maior peso às observações vizinhas durante a calibração do modelo (Fotheringham; Brunsdon; Charlton, 2009). Assim, coeficientes positivos indicam que o aumento da variável explicativa contribui para o crescimento da geração de resíduos em determinada localidade, enquanto coeficientes negativos apontam uma relação inversa (Mennis; Jordan, 2005; Polyceo, 2016). A representação cartográfica desses coeficientes constitui, portanto, uma ferramenta poderosa para identificar áreas em que variáveis socioeconômicas e demográficas exercem influência diferenciada, subsidiando políticas públicas mais adequadas às especificidades locais (Atlas.co, 2025; Elsevier, 2023).

3.3.1 Qualidade do modelo GWR para estimativas de taxas de geração de RSU com base no R^2

A Figura 10 ilustra o mapa da distribuição espacial da qualidade do R^2 local do modelo GWR nos municípios de Goiás e no Distrito Federal. E também, apresenta os valores de R^2 que demonstram a excelente capacidade preditiva do modelo *Geographically Weighted Regression* (GWR) em explicar a variabilidade espacial na geração de resíduos sólidos urbanos nos municípios goianos e no Distrito Federal, com valores oscilando entre 0,847 e 0,999. A média geral de R^2 local de 0,976 confirma que o modelo explica, em média, mais de 97% da variabilidade observada na geração de resíduos, superando significativamente os modelos globais tradicionais que tipicamente apresentam valores do R^2 entre 0,72 – 0,86 em estudos similares de resíduos sólidos municipais (Adusei *et al.*, 2022).

Esta alta qualidade do ajuste local (R^2) do modelo GWR nos municípios de Goiás e no Distrito Federal (Figura 10) indica que as cinco variáveis selecionadas (Tabela 5) – densidade populacional (POPDEN), tamanho dos domicílios (TAMDOM), alfabetização (TXALF), emprego formal (EMPFOR) e PIB *per ca-*

Figura 10 – *Distribuição espacial da qualidade do ajuste local (R^2) do modelo GWR nos municípios de Goiás e Distrito Federal*



Fonte: Elaborada pelo autor.

pita (PIBPCAPT) – são particularmente eficazes para explicar os padrões espaciais de geração de resíduos no contexto socioeconômico e territorial específico de Goiás e do Distrito Federal. A distribuição espacial dos valores de R^2 revela padrões regionais bem definidos, com uma concentração de municípios apresentando ajuste ($R^2 > 0,99$) nas regiões centro leste e parte da região oeste das regiões estudadas, formando *clusters* de alta qualidade preditiva que refletem a homogeneidade das características socioeconômicas e territoriais em cada uma dessas regiões.

A região metropolitana de Brasília, que inclui o Distrito Federal, os municípios goianos do entorno, e a região metropolitana de Goiânia, apresentam valores de R^2 elevados. Este resultado é relevante considerando que a Região Integrada de Desenvolvimento do Distrito Federal e Entorno (RIDE-DF) abriga mais de 4,2 milhões de habitantes e representa um dos principais polos de crescimento demográfico do país (SUDECO, 2022). A capacidade do modelo de explicar efetivamente a geração de resíduos nesta região complexa e heterogênea demonstra a robustez da

abordagem metodológica adotada.

A análise detalhada da distribuição espacial do R^2 local evidencia que os municípios com maior qualidade de ajuste ($R^2 > 0,99$) incluem tanto municípios da região central de Goiás quanto municípios do entorno de Brasília, demonstrando que o modelo é eficaz em capturar padrões diversos de geração de resíduos em diferentes contextos urbanos e metropolitanos.


Esta qualidade do ajuste pode estar relacionada às características específicas dos diferentes tipos de municípios analisados, onde os padrões de consumo e geração de resíduos seguem tendências previsíveis baseadas nos indicadores socioeconômicos selecionados, conforme observado em estudos sobre relação entre desenvolvimento socioeconômico e performance de modelos de resíduos sólidos (Velis *et al.*, 2023). A inclusão do Distrito Federal e dos municípios do entorno permite uma compreensão mais completa dos determinantes da geração de resíduos em uma das regiões de maior dinamismo econômico e demográfico do Centro-Oeste brasileiro.

3.3.2 Densidade Populacional (POPDEN)

Nas regiões em estudo (Figura 11), os valores da distribuição espacial dos coeficientes de densidade populacional com maiores coeficientes positivos concentram-se, em sua maioria, na Mesorregião Centro Goiano, especificamente nas microrregiões de Anápolis e Goiânia. Os municípios de São Francisco de Goiás (16,999), Campo Limpo de Goiás (16,728), Bonfinópolis (16,318), Terezópolis de Goiás (16,303) e Goi-anápolis (16,202) apresentam os valores mais elevados, todos localizados no entorno imediato da Região Metropolitana de Goiânia. A literatura científica internacional tem demonstrado a importância da densidade populacional como determinante da geração de resíduos sólidos municipais. Estudos conduzidos por pesquisadores têm evidenciado que a densidade populacional influencia tanto a quantidade quanto a composição dos resíduos gerados (Kawai; Tasaki, 2016).

Esta concentração de valores positivos na região central do estado reflete as características da urbanização goiana, onde a densidade populacional tem impacto na geração de resíduos. A Região Metropolitana de Goiânia, que registrou a segunda maior taxa de crescimento metropolitano do país entre 2010 e 2022, com expansão de 19,35% (Observatório de Metrôpoles, 2023), apresenta densidade populacional média de 364,25 hab./km², significativamente superior à média estadual de 20,74 hab./km² (IBGE, 2022). Este crescimento tem sido acompanhado por mudanças nos padrões de consumo urbano, resultando em maior geração de resíduos *per capita* em áreas de alta densidade populacional.

Figura 11 – *Distribuição espacial dos coeficientes de densidade populacional (POPDEN) nos municípios de Goiás e Distrito Federal*



Fonte: Elaborada pelo autor.

A intensidade destes coeficientes na região metropolitana pode ser explicada pela teoria da transição urbana, onde o aumento da densidade populacional em áreas metropolitanas está associado não apenas ao crescimento demográfico, mas também à mudança nos padrões de consumo, maior acesso a bens duráveis e não duráveis, e intensificação das atividades econômicas que resultam em maior geração de resíduos *per capita*, conforme documentado em estudos sobre fatores socioeconômicos que explicam a geração de resíduos municipais (Páramo-Telle; Vence, 2025).

São Francisco de Goiás, município que apresenta o maior coeficiente (16,999), localiza-se na microrregião de Anápolis e integra o eixo de desenvolvimento da região metropolitana de Goiânia-Anápolis-Brasília (Dutra; Araújo; Souza, 2023). Este município exemplifica o fenômeno de intensificação urbana característico da região central goiana, onde o aumento da densidade populacional resulta em incremento desproporcional na geração de resíduos devido à consolidação de padrões de consumo metropolitanos. Campo Limpo de Goiás (16,728), também na micror-

região de Anápolis, apresenta características similares, funcionando como município de expansão urbana da região metropolitana.

Em contraste, os menores coeficientes concentram-se em sua maioria na Mesorregião Noroeste Goiano, especificamente na microrregião de São Miguel do Araguaia. Os municípios de Mundo Novo (-0,467), São Miguel do Araguaia (-0,392), Nova Crixás (-0,385), Crixás (-0,371) e Mozarlândia (-0,255) apresentam coeficientes negativos, indicando que nestas localidades o aumento da densidade populacional está associado à redução na geração de resíduos *per capita*. Esta região apresenta estes resultados possivelmente devido a padrões de consumo mais sustentáveis, menor acesso a bens industrializados e práticas tradicionais de reutilização e compostagem que reduzem a geração de resíduos mesmo com aumento da densidade populacional (Nguyen; Chuang; Chen, 2020). Áreas rurais ou semi-rurais frequentemente apresentam padrões de consumo diferentes, com maior proporção de resíduos orgânicos compostáveis e menor geração de resíduos industrializados (Abdel-Shafy; Mansour, 2018).

A microrregião de São Miguel do Araguaia, que concentra todos os valores negativos, caracteriza-se por economia baseada na agropecuária extensiva e baixa densidade populacional média. Mundo Novo, município com menor coeficiente (-0,467), possui densidade populacional significativamente inferior aos municípios da região metropolitana de Goiânia. Esta diferença reflete não apenas aspectos demográficos, mas também padrões econômicos distintos, onde comunidades rurais tendem a apresentar práticas diferentes de gestão de recursos e menor geração de resíduos industrializados.


A distribuição espacial destes extremos evidencia uma polarização entre as mesorregiões Centro Goiano e Noroeste Goiano, demonstrando disparidades socioeconômicas. Esta polarização sugere que políticas de gestão de resíduos devem considerar as especificidades regionais, com estratégias diferenciadas para áreas metropolitanas de alta densidade e regiões rurais de baixa densidade populacional, alinhando-se com as diretrizes da Política Nacional de Resíduos Sólidos brasileira (Neto *et al.*, 2025).

3.3.3 Tamanho Médio dos Domicílios (TAMDOM)

A distribuição espacial dos coeficientes locais do tamanho médio dos domicílios nos municípios de Goiás e no Distrito Federal é mostrado na Figura 12. Esses coeficientes locais apresentam padrão espacial altamente concentrado, com todos os valores extremos positivos localizados na Mesorregião Leste Goiano, especificamente na microrregião do Entorno do Distrito Federal. Valparaíso de Goiás (11,051), Novo Gama (11,035), Cidade Ocidental (10,800), Santo Antônio do Descoberto (10,695)

e Águas Lindas de Goiás (10,381) constituem os cinco municípios com maiores coeficientes, todos integrantes da Região Integrada de Desenvolvimento do Distrito Federal e Entorno (RIDE-DF) (SUDECO, 2022).

Figura 12 – *Distribuição espacial dos coeficientes de tamanho médio dos domicílios (TAMDOM) nos municípios de Goiás e Distrito Federal*



Fonte: Elaborada pelo autor.

Esta concentração na microrregião do Entorno do Distrito Federal reflete as características socioeconômicas específicas desta área metropolitana, caracterizada por intensos fluxos migratórios e formação de domicílios com composições familiares diferenciadas (Codeplan, 2018). Segundo o estudo, essas composições correspondem a arranjos familiares que se afastam do modelo nuclear tradicional, reunindo famílias extensas, agregados e múltiplos núcleos sob o mesmo teto, como resultado de dinâmicas migratórias e condições econômicas que favorecem moradias coletivas e de maior porte. A RIDE-DF, que abrange 29 municípios e concentra mais de 4,2 milhões de habitantes (Xavier, 2025), tem experimentado crescimento demográfico superior ao próprio Distrito Federal, com o entorno crescendo mais rapidamente que a capital federal. Valparaíso de Goiás, município com maior coeficiente (11,051),

exemplifica este fenômeno, apresentando características de cidade-dormitório com domicílios de maior porte para acomodar famílias migrantes.

A intensidade destes coeficientes (Figura 12) no Entorno de Brasília, Distrito Federal, pode ser explicada pela teoria da transição demográfica urbana, onde famílias migrantes tendem a manter padrões de consumo e composição familiar diferenciados durante o processo de adaptação ao novo contexto urbano, resultando em relações específicas entre tamanho do domicílio e geração de resíduos que diferem dos padrões observados em regiões com populações mais estáveis, conforme documentado em estudos sobre impacto do status socioeconômico na geração de resíduos municipais (Khan; Kumar; Samadder, 2016).

Novo Gama (11,035) e Cidade Ocidental (10,800), municípios limítrofes ao Distrito Federal (Figura 12), funcionam como extensões habitacionais de Brasília, concentrando população que trabalha na capital mas reside no entorno devido ao menor custo habitacional (CODEPLAN, 2021). Esta dinâmica resulta em domicílios com características específicas, onde o maior número de pessoas por residência está associado a incremento desproporcional na geração de resíduos.

Em contraste, os menores coeficientes (Figura 12) encontram-se na Mesor-região Centro Goiano, distribuídos entre as microrregiões de Anápolis e Goiânia. Caturai (-0,715), Goianira (-0,691), Trindade (-0,686), Santa Bárbara de Goiás (-0,642) e Abadia de Goiás (-0,628) apresentam coeficientes negativos, indicando que nestas localidades o aumento do tamanho dos domicílios está associado à redução na geração de resíduos *per capita*. Estes municípios, todos integrantes ou próximos à Região Metropolitana de Goiânia, apresentam características urbanas consolidadas onde economias de escala no consumo familiar resultam em menor geração de resíduos por pessoa adicional no domicílio.

Caturai, município com menor coeficiente (-0,715), localiza-se na micror-região de Anápolis e apresenta características de município de pequeno porte com economia baseada na agropecuária. Esta localidade exemplifica o fenômeno onde domicílios maiores em contextos rurais ou semi-rurais tendem a apresentar práticas mais eficientes de gestão de recursos, maior reutilização de materiais entre membros da família e menor desperdício de alimentos (Grover; Singh, 2014). Goianira (-0,691) e Trindade (-0,686), municípios da microrregião de Goiânia, apresentam características similares, funcionando como cidades de expansão metropolitana onde domicílios maiores podem estar associados a práticas mais sustentáveis de consumo.

Estudos identificaram que em algumas comunidades, especialmente em áreas com forte tradição agrícola ou rural, famílias maiores tendem a apresentar práticas mais eficientes de uso de recursos, maior compartilhamento de bens duráveis, e menor desperdício de alimentos e materiais, resultando em menor geração de resíduos *per*

capita mesmo com maior número de pessoas no domicílio (Nguyen; Chuang; Chen, 2020). Este padrão pode também refletir características específicas da economia local do município de Caturai, onde famílias maiores podem estar associadas a atividades econômicas que promovem práticas mais sustentáveis de consumo e gestão de resíduos, demonstrando a complexidade da relação entre composição familiar e geração de resíduos em diferentes contextos territoriais e culturais (Gharagozloo; Ghazizade, 2023).


3.3.4 Taxa de Alfabetização (TXALF)

A distribuição espacial dos coeficientes da taxa de alfabetização nos municípios de Goiás e no Distrito Federal (Figura 13) apresenta variação espacial considerável, oscilando entre -0,213 (Amaralina) e 8,041 (Cabeceiras), demonstrando que o impacto da educação na geração de resíduos varia significativamente entre os municípios goianos.

O município de Cabeceiras apresenta o maior coeficiente positivo, indicando que nesta localidade maior alfabetização está associada a maior geração de resíduos, possivelmente refletindo maior acesso a informações sobre produtos, mudanças nos padrões de consumo e maior participação na economia formal. Esta relação positiva pode indicar que populações mais educadas têm maior acesso a bens de consumo, serviços e tecnologias que resultam em maior geração de resíduos, especialmente em contextos onde o desenvolvimento educacional está associado ao crescimento econômico local. A média positiva dos coeficientes (1,906) sugere que, na maioria dos municípios, maior alfabetização tende a resultar em maior geração de resíduos (Khan; Kumar; Samadder, 2016).

A distribuição regional dos coeficientes da taxa de alfabetização apresenta um padrão espacial bem definido, com uma concentração de valores muito altos, entre 4,545 - 8,041, na microrregião do Vão do Paranã e no norte do entorno do Distrito Federal, formando um *cluster* de municípios. Esta região se caracteriza por apresentar uma forte relação positiva entre alfabetização e geração de resíduos, possivelmente devido a características socioeconômicas específicas destas localidades, onde a alfabetização pode estar associada a mudanças significativas nos padrões de consumo.

Figura 13 – *Distribuição espacial dos coeficientes de taxa de alfabetização (TXALF) nos municípios de Goiás e Distrito Federal*



Fonte: Elaborada pelo autor.

Em contraste, na mesorregião do noroeste goiano (Figura 13), predominam coeficientes negativos (-0,213 a -0,450), indicando que nestas áreas o aumento na taxa de alfabetização está associado a uma redução na geração de resíduos. Segundo Zhao *et al.* (2024), esta relação negativa pode ser explicada pelo fato de que em algumas regiões, maior alfabetização está associada a maior conscientização ambiental e adoção de práticas mais sustentáveis de consumo e descarte.

A variabilidade espacial dos coeficientes da alfabetização também pode estar relacionada às diferentes oportunidades econômicas e padrões de desenvolvimento disponíveis em cada município, onde a educação pode ter impactos diferenciados dependendo do contexto socioeconômico local. Esta heterogeneidade confirma que a relação entre educação e geração de resíduos é complexa e contextualmente dependente (Velis *et al.*, 2023).

A análise dos coeficientes da taxa de alfabetização fornece indícios importantes para o desenvolvimento de programas educacionais diferenciados de gestão de

resíduos. Municípios com coeficientes positivos podem se beneficiar de programas de educação ambiental que promovam consciência sobre consumo sustentável, práticas de redução na fonte e comportamentos ambientalmente responsáveis.

Nestas localidades, a educação pode ser utilizada como ferramenta para canalizar o maior acesso à informação em direção a práticas mais sustentáveis. Por outro lado, municípios com coeficientes negativos podem servir como exemplos de como a educação pode ser efetivamente utilizada para promover práticas sustentáveis, fornecendo modelos que podem ser adaptados e replicados em outras áreas.


Mapunda, Kimwaga e Kassuwi (2024) destacam que a educação ambiental integrada aos programas de alfabetização pode ser uma estratégia eficaz para promover o desacoplamento entre alfabetização e geração de resíduos, especialmente em regiões onde esta relação é fortemente positiva. A compreensão desta variabilidade espacial permite o desenvolvimento de estratégias educacionais adaptadas às características locais, maximizando o potencial da educação como ferramenta de promoção da sustentabilidade na gestão de resíduos (Lino; Ismail; Castañeda-Ayarza, 2023).

3.3.5 PIB *per capita* (PIBPCAPT)

A análise da distribuição espacial dos coeficientes locais do PIB *per capita* (Figura 14) revela concentração dos valores extremos positivos na Mesorregião Centro Goiano, especificamente na microrregião de Anápolis. Petrolina de Goiás (1,328), Jesúpolis (1,228), Santa Rosa de Goiás (1,139), Damolândia (0,987) e Taquaral de Goiás (0,935) constituem os cinco municípios com maiores coeficientes, todos localizados nesta microrregião que se caracteriza como importante polo industrial e de agronegócios do estado.

Petrolina de Goiás, município com maior coeficiente (1,328), exemplifica o fenômeno de concentração industrial na microrregião de Anápolis, apresentando PIB *per capita* significativamente superior à média estadual devido à presença de atividades industriais de alto valor agregado. Este município, com população de aproximadamente 12.000 habitantes, concentra atividades do setor petroquímico e de beneficiamento agrícola que resultam em elevado PIB *per capita* e, consequentemente, em padrões de consumo que amplificam a geração de resíduos sólidos urbanos. A intensidade do coeficiente indica que cada incremento no PIB *per capita* resulta em aumento desproporcional na geração de resíduos, refletindo a relação direta entre renda e consumo de bens industrializados, conforme documentado em estudos sobre predição de geração de resíduos municipais (Xiaoming; Zhi; Akhundzada, 2025).

Figura 14 – *Distribuição espacial dos coeficientes de PIB per capita (PIBPCAPT) nos municípios de Goiás e Distrito Federal*



Fonte: Elaborada pelo autor.

Em contraste, os menores coeficientes (Figura 14) distribuem-se entre três mesorregiões distintas, com predominância na Mesorregião Leste Goiano. Mimoso de Goiás (-3,364), Padre Bernardo (-2,959) e Vila Propício (-2,894), todos da microrregião do Entorno do Distrito Federal, apresentam os três menores coeficientes, seguidos por Niquelândia (-2,841), da microrregião de Porangatu (Norte Goiano), e Barro Alto (-2,818), da microrregião de Ceres (Centro Goiano).

Mimoso de Goiás, município com menor coeficiente (-3,364), localiza-se na microrregião do Entorno do Distrito Federal e apresenta características paradoxais em relação aos demais municípios desta região. Enquanto outros municípios do entorno beneficiam-se da proximidade com Brasília, Mimoso de Goiás mantém características rurais. O PIB da cidade é de cerca de R\$ 247,6 milhões, sendo que 76,4% do valor adicionado advém da agropecuária, na sequência aparecem as participações dos serviços (11,1%), da administração pública (8,4%) e da indústria (4,1%) (Caravela, 2025). O PIB *per capita* pode ser inflado por grandes propriedades

rurais, mas isso não se traduz necessariamente em maior consumo urbano ou geração de resíduos domésticos. A população urbana pode ter renda relativamente baixa, resultando em menor geração de resíduos apesar do PIB *per capita* alto.

A média negativa (-0,758) para todo o estado é um resultado interessante que merece atenção. Isso indica que, na maioria dos municípios goianos, o maior PIB *per capita* está associado à menor geração de resíduos *per capita*. Este padrão pode refletir a estrutura econômica específica de Goiás, onde muitos municípios têm PIB alto devido ao agronegócio, mas isso não se traduz diretamente em maior consumo urbano. Estudos sobre o conceito da Curva Ambiental de Kuznets (CAK)⁴ sugerem que a relação entre renda e geração de resíduos pode ser não-linear, com países ou regiões mais ricas eventualmente reduzindo a geração de resíduos através de tecnologias mais eficientes e mudanças nos padrões de consumo (Blagoeva; Georgieva; Dimova, 2023).

Fontaine, Legros e Frayret (2025) observaram que esta relação negativa entre PIB *per capita* e geração de resíduos em algumas regiões pode indicar um processo de desacoplamento entre crescimento econômico e geração de resíduos, possivelmente devido a políticas ambientais mais eficientes, maior conscientização ambiental ou mudanças nos padrões de consumo em áreas mais desenvolvidas. A variabilidade espacial observada nos coeficientes do PIB *per capita* reflete a diversidade econômica do estado de Goiás, onde coexistem diferentes modelos de desenvolvimento e padrões de consumo.

Esta heterogeneidade confirma que a relação entre renda e geração de resíduos não é uniforme, dependendo das características econômicas e sociais específicas de cada município (Khan; Kumar; Samadder, 2016). Segundo Lu *et al.* (2024), este fenômeno pode indicar um processo de "*leapfrogging*"⁵ em algumas regiões, onde comunidades em desenvolvimento adotam diretamente práticas mais sustentáveis de consumo e gestão de resíduos, sem passar pela fase de alto desperdício típica de economias em transição.

3.3.6 Empregos Formais (EMPFOR)


A análise da distribuição espacial dos coeficientes locais do número de empregos formais (Figura 15) revela distribuição espacial mais diversificada em

⁴Curva Ambiental de Kuznets (CAK) descreve os impactos que o desenvolvimento econômico exerce sobre os níveis de emissões de poluentes, uma vez que estes estão intimamente relacionados com a produção de um país (Stern, 2018).

⁵O termo *leapfrogging* descreve o processo em que países ou regiões em desenvolvimento "saltam" etapas intermediárias do crescimento econômico e tecnológico, adotando diretamente práticas e tecnologias mais sustentáveis, sem repetir os estágios de alto consumo e poluição observados em economias industrializadas (Perkins, 2003).

comparação com as demais variáveis, com valores extremos positivos distribuídos entre três mesorregiões distintas. Campo Alegre de Goiás (183,528), Cristalina (180,991), Orizônia (180,516), Luziânia (179,002) e Santo Antônio do Descoberto (176,439), indicando que, em geral, o emprego formal tem um impacto positivo substancial na geração de resíduos nos municípios goianos, sendo a variável com o maior coeficiente médio entre todas as analisadas (Maalouf; Mavropoulos, 2023).

Figura 15 – *Distribuição espacial dos coeficientes de emprego formal (EMPFOR) nos municípios de Goiás e Distrito Federal*



Fonte: Elaborada pelo autor.

Esta relação positiva intensa pode estar associada a características específicas da economia local, como presença de indústrias, comércio desenvolvido ou serviços que geram tanto emprego formal quanto resíduos. A consistência dos coeficientes positivos em todo o estado confirma que a formalização do trabalho está universalmente associada ao aumento da geração de resíduos, refletindo a relação direta entre emprego formal, renda disponível e padrões de consumo (Khan; Kumar; Samadder, 2016).

Campo Alegre de Goiás, é o município com maior coeficiente (183,528), localiza-se na microrregião de Catalão e apresenta características específicas relacionadas à mineração e agropecuária moderna. Este município, que integra uma das principais regiões produtoras de grãos do estado, tem experimentado crescimento significativo no emprego formal devido à expansão do agronegócio e atividades de apoio (Estatísticas, 2025). O coeficiente extremamente elevado (Figura 15) indica que cada incremento no emprego formal resulta em aumento desproporcional na geração de resíduos, refletindo não apenas o aumento da renda, mas também mudanças nos padrões de consumo associadas à formalização do trabalho.

A distribuição dos valores extremos positivos entre diferentes mesorregiões evidencia que o emprego formal tem impacto significativo na geração de resíduos independentemente da localização geográfica, desde que associado a atividades econômicas modernas e acesso a mercados de consumo. Esta distribuição contrasta com as demais variáveis, que apresentam concentração espacial mais definida, sugerindo que a formalização do trabalho constitui fator transversal de influência nos padrões de consumo e geração de resíduos, conforme documentado em estudos sobre heterogeneidade espacial de fatores socioeconômicos (Mendez; Sachdeva, 2025).

Em contraste, na parte oeste do estado predominam coeficientes mais baixos (3,655-20,821), indicando que nestas áreas o aumento no número de empregos formais tem um impacto menor, embora ainda positivo, na geração de resíduos. Fontaine, Legros e Frayret (2025) observaram que esta variação regional no impacto do emprego formal pode estar relacionada a diferenças nos setores econômicos predominantes, nos níveis salariais e nos padrões de consumo associados ao emprego formal em diferentes contextos regionais.

O município de Jussara apresenta o menor coeficiente positivo (3,655), indicando que embora o emprego formal ainda contribua para a geração de resíduos, seu impacto é relativamente menor nesta localidade. Esta variação pode refletir diferenças nos tipos de emprego formal disponíveis, nos salários praticados ou nos padrões de consumo locais. A amplitude da variação nos coeficientes (de 3,655 a 183,528) demonstra que o impacto do emprego formal na geração de resíduos varia substancialmente entre os municípios, possivelmente relacionado às características específicas da economia local, disponibilidade de bens e serviços, e padrões de consumo regionais. Esta heterogeneidade espacial confirma que embora a direção da relação seja consistente (sempre positiva), sua magnitude varia significativamente dependendo do contexto socioeconômico local (Velis *et al.*, 2023).

É interessante notar que, diferentemente de outras variáveis analisadas, o número de empregos formais apresenta coeficientes positivos em todos os municípios goianos, sem exceção. Este resultado sugere que a formalização do emprego é um

determinante consistentemente positivo da geração de resíduos em todo o estado, embora a intensidade deste impacto varie significativamente entre diferentes regiões. Segundo Lu *et al.* (2024), esta relação positiva universal entre emprego formal e geração de resíduos é um fenômeno comum em economias em desenvolvimento, onde a formalização do emprego está fortemente associada ao aumento da renda disponível e à transição para padrões de consumo mais intensivos em recursos e geradores de resíduos. A compreensão desta variabilidade espacial permite o desenvolvimento de políticas integradas que promovam simultaneamente desenvolvimento econômico e sustentabilidade ambiental (Lino; Ismail; Castañeda-Ayarza, 2023).

3.3.7 Discussão Integrada dos Resultados

A análise espacial dos coeficientes locais do modelo GWR revela padrões regionais consistentes que refletem as disparidades socioeconômicas e as especificidades territoriais do estado de Goiás. A distribuição dos valores extremos evidencia cinco padrões espaciais principais: (1) concentração de valores positivos elevados na Mesorregião Centro Goiano para densidade populacional e PIB *per capita*; (2) predominância da Mesorregião Leste Goiano, especificamente do Entorno do Distrito Federal, para tamanho de domicílios e taxa de alfabetização; (3) distribuição mais diversificada dos empregos formais pelo estado e o Distrito Federal; (4) concentração de valores negativos na Mesorregião Noroeste Goiano; e (5) melhor ajuste do modelo nas regiões metropolitanas de Brasília e Goiânia.

Estes padrões refletem as dinâmicas de desenvolvimento regional que têm caracterizado Goiás nas últimas décadas, marcadas pela consolidação de dois principais eixos de crescimento: a Região Metropolitana de Goiânia e a Região Integrada de Desenvolvimento do Distrito Federal e Entorno (SUDECO, 2022). A Região Metropolitana de Goiânia, que concentra aproximadamente 35% da população estadual, apresenta características de metrópole consolidada onde a densidade populacional e o PIB *per capita* exercem forte influência na geração de resíduos devido aos padrões de consumo urbano intensivo (Observatório de Metrôpoles, 2023).

O Entorno do Distrito Federal, por sua vez, apresenta características específicas relacionadas aos fluxos migratórios direcionados à capital federal e às oportunidades econômicas geradas pela proximidade com Brasília. Esta região tem experimentado crescimento populacional acelerado, com municípios como Valparaíso de Goiás, Novo Gama e Águas Lindas de Goiás funcionando como cidades-dormitório que concentram população trabalhadora em Brasília (CODEPLAN, 2021). Esta dinâmica resulta em domicílios de maior porte e padrões específicos de consumo que amplificam a geração de resíduos.

A Mesorregião Noroeste Goiano, que concentra sistematicamente os valores extremos negativos para todas as variáveis, apresenta características que contrastam drasticamente com as regiões metropolitanas. Esta região, caracterizada por baixos indicadores de desenvolvimento social e economia baseada na agropecuária extensiva, mantém padrões tradicionais de consumo que resultam em menor geração de resíduos mesmo com incrementos nas variáveis socioeconômicas (Oliveira *et al.*, 2024). Este padrão sugere que políticas de gestão de resíduos devem considerar as especificidades culturais e econômicas regionais, reconhecendo que estratégias eficazes em regiões metropolitanas podem não ser adequadas para regiões rurais.

A distribuição espacial dos coeficientes também evidencia a importância da proximidade com centros urbanos na determinação dos padrões de consumo e geração de resíduos. Municípios localizados nas microrregiões de Anápolis, Goiânia e Entorno do Distrito Federal apresentam sistematicamente coeficientes mais elevados, refletindo o acesso fácil a mercados de consumo, maior diversidade de produtos disponíveis e padrões culturais que favorecem o consumo de bens industrializados (Mancini *et al.*, 2021).

A análise da qualidade do ajuste local (R^2) reforça estas conclusões, evidenciando que o modelo apresenta melhor desempenho em regiões com características socioeconômicas mais homogêneas e previsíveis, como o Entorno do Distrito Federal, e menor desempenho em regiões com dinâmicas mais complexas, como a microrregião de Catalão. Esta variação na qualidade do ajuste sugere que futuras pesquisas devem considerar a incorporação de variáveis explicativas adicionais específicas para cada região, bem como abordagens metodológicas que capturem adequadamente a heterogeneidade intra-regional (Lu *et al.*, 2014).

Os resultados obtidos têm implicações importantes para o planejamento de políticas públicas de gestão de resíduos sólidos urbanos em Goiás. A identificação de padrões espaciais específicos permite o desenvolvimento de estratégias regionalizadas que considerem as características locais de geração de resíduos. Regiões metropolitanas requerem políticas focadas na redução do consumo e no aumento da eficiência dos sistemas de coleta e tratamento, enquanto regiões rurais podem beneficiar-se de estratégias que valorizem práticas tradicionais sustentáveis e promovam a economia circular (Brasil, 2010).

A inclusão do Distrito Federal na análise representa um avanço metodológico significativo, permitindo uma compreensão mais completa das dinâmicas regionais que ultrapassam os limites administrativos estaduais. A influência da capital Brasília sobre os municípios goianos do entorno evidencia a necessidade de abordagens integradas de planejamento que considerem as interdependências metropolitanas e os fluxos socioeconômicos inter-regionais (Codeplan, 2018).

Os resultados confirmam a adequação da abordagem do modelo GWR para análise de fenômenos socioeconômicos espacialmente heterogêneos, demonstrando que modelos que incorporam a variação espacial dos parâmetros proporcionam compreensão mais nuançada dos processos territoriais. A capacidade do modelo de identificar padrões locais específicos e quantificar a qualidade do ajuste em diferentes regiões constitui ferramenta para pesquisadores e gestores públicos interessados em compreender e intervir em dinâmicas territoriais complexas.

3.4 Conclusão

A investigação realizada demonstra que a geração de resíduos sólidos urbanos em Goiás e no Distrito Federal é um fenômeno marcado pela heterogeneidade espacial, cuja compreensão exige modelos capazes de capturar variações locais. O modelo GWR revelou a amplitude dessas diferenças, evidenciando que fatores socioeconômicos, demográficos e educacionais exercem impactos distintos conforme o território. Essa multiplicidade de realidades coloca em xeque a validade de políticas uniformes, sugerindo que estratégias eficazes de gestão de resíduos devem partir do reconhecimento da diversidade interna do estado, especialmente entre áreas metropolitanas densamente povoadas e regiões de baixa densidade populacional.

Entre todas as variáveis analisadas (Tabela 5), o número de emprego formal (EMPFOR) destacou-se como o fator mais consistente e determinante da geração de resíduos sólidos urbanos (RSU). Diferentemente de outras variáveis, que oscilaram entre coeficientes positivos e negativos em diferentes regiões, o emprego formal (EMPFOR) apresentou correlação universalmente positiva em todos os municípios. Esse resultado indica que a formalização do trabalho, ao ampliar a renda disponível e estimular novos padrões de consumo, converte-se diretamente em maior produção de resíduos. Trata-se de um achado de grande relevância, pois conecta desenvolvimento econômico, estrutura do mercado de trabalho e impactos ambientais de forma inequívoca.

Esse padrão sugere que políticas públicas de gestão de resíduos devem considerar não apenas variáveis macroeconômicas tradicionais, mas também a dinâmica do emprego formal como vetor de intensificação do consumo urbano. Em municípios caracterizados por expansão do setor industrial, do comércio e dos serviços, o aumento do emprego formal tende a ampliar a demanda por bens duráveis e não duráveis, elevando a pressão sobre os sistemas de coleta e tratamento de resíduos. Reconhecer essa relação é fundamental para alinhar políticas de desenvolvimento econômico a estratégias de sustentabilidade, garantindo que o crescimento não resulte em sobrecarga ambiental.

Além da variável EMPFOR, outras variáveis (Tabela 5) apresentaram comportamentos regionais contrastantes que enriquecem a leitura espacial do fenômeno. A densidade populacional (POPDEN), por exemplo, mostrou-se fortemente associada à intensificação da geração de resíduos sólidos urbanos (RSU) em áreas metropolitanas, enquanto em regiões rurais e de baixa urbanização pôde se relacionar a padrões mais sustentáveis de descarte. O mesmo ocorreu com a taxa de alfabetização (TXALF) e o tamanho médio dos domicílios (TAMDOM), que revelaram influências ambíguas: em alguns contextos, vinculavam-se ao aumento do consumo; em outros, a práticas ambientalmente mais responsáveis. Esses contrastes reforçam que a gestão de resíduos deve ser territorializada, adaptando-se às especificidades de cada realidade local.

O caso particular da variável Produto Interno Bruto *per capita* (PIBPCAPT) ilustra como variáveis amplamente utilizadas em estudos comparativos internacionais podem adquirir significados distintos em contextos regionais. Em vários municípios goianos, especialmente no entorno do Distrito Federal e em áreas do Leste do estado, observou-se uma relação inversa entre PIB *per capita* e geração de resíduos. Esse padrão, em grande parte explicado pela predominância do agronegócio, mostra que altas rendas agregadas nem sempre se traduzem em maior consumo urbano. Assim, a variável PIBPCAPT, ainda que relevante, revelou-se insuficiente como indicador isolado para compreender a produção de resíduos sólidos em regiões de economia fortemente agroexportadora.

Do ponto de vista metodológico, a adoção do modelo GWR demonstrou-se particularmente adequada para desvendar tais nuances. O modelo não apenas superou estatisticamente a regressão global OLS em termos de ajuste, mas também possibilitou mapear territorialmente as intensidades e direções dos efeitos de cada variável. Essa abordagem trouxe clareza sobre como os determinantes da geração de resíduos se distribuem espacialmente, oferecendo um instrumento valioso para gestores públicos. Ao indicar regiões críticas e variáveis mais influentes em cada contexto, a modelagem espacial amplia a capacidade de planejamento e fomenta políticas mais eficazes e ajustadas à realidade local.

Os achados desta pesquisa reforçam a necessidade de um paradigma de governança ambiental multiescalar, que articule as esferas municipal, estadual e metropolitana em estratégias integradas de gestão de resíduos. O destaque do emprego formal (EMPFOR) como variável-chave indica que políticas de incentivo ao desenvolvimento econômico devem caminhar lado a lado com instrumentos de mitigação dos impactos ambientais, promovendo práticas de consumo mais sustentáveis. Reconhecer a pluralidade territorial e a complexidade das relações socioeconômicas é condição indispensável para avançar rumo a uma gestão de

resíduos sólidos urbanos que seja eficiente, justa e ambientalmente responsável, transformando desafios em oportunidades de inovação e sustentabilidade.

Considerações finais

4.1 Contribuições da pesquisa

Além de sua relevância metodológica, o trabalho traz contribuições significativas para a formulação de políticas públicas mais eficazes e territorialmente sensíveis. Por meio da aplicação do modelo GWR aos 246 municípios do estado de Goiás e Distrito Federal, identificou-se que variáveis como densidade populacional (POPDEN)), tamanho médio dos domicílios (TAMDOM), taxa de alfabetização (TXALF), PIB *per capita* (PIBPCAPT) e o número de empregos formais ((EMPFOR) explicam 98% da variabilidade global e 99% da variabilidade local na geração de resíduos sólidos urbanos (RSU).

Esses resultados permitem inferir quais municípios apresentam maior vulnerabilidade ou pressão sobre seus sistemas de gestão de resíduos, e quais fatores são mais determinantes em cada região. Por exemplo, municípios com baixa taxa de alfabetização e maior número médio de moradores por domicílio apresentaram maior geração per capita de resíduos, sugerindo a necessidade de ações específicas de educação ambiental e apoio à estrutura familiar. Essa análise espacial, portanto, fornece subsídios técnicos concretos para que gestores municipais e estaduais:

- Priorizem investimentos conforme as particularidades locais;
- Estabeleçam metas realistas de coleta seletiva e reciclagem;
- Estructurem sistemas de tratamento adaptados à realidade socioeconômica e geográfica;
- Direcionem políticas públicas ambientais com base em evidências e não apenas em médias estaduais.

Em um contexto de crescente pressão ambiental e orçamentária nos municípios brasileiros, os resultados aqui apresentados contribuem para a construção de estratégias de gestão sustentável baseadas em dados empíricos, promovendo maior equidade e eficiência na alocação de recursos e no planejamento ambiental.

4.2 Limitações do estudo

O presente estudo avançou na compreensão da geração de resíduos sólidos urbanos (RSU) em Goiás e no Distrito Federal, mas apresenta limitações que precisam ser consideradas. A principal delas está relacionada à disponibilidade de informações nas bases de dados e a atualizações da mesma, visto que até a presente data, nem todas as informações do censo foram divulgadas e outros fatores que poderiam ser utilizados ainda não possuem dados abertos. Além disso, a análise foi conduzida em um recorte temporal estático, o que restringe a observação da evolução histórica da geração de resíduos e impede avaliar o impacto de políticas públicas ao longo do tempo.

Do ponto de vista metodológico, a aplicação da Regressão Geograficamente Ponderada (GWR) trouxe ganhos significativos em relação ao modelo global, mas também envolve limitações próprias. A escolha da largura de banda e da função de kernel, por exemplo, pode alterar os resultados, exigindo cuidado na interpretação dos coeficientes locais.

Outro aspecto importante refere-se ao recorte espacial adotado, limitado ao estado de Goiás e ao Distrito Federal. Embora adequado ao objetivo do estudo, esse recorte não permite considerar fluxos interestaduais de resíduos ou influências externas, que podem impactar a dinâmica local. O reconhecimento dessas limitações reforça a necessidade de novas investigações que complementem e ampliem os resultados aqui apresentados.

4.3 Sugestões para pesquisas futuras

Diversas direções de aprofundamento podem orientar futuras pesquisas. Uma delas consiste em expandir a base de dados, incorporando variáveis ambientais e de infraestrutura, como qualidade da coleta, reciclagem, disposição final e indicadores de poluição. Esse avanço permitiria compreender de forma mais completa a relação entre determinantes socioeconômicos e impactos ambientais. Também se recomenda incluir séries temporais mais longas, de modo a captar variações históricas e avaliar os efeitos de políticas públicas implementadas ao longo do tempo.

Outra linha promissora é a aplicação de metodologias complementares ou alternativas à GWR, capazes de capturar relações não lineares e dependências espaciais mais complexas. Modelos espaciais Bayesianos, algoritmos de aprendizado de máquina e análises multiescalares podem oferecer novas perspectivas para entender a heterogeneidade da geração de resíduos em diferentes contextos. Tais abordagens

podem ainda ser comparadas entre si, verificando qual delas apresenta maior capacidade explicativa em diferentes cenários regionais.

Além disso, é recomendado integrar análises quantitativas e qualitativas, combinando a modelagem espacial com estudos sobre governança ambiental, políticas públicas e economia circular. O fortalecimento de redes de cooperação acadêmica e institucional é fundamental para ampliar a disponibilidade de dados e consolidar metodologias, favorecendo a construção de soluções mais eficazes para a gestão de resíduos sólidos urbanos.

4.4 Conclusão

A presente dissertação estruturou-se em dois artigos complementares, que, em conjunto, possibilitaram uma compreensão abrangente sobre a geração de resíduos sólidos urbanos e as potencialidades do modelo GWR para análise desse fenômeno. O primeiro artigo, de caráter bibliométrico e sistemático, permitiu mapear a evolução da produção científica internacional sobre o tema, identificando tendências, lacunas e metodologias mais recorrentes. O segundo, de natureza aplicada, realizou um estudo de caso em Goiás e no Distrito Federal, evidenciando como fatores socioeconômicos, demográficos e de infraestrutura influenciam espacialmente a geração de resíduos. Assim, os dois trabalhos dialogam entre si, unindo panorama global e aplicação regional.

A revisão de literatura revelou que a produção acadêmica com o modelo GWR e resíduos sólidos urbanos (RSU) têm crescido de forma significativa, sobretudo a partir de 2017, destaque para a liderança da China, que reformou a economia do país no final da década de 70, passando para uma economia de mercado que tem um setor privado em rápido crescimento e um forte setor estatal, fazendo sua economia desempenhar um papel fundamental na economia global. Constatando que a maioria dos estudos concentram-se em contaminação por metais pesados e em diagnósticos ambientais em áreas urbanas densamente povoadas. Entretanto, a pesquisa identificou carência de pesquisas em países em desenvolvimento, especialmente na América Latina, onde enfrentam desafios da gestão de resíduos, pelo fato da falta de políticas públicas e de ações governamentais planejadas e estruturadas para solucionar problemas sociais. Esse mapeamento revelou lacuna regional ainda pouco explorada.

Do ponto de vista metodológico, a revisão destacou a importância das bases de dados nacionais, internacionais da produção científica, uso de sensoriamento remoto, integração com Sistemas de Informação Geográfica e emprego de técnicas multivariadas. Essas práticas elevam a qualidade dos resultados e subsidiam políticas

públicas mais precisas. Contudo, também foram evidenciadas limitações, falta de padronização metodológica e a concentração de pesquisas em poucos países. Tal fato, justifica a necessidade de ampliar colaborações internacionais e fortalecer o acesso a dados abertos e confiáveis, condição essencial para expandir a aplicação do modelo GWR em diferentes realidades socioeconômicas.

O estudo de caso em Goiás e no Distrito Federal complementou essas discussões, demonstrando como o modelo GWR pode ser utilizado para revelar padrões espaciais heterogêneos na geração de resíduos sólidos urbanos. Os resultados mostraram que variáveis socioeconômicas como densidade populacional, tamanho médio dos domicílios, taxa de alfabetização, PIB *per capita* e empregos formais explicam de forma significativa a variação observada. Além disso, a análise local indicou ganhos substanciais de ajuste em relação ao modelo OLS, confirmando a adequação da abordagem espacial. Esse achado consolida o modelo GWR como ferramenta eficaz para estudos regionais de gestão ambiental.

Um dos principais méritos do estudo de caso foi evidenciar que os determinantes da geração de resíduos não atuam de maneira uniforme em todo o território. Regiões metropolitanas de Goiânia e do Entorno de Brasília, apresentaram maior influência de fatores ligados à densidade urbana e infraestrutura viária, enquanto municípios de menor economia foram mais sensíveis a aspectos educacionais e socioeconômicos. Essa heterogeneidade demonstra a carência de políticas públicas em garantir o bem estar da população local e regional no setor de resíduos sólidos urbanos.

A integração entre os dois artigos também fortalece o vínculo entre teoria e prática. Enquanto a revisão de literatura destacou tendências e lacunas globais, o estudo de caso demonstrou eficiência do modelo GWR com variáveis socioeconômicas e regionais no Brasil. Essa articulação amplia a relevância científica da pesquisa, e evidencia que análises espaciais avançadas podem apoiar não apenas diagnósticos ambientais, mas também o planejamento urbano, a definição de prioridades de investimento e a mitigação de desigualdades socioambientais.

Por fim, a pesquisa reafirma que compreender a geração de resíduos sólidos exige abordagens multidimensionais, capazes de integrar fatores sociais, econômicos e territoriais. O uso do GWR demonstrou-se promissor tanto para consolidar o campo científico, ainda em expansão, quanto para orientar a gestão pública em Goiás e no Distrito Federal. Futuras pesquisas podem explorar novas variáveis, como infraestrutura de coleta seletiva e indicadores ambientais, além de ampliar a escala temporal das análises. Com isso, fortalecer o diálogo entre ciência e políticas públicas, contribuindo para a construção de cidades mais sustentáveis.

Referências

ABDEL-SHAFY, Hussein I; MANSOUR, Mona SM. Solid waste issue: Sources, composition, disposal, recycling, and valorization. **Egyptian journal of petroleum**, Elsevier, v. 27, n. 4, p. 1275–1290, 2018. 65

ABDULLAH, Nibras; AL-WESABI, Ola A; MOHAMMED, Badiea Abdulkarem; AL-MEKHLAFI, Zeyad Ghaleb; ALAZMI, Meshari; ALSAFFAR, Mohammad; BAKLIZI, Mahmoud; SUMARI, Putra. Iot-based waste management system in formal and informal public areas in mecca. **International Journal of Environmental Research and Public Health**, MDPI, v. 19, n. 20, p. 13066, 2022. 27, 29

ABRELPE, Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais. **Panorama dos Resíduos Sólidos no Brasil 2023**. São Paulo: [s.n.], 2023. 44, 45, 49, 50

ADUSEI, K. K.; NG, K. T. W.; KARIMI, N.; MAHMUD, T. S.; DOOLITTLE, E. Modeling of municipal waste disposal behaviors related to meteorological seasons using recurrent neural network lstm models. **Ecological Informatics**, Elsevier, v. 72, p. 101925, 2022. 61

AGYEMAN, P. C.; KINGSLEY, J.; KEBONYE, N. M.; BORÚUVKA, L.; VAVSÁT, R.; DRÁBEK, O.; NVEMEVCEK, K. Human health risk exposure and ecological risk assessment of potentially toxic element pollution in agricultural soils in the district of frydek mistek, czech republic: a sample location approach. **Environmental Sciences Europe**, Springer, v. 33, n. 1, p. 137, 2021. 39

AGYEMAN, Prince Chapman; KINGSLEY, Jonh; KEBONYE, Ndiye Michael; OFORI, Solomon; BORUVKA, Lubovs; VAVSÁT, Radim; KOVCÀREK, Martin. Ecological risk source distribution, uncertainty analysis, and application of geographically weighted regression cokriging for prediction of potentially toxic elements in agricultural soils. **Process Safety and Environmental Protection**, Elsevier, v. 164, p. 729–746, 2022. 33

AKINGBEMISILU, Tosin Harold. A critical evaluation of government role in spatial data infrastructures for healthcare decision-making. **Journal of Public Policy**, v. 8, n. 1, p. 14–23, 2024. 27

ALMEIDA, Eduardo. Econometria espacial. **Campinas–SP. Alínea**, v. 31, 2012. 55

ALZAMORA, Bruno Ribas; BARROS, Raphael Tobias de Vasconcelos; OLIVEIRA, Leise Kelli de; GONCALVES, Sabrina Silveira. Forecasting and the influence of socioeconomic factors on municipal solid waste generation: A literature review. **Environmental Development**, Elsevier, v. 44, p. 100734, 2022. 20, 21, 39, 46, 51

AMINZADEGAN, Sajede; SHAHRIARI, Mohsen; MEHRANFAR, Fahime; ABRA-MOVIĆ, Borna. Factors affecting the emission of pollutants in different types of transportation: A literature review. **Energy Reports**, Elsevier, v. 8, p. 2508–2529, 2022. 40

AMRHEIN, Valentin; TRAFIMOW, David; GREENLAND, Sander. Inferential statistics as descriptive statistics: There is no replication crisis if we don't expect replication. **The American Statistician**, Taylor & Francis, v. 73, n. sup1, p. 262–270, 2019. 57

ANSELIN, Luc. Local indicators of spatial association—lisa. **Geographical analysis**, Wiley Online Library, v. 27, n. 2, p. 93–115, 1995. 55

ANTCZAK, Elżbieta. Municipal waste in poland: Analysis of the spatial dimensions of determinants using geographically weighted regression. **European Spatial Research and Policy**, Wydawnictwo Uniwersytetu Łódzkiego, v. 26, n. 2, p. 177–197, 2019. 27, 41, 46, 47, 51

ANTCZAK, Elżbieta. Regionally divergent patterns in factors affecting municipal waste production: the polish perspective. **Sustainability**, MDPI, v. 12, n. 17, p. 6885, 2020. 28, 29, 39, 40, 42

ARBULÚ, Italo; LOZANO, Javier; REY-MAQUIEIRA, Javier. The challenges of municipal solid waste management systems provided by public-private partnerships in mature tourist destinations: The case of mallorca. **Waste Management**, Elsevier, v. 51, p. 252–258, 2016. 51

ARIA, Massimo; CUCCURULLO, Corrado. bibliometrix: An r-tool for comprehensive science mapping analysis. **Journal of informetrics**, Elsevier, v. 11, n. 4, p. 959–975, 2017. 29, 31

ATLAS.CO. **Geographic Weighted Regression – Definitions & FAQs**. 2025. <https://atlas.co/glossary/geographic-weighted-regression/>. Acesso em: 05 set. 2025. 61

BIVAND, Roger S; PEBESMA, Edzer J; GOMEZ-RUBIO, Virgilio. **Applied spatial data analysis with R**. [S.l.]: Springer, 2008. 52

BLAGOEVA, Nadezhda; GEORGIEVA, Vanya; DIMOVA, Delyana. Relationship between gdp and municipal waste: Regional disparities and implication for waste management policies. **Sustainability**, MDPI, v. 15, n. 21, p. 15193, 2023. 46, 72

BLEISCHWITZ, Raimund; YANG, Miying; HUANG, Beijia; XU, Xiaozhen; ZHOU, Jie; MCDOWALL, Will; ANDREWS-SPEED, Philip; LIU, Zhe; YONG, Geng. The circular economy in china: Achievements, challenges and potential implications for decarbonisation. **Resources, Conservation and Recycling**, Elsevier, v. 183, p. 106350, 2022. 34, 35

Brasil. **Lei nº 12.305, de 2 de agosto de 2010. Institui a Política Nacional de Resíduos Sólidos**. Brasília, DF: [s.n.], 2010. 3 ago. 2010. 30, 45, 76

Brasil (Decreto nº 10.936/2022). **Decreto nº 10.936, de 12 de janeiro de 2022. Regulamenta a Lei nº 12.305, de 2 de agosto de 2010**. 2022. Brasília, DF: [s.n.]. 13 jan. 2022a. 45

Brasil (Decreto nº 11.043/2022). **Decreto nº 11.043, de 13 de abril de 2022. Aprova o Plano Nacional de Resíduos Sólidos**. 2022. Brasília, DF: [s.n.]. 14 abr. 2022b. 45

BUJANDA, Arturo; FULLERTON, Thomas M. Impacts of transportation infrastructure on single-family property values. **Applied Economics**, Taylor & Francis, v. 49, n. 51, p. 5183–5199, 2017. 41

CARAVELA. **Caravela Dados e Estatísticas**. Mimoso de Goiás - GO, 2025. Acessado em: 25 jul. 2025. Disponível em: <https://www.caravela.info/regional/mimoso-de-go%C3%A1s---go>. 71

CHEN, Feng; LEUNG, Yee; WANG, Qiang; ZHOU, Yu. Spatial non-stationarity test of regression relationships in the multiscale geographically weighted regression model. **Spatial Statistics**, Elsevier, v. 62, p. 100846, 2024. 52, 53, 54

CHEN, Fangke; ZHANG, Shiwen; LIANG, Yuwei; YIN, Aojie. Spatiotemporal variability in municipal solid waste production and the determinants in hefei's core urban districts. **Sustainability**, MDPI, v. 15, n. 22, p. 16058, 2023. 51

CHEN, Xiaohui; ZHAO, Qing; HUANG, Fei; QIU, Rongzu; LIN, Yuhong; ZHANG, Lanyi; HU, Xisheng. Understanding spatial variation in the driving pattern of carbon dioxide emissions from taxi sector in great eastern china: Evidence from an analysis of geographically weighted regression. **Clean Technologies and Environmental Policy**, Springer, v. 22, n. 4, p. 979–991, 2020. 39

CHEN, Zhifan; ZHANG, Sen; GENG, Wencai; DING, Yongfeng; JIANG, Xingyuan. Use of geographically weighted regression (gwr) to reveal spatially varying relationships between cd accumulation and soil properties at field scale. **Land**, MDPI, v. 11, n. 5, p. 635, 2022. 28, 47

CHENG, Jinhua; SHI, Fengyu; YI, Jiahui; FU, Hongxue. Analysis of the factors that affect the production of municipal solid waste in china. **Journal of cleaner production**, Elsevier, v. 259, p. 120808, 2020. 28, 39

CHENG, Shuang; ZHANG, Guoqiao; YANG, Xuexi; LEI, Bingfeng. A multiscale geographically weighted regression kriging method for spatial downscaling of satellite-based ozone datasets. **Frontiers in Environmental Science**, Frontiers Media SA, v. 11, p. 1267752, 2024. 47

CHHAY, Leaksmy; REYAD, Md Amjad Hossain; SUY, Rathny; ISLAM, Md Rafiqul; MIAN, Md Manik. Municipal solid waste generation in china: influencing factor analysis and multi-model forecasting. **Journal of Material Cycles and Waste Management**, Springer, v. 20, n. 3, p. 1761–1770, 2018. 20

Codeplan. **Brasília e sua Região Polarizada**. [S.l.: s.n.], 2018. 66, 76

CODEPLAN. **Pesquisa Metropolitana por Amostra de Domicílios (PMAD) Entorno 2021**. [S.l.: s.n.], 2021. 67, 75

COLVERO, Diogo Appel; CARVALHO, Eraldo Henriques de; PFEIFFER, Simone Costa; GOMES, Ana Paula. Avaliação da geração de resíduos sólidos urbanos no estado de goiás, brasil: análise estatística de dados. **Engenharia Sanitaria e Ambiental**, SciELO Brasil, v. 22, n. 05, p. 931–941, 2017. 45, 46

COMBER, Alexis; SEE, Linda; FRITZ, Steffen; VELDE, Marijn Van der; PERGER, Christoph; FOODY, Giles. Using control data to determine the reliability of volunteered geographic information about land cover. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 23, p. 37–48, 2013. 52, 53

- CUI, Lulu; LI, Rui; ZHANG, Yunchen; MENG, Ya; ZHAO, Yilong; FU, Hongbo. A geographically and temporally weighted regression model for assessing intra-urban variability of volatile organic compounds (vocs) in yangpu district, shanghai. **Atmospheric Environment**, Elsevier, v. 213, p. 746–756, 2019. 39
- CUI, Wenjing; WEI, Yuan. Spatio-temporal evolution and the driving factors of municipal solid waste in chinese different geographical regions between 2002 and 2020. **Environmental Research**, Elsevier, v. 240, p. 117456, 2024. 28
- DAOUD, Omar Walid; AHMED, Vian; ALZAATREH, Ayman; ANANE, Chiraz. The impact of socio-economic factors on recycling behavior and waste generation: Insights from a diverse university population in the uae. **Cleaner Waste Systems**, Elsevier, v. 11, p. 100266, 2025. 46, 47, 48, 51, 52, 53, 54, 57
- DESHPANDE, Ashutosh; RAMANATHAN, Vasanth; BABU, Karthigaiselvan; DESHPANDE, A; RAMANATHAN, V; BABU, K. Assessing the socioeconomic factors affecting household waste generation and recycling behavior in chennai: A survey-based study. **International Journal of Science and Research Archive**, v. 11, n. 2, p. 750–758, 2024. 20
- DEUS, Rafael Mattos; BATTISTELLE, Rosane Aparecida Gomes; SILVA, Gustavo Henrique Ribeiro. Resíduos sólidos no brasil: contexto, lacunas e tendências. **Engenharia Sanitária e Ambiental**, SciELO Brasil, v. 20, n. 4, p. 685–698, 2015. 48
- DONTHI, Rama Bhupal Reddy; RAMANNAGARI, Bhavani. Impact of socioeconomic status on characterization of household waste in anantapur municipal corporation region, andhra pradesh, india. **Journal of Material Cycles and Waste Management**, Springer, p. 1–13, 2025. 20
- DONTHU, Naveen; KUMAR, Satish; SUREKA, Riya; JOSHI, Rohit. Research constituents and citation analysis of the journal of business and industrial marketing (1986–2019). **Journal of Business & Industrial Marketing**, v. 36, n. 8, p. 1435–1451, 2021. 29
- DORMANN, Carsten F; CALABRESE, Justin M; GUILLERA-ARROITA, Gurutzeta; MATECHOU, Eleni; BAHN, Volker; BARTOŃ, Kamil; BEALE, Colin M; CIUTI, Simone; ELITH, Jane; GERSTNER, Katharina *et al.* Model averaging in ecology: A review of bayesian, information-theoretic, and tactical approaches for predictive inference. **Ecological monographs**, Wiley Online Library, v. 88, n. 4, p. 485–504, 2018. 53

DUNKEL, Jürgen; DOMINGUEZ, David; BORZDYNski, Óscar G; SÁNCHEZ, Ángel. Solid waste analysis using open-access socio-economic data. **Sustainability**, MDPI, v. 14, n. 3, p. 1233, 2022. 21

DURÁN, Claudia E Saldaña; MESSINA, Sarah. Urban management model: Municipal solid waste for city sustainability. *In: Municipal solid waste management*. [S.l.]: IntechOpen, 2019. 42

DUTRA, Rodrigo Marciel Soares; ARAÚJO, Adilson Ribeiro de; SOUZA, Murilo Mendonça Oliveira de. Goiabira: O arranjo urbano-regional goiânia-anápolis-brasília. **Revista Tocantinense de Geografia**, v. 12, n. 27, p. 35–53, 2023. 64

EDITION, Fourth. Guidelines for drinking-water quality. **WHO chronicle**, v. 38, n. 4, p. 104–8, 2011. Disponível em: <https://www.who.int/publications/i/item/9789241549950>. 40

ELSEVIER. **Geographically weighted regression (GWR) analysis provide a set of statistics...** 2023. <https://www.sciencedirect.com/topics/earth-and-planetary-sciences/geographically-weighted-regression>. Acesso em: 05 set. 2025. 61

ESTATÍSTICAS, Caravela Dados e. **Economia de Campo Alegre de Goiás-GO**. 2025. <https://www.caravela.info/regional/campo-alegre-de-go>Acessado em 19 setembro de 2025. 74

FAN, Jingjing; WANG, Dongnan; ZHAO, Yue; ZHOU, Xiong; CHENG, Yao; XU, Fanfan; WEI, Shibo; LIU, Huixin. Spatiotemporal geographically weighted regression analysis for runoff variations in the weihe river basin. **Journal of Environmental Management**, Elsevier, v. 366, p. 121908, 2024. 47

FANG, Ming; CHANG, Chiu-Lan. Nexus between fiscal imbalances, green fiscal spending, and green economic growth: Empirical findings from e-7 economies. **Economic Change and Restructuring**, v. 55, n. 4, p. 2423–2443, 2022. 39, 41

FIELD, Andy. **Descobrimdo a estatística usando o SPSS-5**. [S.l.]: Penso Editora, 2020. 55

FIGUEREDO, Wilton Nascimento *et al.* Análise bibliométrica da produção brasileira sobre a covid-19. **Revista Baiana de Enfermagem**, v. 34, 2020. 30

FONTAINE, Laurie; LEGROS, Robert; FRAYRET, Jean-Marc. Solid waste generation prediction model framework using socioeconomic and demographic factors with

real-time msw collection data. **Waste Management & Research**, v. 43, n. 2, p. 267–281, 2025. 72, 74

FOTHERINGHAM, A Stewart; BRUNSDON, Chris; CHARLTON, Martin. Geographically weighted regression. **The Sage handbook of spatial analysis**, Sage Thousand Oaks, CA, v. 1, p. 243–254, 2009. 59, 61

FREITAS, Mydiã Falcão; PIRES, Mônica Moura; BENINCÁ, Dirceu. Fragilidades e potencialidades na gestão dos resíduos sólidos urbanos no brasil. **urbe. Revista Brasileira de Gestão Urbana**, v. 16, p. e20230271, 2024. 44, 45, 49, 53, 54, 56

GDF, Governo do Distrito Federal. **Plano Distrital de Gestão Integrada de Resíduos Sólidos**. 2017. 45

GHANBARI, Forough; KAMALAN, Hamidreza; SARRAF, Amirpouya. An evolutionary machine learning approach for municipal solid waste generation estimation utilizing socioeconomic components. **Arabian Journal of Geosciences**, Springer, v. 14, n. 2, p. 92, 2021. 21

GHARAGOZLOO, Shaghayegh; GHAZIZADE, Mahdi Jalili. The influence of socioeconomic and psychological factors on the composition of household solid waste in farahzad neighborhood, tehran, iran. **Environmental Health Insights**, v. 17, p. 11786302231195794, 2023. 68

GHASEMI, Asghar; ZAHEDIASL, Saleh. Normality tests for statistical analysis: a guide for non-statisticians. **International journal of endocrinology and metabolism**, v. 10, n. 2, p. 486, 2012. 55

GHINEA, Cristina; DRĂGOI, Elena Niculina; COMĂNIȚĂ, Elena-Diana; GAVRILESCU, Marius; CÂMPEAN, Teofil; CURTEANU, SILVIA; GAVRILESCU, Maria. Forecasting municipal solid waste generation using prognostic tools and regression analysis. **Journal of environmental management**, Elsevier, v. 182, p. 80–93, 2016. 51

GICHAMO, T; GÖKÇEKUŞ, H. Interrelation between climate change and solid waste. **J. Environ. Pollut. Control**, v. 2, n. 1, p. 104, 2019. 46

GILBERT, Angela; CHAKRABORTY, Jayajit. Using geographically weighted regression for environmental justice analysis: Cumulative cancer risks from air toxics in florida. **Social Science Research**, v. 40, n. 1, p. 273–286, 2011. 34

Goiás. **Lei nº 21.830, de 22 de março de 2023. Altera a Lei nº 14.248, de 29 de julho de 2002, que dispõe sobre a Política Estadual de Resíduos**

Sólidos e dá outras providências, para incluir disposições especiais sobre os serviços ambientais de reciclagem. Goiânia, GO: [s.n.], 2023. 22 mar. 2023. 45

Google. **NotebookLM: AI-based approach to summarizing user documents.** 2023. 32

GRINESKI, Sara E.; COLLINS, Timothy W.; OLVERA, Hector A. Local variability in the impacts of residential particulate matter and pest exposure on children's wheezing severity: a geographically weighted regression analysis of environmental health justice. **Population and environment**, v. 37, p. 22–43, 2015. 34

GROVER, Priya; SINGH, Pavitra. An analytical study oif effect of family income and size on per capita household solid waste generation in developing countries. **American Research Institute for Policy Development**, v. 3, n. 1, p. 127–143, 2014. 67

HE, Rui; SANDOVAL-REYES, Mexitli; SCOTT, Ian; SEMEANO, Rui; FERRAO, Paulo; MATTHEWS, Scott; SMALL, Mitchell J. Global knowledge base for municipal solid waste management: Framework development and application in waste generation prediction. **Journal of Cleaner Production**, Elsevier, v. 377, p. 134501, 2022. 20, 21

HOOVER, Shelley; TATE, Eric. Spatial heterogeneity in social vulnerability to flood exposure. **Natural Hazards**, Springer, p. 1–25, 2025. 59

HOZ-M, Javier De La; FERNANDEZ-GÓMEZ, María José; MENDES, Susana. Trends and topics in geographically weighted regression research from 1996 to 2019. **Area**, v. 54, n. 1, p. 105–117, 2022. 33

HURVICH, Clifford M.; SIMONOFF, Jeffrey S.; TSAI, Chih-Ling. Smoothing parameter selection in nonparametric regression using an improved akaike information criterion. **Journal of the Royal Statistical Society Series B: Statistical Methodology**, v. 60, n. 2, p. 271–293, 2018. 53, 59

IBGE - Instituto Brasileiro de Geografia e Estatística. **Pesquisa de Informações Básicas Municipais - MUNIC 2023.** Rio de Janeiro: [s.n.], 2023. 44, 45

IBGE, Instituto Brasileiro de Geografia e Estatística. **Censo Demográfico 2022.** Rio de Janeiro: [s.n.], 2022. 48, 50, 51, 63

IEA Bioenergy. **Social and Environmental Sustainability of Municipal Solid Waste in the Context of the UN Sustainable Development Goals.** [S.l.: s.n.], 2025. March 2025. 18, 19, 44

IMB, Instituto Mauro Borges. **Estatísticas Municipais - Goiás**. Goiânia: [s.n.], 2024. 48

ISMAILA, AB; MUHAMMED, I; BIBI, UM; HUSAIN, MA. Modelling municipal solid waste generation using geographically weighted regression: a case study of nigeria. **International Research Journal of Environment Sciences**, v. 4, n. 8, p. 98–108, 2015. 23, 42, 46, 51

JIAO, Jianling; SHUAI, Yana; LI, Jingjing. Incentive effects of subsidy policies on chinese municipal solid waste recycling considering price competition: Subsidies for residents or recyclers? **Environment, Development and Sustainability**, v. 26, n. 11, p. 27529–27551, 2024. 27

KALA, Kaveri; BOLIA, Nomesh B. Effects of socio-economic factors on quantity and type of municipal solid waste. **Management of Environmental Quality: An International Journal**, Emerald Publishing Limited, v. 31, n. 4, p. 877–894, 2020. 21

KATEBIKORD, Azadeh; SADEGHI, Seyed Hamidreza; SINGH, Vijay P. Spatial modeling of soil organic carbon using remotely sensed indices and environmental field inventory variables. **Environmental Monitoring and Assessment**, v. 194, n. 3, p. 152, 2022. 40

KAWAI, Katsuhiko; TASAKI, Tomohiro. Trends in per capita generation of municipal solid waste in japan. **Waste Management**, Elsevier, v. 48, p. 102–111, 2016. 63

KAZA, Silpa; YAO, Lisa; BHADA-TATA, Perinaz; WOERDEN, Frank Van. **What a waste 2.0: a global snapshot of solid waste management to 2050**. [S.l.]: World Bank Publications, 2018. 27

KESER, Saniye; DUZGUN, Sebnem; AKSOY, Aysegul. Application of spatial and non-spatial data analysis in determination of the factors that impact municipal solid waste generation rates in turkey. **Waste Management**, v. 32, n. 3, p. 359–371, 2012. 28, 39, 40, 42

KHAN, D.; KUMAR, A.; SAMADDER, S. R. Impact of socioeconomic status on municipal solid waste generation rate. **Waste management**, v. 49, p. 15–25, 2016. 67, 68, 72, 73

KOLEKAR, K. A.; HAZRA, T.; CHAKRABARTY, S. N. A review on prediction of municipal solid waste generation models. **Procedia Environmental Sciences**, v. 35, p. 238–244, 2016. 46

KONTOS, Themistoklis D.; ZEYGOLIS, Yiannis G. A fuzzy spatial multiple criteria analysis methodology for solid waste landfill siting. **J**, v. 7, n. 4, p. 502–528, 2024. 28

KRISTÝNARYBOVÁ, Jan Slavík. **Smart cities and ageing Population—Implications for waste management in the Czech Republic**. [S.l.]: IEEE, 2016. 51

KUT, Paweł; PIETRUCHA-URBANIK, Katarzyna. Bibliometric analysis of multi-criteria decision-making (mcdm) methods in environmental and energy engineering using citespace software: Identification of key research trends and patterns of international cooperation. **Energies**, v. 17, n. 16, p. 3941, 2024. 41

KUZIEMSKA, Beata; GRUŻEWSKA, Agata; WYSOKIŃSKI, Andrzej; PAKUŁA, Krzysztof; PIENIAK-LENDZION, Krystyna. Environmental awareness and knowledge of municipal waste management among inhabitants of eastern mazovia. **Rocznik Ochrona Środowiska**, v. 23, 2021. 39, 40

LEAL, Thomas Leonardo Marques de Castro; FREITAS, Mydiã Falcão; ALENCAR, Nívia Raquel Oliveira; LISBOA, Gerson dos Santos; STRACIERI, Juliana. Análise estatística da geração de resíduos sólidos do estado da bahia, brasil. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 19, n. 1, 2023. 47

LI, Bowen; MU, Yifei. Impact of china's national sword policy on waste import margins: A difference-in-differences approach. **Sustainability**, v. 16, n. 2, p. 776, 2024. 34

LI, Jun; XU, Xibo; LV, Jianshu; WU, Quanyuan; REN, Mengyan; CAO, Jianfei; LIU, Peiyuan. Source apportionment and health risk quantification for heavy metal sources in soils near aluminum-plastic manufacturing facilities in northeast china. **Human and Ecological Risk Assessment: An International Journal**, Taylor & Francis, v. 26, n. 8, p. 2225–2244, 2020. 40

LI, Nan; HAN, Ruru; LU, Xiaohui. Bibliometric analysis of research trends on solid waste reuse and recycling during 1992–2016. **Resources, Conservation and Recycling**, v. 130, p. 109–117, 2018. 33

LI, Ziqi; FOTHERINGHAM, A Stewart; LI, Wenwen; OSHAN, Taylor. Fast geographically weighted regression (fastgwr): a scalable algorithm to investigate spatial process heterogeneity in millions of observations. **International Journal of Geographical Information Science**, Taylor & Francis, v. 33, n. 1, p. 155–175, 2019. 27, 33, 36, 59

LIANG, Longwu; WANG, Zhenbo; LI, Jiaxin. The effect of urbanization on environmental pollution in rapidly developing urban agglomerations. **Journal of cleaner production**, v. 237, p. 117649, 2019. 39, 40

LIN, Yan; HOOVER, Joseph; BEENE, Daniel; ERDEI, Esther; LIU, Zhuoming. Environmental risk mapping of potential abandoned uranium mine contamination on the navajo nation, usa, using a gis-based multi-criteria decision analysis approach. **Environmental Science and Pollution Research**, Springer, v. 27, n. 24, p. 30542–30557, 2020. 40

LIN, Yongqing; YE, Bixiong; WANG, Qin; DONG, Shaoxia. Environmental and socioeconomic factors for gastric cancer in 14 counties of the huai river basin from 2014 to 2018. **International Journal of Environmental Research and Public Health**, MDPI, v. 19, n. 4, p. 2213, 2022. 41

LINO, Fátima AM; ISMAIL, Kamal AR; CASTAÑEDA-AYARZA, Juan A. Municipal solid waste treatment in brazil: A comprehensive review. **Energy Nexus**, v. 11, p. 100232, 2023. 70, 75

LIU, Chen; WU, Xin-wu. Factors influencing municipal solid waste generation in china: A multiple statistical analysis study. **Waste Management & Research**, Sage Publications Sage UK: London, England, v. 29, n. 4, p. 371–378, 2011. 20, 21

LIU, Geng; ZHOU, Xin; LI, Qiang; SHI, Ying; GUO, Guanlin; ZHAO, Long; WANG, Jie; SU, Yingqing; ZHANG, Chao. Spatial distribution prediction of soil as in a large-scale arsenic slag contaminated site based on an integrated model and multi-source environmental data. **Environmental Pollution**, Elsevier, v. 267, p. 115631, 2020. 39

LIU, Jinhui; LI, Qing; GU, Wei; WANG, Chen. The impact of consumption patterns on the generation of municipal solid waste in china: Evidences from provincial data. **International journal of environmental research and public health**, MDPI, v. 16, n. 10, p. 1717, 2019. 27

LIU, Tao; ZHANG, Huan; SHI, Tiezhu. Modeling and predictive mapping of soil organic carbon density in a small-scale area using geographically weighted regression kriging approach. **Sustainability**, v. 12, n. 22, p. 9330, 2020. 28

LIU, Yue *et al.* Identifying the sources and spatial patterns of potentially toxic trace elements (ptes) in shanghai suburb soils using global and local regression models. **Environmental Pollution**, v. 264, p. 114171, 2020. 40, 41

LONDON, L; JOSHI, TK; CAIRNCROSS, E; CLAUDIO, L. Environmental justice: An international perspective. **Encyclopedia of environmental health**, Elsevier Burlington, v. 2, p. 441–48, 2011. 27

LU, Binbin; HARRIS, Paul; CHARLTON, Martin; BRUNSDON, Chris. The gwmodel r package: further topics for exploring spatial heterogeneity using geographically weighted models. **Geo-spatial Information Science**, Taylor & Francis, v. 17, n. 2, p. 85–101, 2014. 54, 59, 76

LU, M.; ZHOU, Chuanbin; WANG, Chenghao; JACKSON, Robert B; KEMPES, Christopher P. Worldwide scaling of waste generation in urban systems. **Nature Cities**, Nature Publishing Group US New York, v. 1, n. 2, p. 126–135, 2024. 72, 75

MAALOUF, Amani; MAVROPOULOS, Antonis. Re-assessing global municipal solid waste generation. **Waste Management & Research**, v. 41, n. 4, p. 936–947, 2023. 73

MADDEN, Ben; FLORIN, Nick; MOHR, Steve; GIURCO, Damien. Using the waste kuznet’s curve to explore regional variation in the decoupling of waste generation and socioeconomic indicators. **Resources, Conservation and Recycling**, Elsevier, v. 149, p. 674–686, 2019. 46, 47, 51

MAHMOOD, Shakeel; IRSHAD, Ahtisham; NASIR, Jan Mohammad; SHARIF, Faiza; FAROOQI, Shahid Hussain. Spatiotemporal analysis of dengue outbreaks in samanabad town, lahore metropolitan area, using geospatial techniques. **Environmental Monitoring and Assessment**, Springer, v. 191, n. 2, p. 55, 2019. 40

MANCINI, Sandro Donnini; MEDEIROS, Gerson Araújo de; PAES, Michel Xocaira; OLIVEIRA, Benone Otávio Souza de; ANTUNES, Maria Lúcia Pereira; SOUZA, Ricardo Gabbay de; FERRAZ, José Lázaro; BORTOLETO, Ana Paula; OLIVEIRA, José Antônio Puppim de. Circular economy and solid waste management: challenges and opportunities in brazil. **Circular Economy and Sustainability**, Springer, v. 1, n. 1, p. 261–282, 2021. 76

MAPA, Ministério da Agricultura e Pecuária. **Finanças verdes**. 2025. Acesso em: 10 jul. 2025. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/politica-agricola/financas-verdes>. 19

MAPUNDA, Abdon Salim; KIMWAGA, Richard Joseph; KASSUWI, Shaaban Ally. Modeling solid waste minimization performance at source in dar es salaam city,

tanzania. **Journal of Geoscience and Environment Protection**, v. 12, n. 9, p. 17–32, 2024. 46, 47, 70

MASSARELLI, Carmine; URICCHIO, Vito Felice. The contribution of open source software in identifying environmental crimes caused by illicit waste management in urban areas. **Urban Science**, v. 8, n. 1, p. 21, 2024. 42

MAZUREK, Damian; CZAPIEWSKI, Konrad. What solutions for waste management? issues of flows and governance exemplified by the Łódź agglomeration (poland). **Energies**, v. 14, n. 12, p. 3366, 2021. 27, 40

MENDEZ, Carlos; SACHDEVA, Akash. Spatial heterogeneity and multiscale geographically weighted regression in brazil. 2025. Disponível em: <https://carlos-mendez.org/publication/20250401-sea/>. 74

MENNIS, Jeremy L; JORDAN, Lisa. The distribution of environmental equity: Exploring spatial nonstationarity in multivariate models of air toxic releases. **Annals of the Association of American Geographers**, Taylor & Francis, v. 95, n. 2, p. 249–268, 2005. 61

MIEZAH, Kodwo; OBIRI-DANSO, Kwasi; KÁDÁR, Zsófia; FEI-BAFFOE, Bernard; MENSAH, Moses Y. Municipal solid waste characterization and quantification as a measure towards effective waste management in ghana. **Waste management**, Elsevier, v. 46, p. 15–27, 2015. 46

MIRZAEI, Mohsen; JAFARI, Ali; GHOLAMALIFARD, Mehdi; AZADI, Hossein; SHOOSHTARI, Sharif Joorabian; MOGHADDAM, Saghi Movahhed; GEBREHIWOT, Kindeya; WITLOX, Frank. Mitigating environmental risks: Modeling the interaction of water quality parameters and land use cover. **Land Use Policy**, Elsevier, v. 95, p. 103766, 2020. 40

MONTEIRO, Antônio Miguel Vieira; CÂMARA, G; CARVALHO, MS; DRUCK, S. Análise espacial de dados geográficos. **Brasília: Embrapa**, 2004. 55

MORAIS, Isa Lucia de; RIZZO, Cristiane Daia; BRANDELERO, Suzi Mari; HANNIBAL, Wellington. Eficácia de placas educativas no descarte de resíduos sólidos urbanos e à não alimentação do sagui-de-trufo-preto (*callithrix penicillata*). **Research, Society and Development**, v. 10, n. 13, p. e300101321463–e300101321463, 2021. 46, 47

MORAN, Patrick AP. Notes on continuous stochastic phenomena. **Biometrika**, JSTOR, v. 37, n. 1/2, p. 17–23, 1950. 55

MTE. **Relação Anual de Informações Sociais: RAIS, ano-base 2022**, Ministério do Trabalho e Emprego. Brasília, DF: [s.n.], 2024. 50

NAQVI, Syed Ali Asad; SAJJAD, Muhammad; WASEEM, Liaqat Ali; KHALID, Shoaib; SHAIKH, Saima; KAZMI, Syed Jamil Hasan. Integrating spatial modelling and space–time pattern mining analytics for vector disease-related health perspectives: a case of dengue fever in pakistan. **International Journal of Environmental Research and Public Health**, MDPI, v. 18, n. 22, p. 12018, 2021. 39

NASA. **POWER: Prediction of Worldwide Energy Resources** [recurso eletrônico]. Hampton, VA: [s.n.], 2025. 50

NDOU, Vhuthu; RAMPEDI, Isaac Tebogo. Bibliometric analysis of municipal solid waste management research: Global and south african trends. **Sustainability**, v. 14, n. 16, p. 10229, 2022. 30

NETO, Alice BP Santos; SIMÕES, Carla L.; SIMOES, Ricardo. Optimization of municipal solid waste collection system: systematic review with bibliometric literature analysis. **Journal of Material Cycles and Waste Management**, v. 26, n. 4, p. 1906–1917, 2024. 30

NETO, Geraldo C de Oliveira; ALEXANDRUK, Marcos; ARAÚJO, Sidnei Alves de; BELAN, Peterson Adriano; DELMONDES, Francisco C; FAIOLI, Rafael Abreu; MATIAS, João; RODRIGUES, Mario; AMORIM, Marlene. Investigating the socio-spatial dynamics of weee collection in são paulo, brazil: A data mining approach. **Recycling**, MDPI, v. 10, n. 2, p. 77, 2025. 65

NGUYEN, K. L. P.; CHUANG, L. Z. H.; CHEN, Q. B. Impacts of socioeconomic changes on municipal solid waste characteristics in taiwan. **Resources, Conservation and Recycling**, v. 161, p. 104931, 2020. 65, 68

NKWUNONWO, Ugonna C; OYEM, Michael N; TOBORE, Anthony O; ASANO, Nelson O; EBINNE, Elijah S. Geospatial analysis and physicochemical assessment of groundwater quality vulnerability to municipal solid waste from landfills. **Air, Soil and Water Research**, SAGE Publications Sage UK: London, England, v. 17, p. 11786221241266039, 2024. 42

NOURANI, Vahid; BAGHANAM, Aida H; SAMADI, Elham; UZELALTINBULAT, Selin. Predicting municipal solid waste generation using artificial intelligence: A hybrid approach of entropy analysis and shap for optimal feature selection. **Waste Management**, Elsevier, v. 205, p. 115012, 2025. 21

NOURQOLIPOUR, Ramin; SHARIFF, Abdul Rashid B Mohamed; AHMAD, Noordin B; BALASUNDRAM, Siva K; SOOD, Alias M; BUYONG, Taher; AMIRI, Fazel. Multi-objective-based modeling for land use change analysis in the south west of selangor, malaysia. **Environmental earth sciences**, Springer, v. 74, n. 5, p. 4133–4143, 2015. 27

NOVAIS, Ana Filipa; TAVARES, António F. Governance models and performance in municipal solid waste management: Evidence from local authorities. **Journal of Environmental Management**, v. 386, p. 125829, 2025. 45

NTAJAL, Joshua; FALKENBERG, Timo; KISTEMANN, Thomas; EVERS, Mariele. Influences of land-use dynamics and surface water systems interactions on water-related infectious diseases—a systematic review. **Water**, MDPI, v. 12, n. 3, p. 631, 2020. 39

Observatório de Metrôpoles. Região metropolitana de goiânia: Dinâmicas territoriais e desafios urbanos. 2023. 63, 75

O'DEA, Rose E; LAGISZ, Malgorzata; JENNIONS, Michael D; KORICHEVA, Julia; NOBLE, Daniel WA; PARKER, Timothy H; GUREVITCH, Jessica; PAGE, Matthew J; STEWART, Gavin; MOHER, David *et al.* Preferred reporting items for systematic reviews and meta-analyses in ecology and evolutionary biology: a prisma extension. **Biological Reviews**, Wiley Online Library, v. 96, n. 5, p. 1695–1722, 2021. 30

OECD. **Global plastics outlook: Economic drivers, environmental impacts and policy options**. Paris: OECD Publishing, 2022. 27

OLIVEIRA, Adjane Damasceno de; RIBEIRO, Renata Santos; SOARES, Rémilton de Carvalho Aragão; MURY, Vinícius Freitas; SÁ, Kaoara Batista de. Iii-056-gestão dos resíduos sólidos urbanos em goiás: Como a regionalização pode contribuir para esse processo? 2024. 46, 47, 48, 76

OLIVO, Valdir Eduardo; PRIETTO, Pedro Domingos Marques; KORF, Eduardo Pavan. Actions and policy tools for local governments to achieve integrated sustainable waste management. **Revista Brasileira de Ciências Ambientais**, v. 56, n. 3, p. 436–444, 2021. 42

OSHAN, Taylor M; LI, Ziqi; KANG, Wei; WOLF, Levi J; FOTHERINGHAM, A Stewart. mgwr: A python implementation of multiscale geographically weighted regression for investigating process spatial heterogeneity and scale. **ISPRS International Journal of Geo-Information**, MDPI, v. 8, n. 6, p. 269, 2019. 53, 54

PANDEY, Prem Chandra; KOUTSIAS, Nikos; PETROPOULOS, George P; SRIVASTAVA, Prashant K; DOR, Eyal Ben. Land use/land cover in view of earth observation: Data sources, input dimensions, and classifiers—a review of the state of the art. **Geocarto International**, Taylor & Francis, v. 36, n. 9, p. 957–988, 2021. 40

PAPALE, Lorenzo Giuliano; GUERRISI, Giorgia; SANTIS, Davide De; SCHIAVON, Giovanni; FRATE, Fabio Del. Satellite data potentialities in solid waste landfill monitoring: Review and case studies. **Sensors**, MDPI, v. 23, n. 8, p. 3917, 2023. 42

PAULAUSKAITE-TARASEVICIENE, Agne; RAUDONIS, Vidas; SUTIENE, Kristina. Forecasting municipal solid waste in lithuania by incorporating socioeconomic and geographical factors. **Waste Management**, Elsevier, v. 140, p. 31–39, 2022. 51

PERKINS, Richard. Environmental leapfrogging in developing countries: A critical assessment and reconstruction. *In*: WILEY ONLINE LIBRARY. **Natural resources forum**. [S.l.], 2003. v. 27, n. 3, p. 177–188. 72

PNRS, Política Nacional de Resíduos Sólidos. **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**. 2010. Diário Oficial da União, seção 1, p. 3, 3 ago. 2010. Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2007-2010/2010/lei/112305.htm. Acesso em: 14 jul. 2025. 44, 45

POLYCEO. **Interpreting result of Geographically Weighted Regression (GWR)?** 2016. <https://gis.stackexchange.com/questions/181820/interpreting-result-of-geographically-weighted-regression-gwr>. Acesso em: 05 set. 2025. 61

PÁRAMO-TELLE, Óscar; VENCE, Xavier. Socioeconomic factors explaining municipal solid waste generation in galicia. similarities and differences between aggregate magnitudes and fractions. **Waste Management**, v. 201, p. 114794, 2025. 47, 64

RAZALI, Nornadiah Mohd; WAH, Yap Bee *et al.* Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors and anderson-darling tests. **Journal of statistical modeling and analytics**, v. 2, n. 1, p. 21–33, 2011. 55

REHANA, Shaik; RAJULAPATI, Chandra Rupa; GHOSH, Subimal; KARMAKAR, Subhankar; MUJUMDAR, Pradeep. Uncertainty quantification in water resource

- systems modeling: Case studies from india. **Water**, MDPI, v. 12, n. 6, p. 1793, 2020. 29
- REIS, W. F.; BARRETO, C. G.; CAPELARI, M. G. M. Circular economy and solid waste management: Connections from a bibliometric analysis. **Sustainability**, v. 15, p. 15715, 2023. 30
- ROSECKY, M.; SOMPLAK, R.; SLAVÍK, J.; KALINA, J.; BULKOVA, G.; BEDNAR, J. Predictive modelling as a tool for effective municipal waste management policy at different territorial levels. **Journal of Environmental Management**, v. 291, p. 112584, 2021. 46
- ROSENSHEIN, L.; SCOTT, L.; PRATT, M. Finding a meaningful model. **ArcUser**, 2011. Winter. 30
- RYBOVA, K. Do sociodemographic characteristics in waste management matter? case study of recyclable generation in the czech republic. **Sustainability**, v. 11, n. 7, p. 2030, 2019. 28, 46, 47
- RYBOVA, K.; BURCIN, B.; SLAVIK, J. Spatial and non-spatial analysis of socio-demographic aspects influencing municipal solid waste generation in the czech republic. **Detritus**, v. 1, n. 1, p. 3–7, 2018. 28
- SAHANI, N.; GHOSH, T. Gis-based spatial prediction of recreational trail susceptibility in protected area of sikkim himalaya using logistic regression, decision tree and random forest model. **Ecological Informatics**, v. 64, p. 101352, 2021. 40
- SALMERÓN, R.; GARCÍA, C. B.; GARCÍA, J. Variance inflation factor and condition number in multiple linear regression. **Journal of statistical computation and simulation**, v. 88, n. 12, p. 2365–2384, 2018. 53, 58
- SARTIKA, E.; SURYANI, A. Comparison of geographically weighted regression analysis and global regression on modeling the unemployment rate in west java. *In: ATLANTIS PRESS. International Seminar of Science and Applied Technology (ISSAT 2020)*. [S.l.], 2020. p. 472–478. 47, 48
- SARWAR, N.; JUNAID, A.; ALVI, S. Impact of urbanization and human development on ecological footprints in oecd and non-oecd countries. **Heliyon**, v. 10, n. 19, 2024. 18, 19
- SHAO, Q.; ZHOU, Y.; ZHU, P.; MA, Y.; SHAO, M. Key factors assessment on bird strike density distribution in airport habitats: Spatial heterogeneity and

geographically weighted regression model. **Sustainability**, v. 12, n. 18, p. 7235, 2020. 29

SHAPIRO, Samuel Sanford; WILK, Martin B. An analysis of variance test for normality (complete samples). **Biometrika**, Oxford University Press, v. 52, n. 3-4, p. 591–611, 1965. 55

SHI, W.; YANG, W.; DU, D. The scientific cooperation network of chinese scientists and its proximity mechanism. **Sustainability**, v. 12, n. 2, p. 660, 2020. 35

SINGH, Tinka; NAIK, Abhipsa; UPPALURI, Ramagopal VS. Characterization of municipal solid waste generation and seasonal classification for various socio-demographic groups in guwahati city. **Journal of Material Cycles and Waste Management**, Springer, v. 26, n. 2, p. 1210–1230, 2024. 20, 21

SRIVASTAVA, Atul; JHA, Pawan Kumar. A multi-model forecasting approach for solid waste generation by integrating demographic and socioeconomic factors: a case study of prayagraj, india. **Environmental monitoring and assessment**, Springer, v. 195, n. 6, p. 768, 2023. 21

STERN, D. I. The environmental kuznets curve. *In: Companion to Environmental Studies*. [S.l.]: Routledge, 2018. p. 49–54. 72

SUDECO. **RIDE-DF – Região Integrada de Desenvolvimento do Distrito Federal e Entorno**. 2022. <https://www.gov.br/sudeco/pt-br/assuntos/ride-df/ride-df>. Acesso em: 24 jul. 2025. 62, 66, 75

SUN, X.; DONG, Y.; SHAFIQ, M. N.; SANTOS, P. Gago-de; GILLANI, S. Economic policy uncertainty and environmental quality: unveiling the moderating effect of green finance on sustainable environmental outcomes. **Humanities and Social Sciences Communications**, v. 12, n. 1, p. 1–12, 2025. 19, 20

SURYOWATI, K.; BEKTI, R. D.; FAJIRIYAH, R.; SISWOYO, E. The effect of regional characteristics and relationship among locations in air pollution using spatial autoregressive (sar) and spatial durbin models (sdm). *In: IOP PUBLISHING. Journal of Physics: Conference Series*. [S.l.], 2021. p. 012051. 28

TERRA, M. M. **Gestão de resíduos sólidos urbanos: tecnologias e estratégias para o encerramento de lixões e recuperação de áreas contaminadas**. Dissertação (Dissertação (Mestrado)) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2024. 47

UNIDAS, ONU Organização das Nações. **World Urbanization Prospects 2019**. New York: [s.n.], 2019. 44

VELEZ, R.; CALDERON, D.; CAREY, L.; AIME, C.; HULTQUIST, C.; YETMAN, G.; KRUCZKIEWICZ, A.; GOROKHOVICH, Y.; CHEN, R. S. Advancing data for street-level flood vulnerability: Evaluation of variables extracted from google street view in quito, ecuador. **IEEE Open Journal of the Computer Society**, v. 3, p. 51–61, 2022. 29

VELIS, Costas A; WILSON, David C; GAVISH, Yoni; GRIMES, Sue M; WHITE-MAN, Andrew. Socio-economic development drives solid waste management performance in cities: A global analysis using machine learning. **Science of the Total Environment**, Elsevier, v. 872, p. 161913, 2023. 20, 21, 51, 63, 69, 74

VOUKKALI, I.; PAPAMICHAEL, I.; LOIZIA, P.; ZORPAS, A. A. Urbanization and solid waste production: Prospects and challenges. **Environmental Science and Pollution Research**, v. 31, n. 12, p. 17678–17689, 2024. 27

WANG, K.; ZHU, Y.; ZHANG, J. Decoupling economic development from municipal solid waste generation in china's cities: Assessment and prediction based on tapio method and ekc models. **Waste Management**, v. 133, p. 37–48, 2021. 39

WANG, Z.; ZHANG, Z.; LIU, J. Exploring spatial heterogeneity and factors influencing construction and demolition waste in china. **Environmental Science and Pollution Research**, v. 29, n. 35, p. 53269–53292, 2022. 28, 39, 40

WASSERSTEIN, R. L.; SCHIRM, A. L.; LAZAR, N. A. Moving to a world beyond "p< 0.05". **The American Statistician**, v. 73, n. sup1, p. 1–19, 2019. 57

WEN, H.; LI, S.; HUI, E. C. M.; XIAO, Y.; LIU, H. Externality impacts of "not in my backyard" facilities on property values: Evidence from the hangzhou waste sorting and reduction complex projects. **Habitat International**, v. 125, p. 102583, 2022. 41

WWF-BRASIL. **Relatório Planeta Vivo 2012: a caminho da Rio+20**. Brasília: WWF-Brasil, 2012. Acesso em: 10 jul. 2025. Disponível em: https://www.wwf.org.br/informacoes/noticias_meio_ambiente_e_natureza/?30380. 19

XAVIER, B. **Área Metropolitana de Brasília já abriga mais de 4,2 milhões de habitantes**. mar. 2025. Acesso em: 24 jul. 2025. Disponível em: <https://www.correiobraziliense.com.br/cidades-df/2025/03/7090383-area-metropolitana-de-brasilia-ja-abriga-mais-de-42-milhoes-de-habitantes.html>. 66

XIAO, Shijiang; DONG, Huijuan; GENG, Yong; TIAN, Xu; LIU, Chang; LI, Haifeng. Policy impacts on municipal solid waste management in shanghai: A system dynamics model analysis. **Journal of Cleaner Production**, Elsevier, v. 262, p. 121366, 2020. 41

XIAOMING, L.; ZHI, W.; AKHUNDZADA, A. Enhancing performance prediction of municipal solid waste generation: a strategic management. **Frontiers in Environmental Science**, v. 13, 2025. 70

XU, Ming; DAIGGER, Glen T; XI, Chuanwu; LIU, Jianguo; QU, Jiuhui; ALVAREZ, Pedro J; BISWAS, Pratim; CHEN, Yongsheng; DOLINOY, Dana; FAN, Ying *et al.* Us–china collaboration is vital to global plans for a healthy environment and sustainable development. **Environmental science & technology**, ACS Publications, v. 55, n. 14, p. 9622–9626, 2021. 34

YALÇINTAŞ, Deniz; OĞUZ, Suzan; ÖZELTÜRKAY, Eda Yaşa; GÜLMEZ, Murat. Bibliometric analysis of studies on sustainable waste management. **Sustainability**, MDPI, v. 15, n. 2, p. 1414, 2023. 29

YANG, Lie; CHEN, Zhulei; LIU, Ting; GONG, Zhe; YU, Yingjian; WANG, Jia. Global trends of solid waste research from 1997 to 2011 by using bibliometric analysis. **Scientometrics**, Springer, v. 96, n. 1, p. 133–146, 2013. 30

YANG, Shuhan; LONG, Ruyin; WU, Meifen; CHEN, Hong; LI, Qianwen. Research progress and frontier of global solid waste management based on bibliometrics. **Environmental Development**, Elsevier, v. 48, p. 100922, 2023. 35

YANG, Xue; YANG, Yong; WAN, Yongyong; WU, Ruojing; FENG, Dekun; LI, Ke. Source identification and comprehensive apportionment of the accumulation of soil heavy metals by integrating pollution landscapes, pathways, and receptors. **Science of the Total Environment**, Elsevier, v. 786, p. 147436, 2021. 39

YANG, X.; YANG, Y.; XU, S.; HAN, J.; CHAI, Z.; YANG, G. A new algorithm for large-scale geographically weighted regression with k-nearest neighbors. **ISPRS International Journal of Geo-Information**, v. 12, n. 7, p. 295, 2023. 41

YAO, Peifan; LI, Bin; ZHANG, Sen; SONG, Lijie; TAI, Jun; ZHAO, Jun; CAO, Wei; ZHANG, Xing; QIAN, Guangren. Quantifying the effect of socio-economic-geo drivers on the change of municipal waste disposal in china by an integrated twfe-prf-sdm methodology. **Journal of environmental management**, Elsevier, v. 343, p. 118213, 2023. 51

YIN, Ziyu; DING, Jiale; LIU, Yi; WANG, Ruoxu; WANG, Yige; CHEN, Yijun; QI, Jin; WU, Sensen; DU, Zhenhong. Gnnwr: an open-source package of spatiotemporal intelligent regression methods for modeling spatial and temporal non-stationarity. **Geoscientific Model Development Discussions**, Göttingen, Germany, v. 2024, p. 1–22, 2024. 47

YU, Hanchen. Generalized geographically and temporally weighted regression. **Computers, Environment and Urban Systems**, v. 117, p. 102244, 2025. 52, 53, 54

YU, Yan; HUANG, Yuan Jun; HE, Jian Hua; ZHAO, Jing Hui. Influencing factors determination of msw clearance volume based on spatial dependency consideration. **Advanced Materials Research**, Trans Tech Publ, v. 878, p. 513–519, 2014. 29

ZHANG, Guoqin; LIN, Tao; CHEN, Shaohua; XIAO, Lishan; WANG, Jin; GUO, Yifang. Spatial characteristics of municipal solid waste generation and its influential spatial factors on a city scale: a case study of xiamen, china. **Journal of Material Cycles and Waste Management**, Springer, v. 17, n. 2, p. 399–409, 2015. 35

ZHANG, Kaili; LIU, Tan; FENG, Rongrong; ZHANG, Zhicheng; LIU, Kang. Coupling coordination relationship and driving mechanism between urbanization and ecosystem service value in large regions: A case study of urban agglomeration in yellow river basin, china. **International Journal of Environmental Research and Public Health**, MDPI, v. 18, n. 15, p. 7836, 2021. 39, 40

ZHANG, Ping; WANG, Yong; MA, Wenjie; LI, Mingyao; ZHAO, Yonghua; WANG, Wentao; JIA, Yefan; FAN, Jinghao; KONG, Lufang; HOU, Kang *et al.* Identifying the determinants of natural, anthropogenic factors and precursors on pm1 pollution in urban agglomerations in china: Insights from optimal parameter-based geographic detector and robust geographic weighted regression models. **Environmental Research**, Elsevier, p. 121817, 2025. 47

ZHANG, Y.; WANG, S.; GAO, Z.; ZHANG, H.; ZHU, Z.; JIANG, B.; DONG, H. Contamination characteristics, source analysis and health risk assessment of heavy metals in the soil in shi river basin in china based on high density sampling. **Ecotoxicology and Environmental Safety**, v. 227, p. 112926, 2021. 29

ZHANG, Zhechen; CHEN, Zhonghao; ZHANG, Jiawen; LIU, Yunfei; CHEN, Lin; YANG, Mingyu; OSMAN, Ahmed I; FARGHALI, Mohamed; LIU, Engui; HASSAN, Dalia *et al.* Municipal solid waste management challenges in developing regions: A comprehensive review and future perspectives for asia and africa. **Science of the Total Environment**, Elsevier, v. 930, p. 172794, 2024. 18, 19, 20

ZHAO, Litao. China's 13th five-year plan: Road map for social development. **East Asian Policy**, v. 8, n. 03, p. 19–32, 2016. 34

ZHAO, Qianqian; FAN, Qiao; ZHOU, Pengfei. An integrated analysis of gwr models and spatial econometric global models to decompose the driving forces of the township consumption development in gansu, china. **Sustainability**, v. 14, n. 1, p. 281, 2021. 28, 39

ZHAO, Tianrui; GAO, Yedong; ZHAN, Wei; SUN, Huihang; ZHANG, Tianqi; LI, Lipin; ZUO, Wei; TANG, Xiaomi; LI, Yanliang; TIAN, Yu. Municipal solid waste (msw) under the population shrinking and aging: Spatio-temporal patterns, driving forces, and the impact of smart city development. **Journal of Cleaner Production**, Elsevier, v. 434, p. 140124, 2024. 69

ZHAO, Yidan; LI, Hong. Understanding municipal solid waste production and diversion factors utilizing deep-learning methods. **Utilities Policy**, Elsevier, v. 83, p. 101612, 2023. 21

ZHOU, Xiaomin. Moderating effect of structural holes on absorptive capacity and knowledge-innovation performance: empirical evidence from chinese firms. **Sustainability**, v. 14, n. 10, p. 5821, 2022. 36

Apêndice A – Script em R - Pacote Bibliometrix

Material Suplementar para o artigo.

Descrição do script em R utilizado para realizar a revisão de literatura, com perspectiva bibliométrica.

Código A.1 – *Script em R - Pacote Bibliometrix*

```
1
2 install.packages("devtools")
3
4 devtools::install_github("massimoaria/pubmedR")
5
6 install.packages("pubmedR")
7
8 install.packages("rio")
9
10 devtools::install_github("massimoaria/bibliometrix")
11
12 install.packages("bibliometrix", dependencies = TRUE)
13
14 install.packages("jsonlite", type = "source")
15
16 library(pubmedR)
17
18 library(bibliometrix)
19
20 A<-convert2df("C:/JoaquimWos.bib", dbsource = 'isi', format = "bibtex")
21
22 B<-convert2df("C:/Joaquim/Sco.bib", dbsource = 'scopus', format = "bibtex")
23
24 M<-mergeDbSources(A,B, remove.duplicated = TRUE)
25
26 rio::export(M,file = "C:/JAQUELINE/M.xlsx")
27
28 biblioshiny()
```

Apêndice B – Mapa do Estado de Goiás e a localização de seus municípios

Apêndice B – Mapa do Estado de Goiás e a localização de seus municípios



Fonte: Arquivos vetoriais IBGE (2022).