

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL– PPGE

FABIANA WEIMANN ARAUJO

**ANÁLISE DAS RELAÇÕES ESPACIAIS E TEMPORAIS ENTRE O CONSUMO DE
ÁGUA EM SANTA CATARINA E VARIÁVEIS CLIMÁTICAS, ECONÔMICAS E
SOCIODEMOGRÁFICAS**

JOINVILLE

2025

FABIANA WEIMANN ARAUJO

**ANÁLISE DAS RELAÇÕES ESPACIAIS E TEMPORAIS ENTRE O CONSUMO DE
ÁGUA EM SANTA CATARINA E VARIÁVEIS CLIMÁTICAS, ECONÔMICAS E
SOCIODEMOGRÁFICAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do grau de Mestre em Engenharia Civil.

Orientador: Prof. Dr. Andreza Kalbusch
Coorientador: Prof. Dr. Elisa Henning

JOINVILLE

2025

**Ficha catalográfica elaborada pelo programa de geração automática da
Biblioteca Universitária Udesc,
com os dados fornecidos pelo(a) autor(a)**

Araujo, Fabiana Weimann

Análise das relações espaciais e temporais entre o consumo de água em Santa Catarina e variáveis climáticas, econômicas e sociodemográficas / Fabiana Weimann Araujo. -- 2025.

143 p.

Orientador: Andreza Kalbusch

Coorientador: Elisa Henning

Dissertação (mestrado) -- Universidade do Estado de Santa Catarina, Centro de Ciências Tecnológicas, Programa de Pós-Graduação em Engenharia Civil, Joinville, 2025.

1. Consumo per capita de água. 2. Dados em painel. 3. Modelo espacial. I. Kalbusch, Andreza. II. Henning, Elisa. III. Universidade do Estado de Santa Catarina, Centro de Ciências Tecnológicas, Programa de Pós-Graduação em Engenharia Civil. IV. Título.

FABIANA WEIMANN ARAUJO

**ANÁLISE DAS RELAÇÕES ESPACIAIS E TEMPORAIS ENTRE O CONSUMO DE
ÁGUA EM SANTA CATARINA E VARIÁVEIS CLIMÁTICAS, ECONÔMICAS E
SOCIODEMOGRÁFICAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro de Ciências Tecnológicas da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do grau de Mestre em Engenharia Civil.

Orientador: Profa. Dra. Andreza Kalbusch
Coorientador: Profa. Dra. Elisa Henning

BANCA EXAMINADORA

Andreza Kalbusch

Universidade do Estado de Santa Catarina - UDESC

Membros:

Dr. Francisco Henrique de Oliveira

Universidade do Estado de Santa Catarina - UDESC

Dra. Priscila Ferraz Franczak

Universidade da Região de Joinville - UNIVILLE

Joinville, 15 de julho de 2025.

AGRADECIMENTOS

Agradeço à minha orientadora e coorientadora por aceitarem conduzir o meu trabalho de pesquisa, pela orientação e por todas as contribuições. A todos os meus professores do curso da Universidade do Estado de Santa Catarina pela excelência da qualidade técnica de cada um.

Agradeço, especialmente, à minha família, pelo apoio incondicional, incentivo e compreensão em todos os momentos.

RESUMO

Este estudo tem como objetivo principal analisar as relações entre variáveis climáticas, sociodemográficas, expansão urbana e fatores econômicos, e suas influências no consumo de água *per capita* urbano nos municípios de Santa Catarina entre 2012 e 2021. Os dados utilizados incluem temperatura média anual, precipitação diária anual, PIB municipal, valor adicionado por setor econômico, e a classificação do uso do solo. A análise é conduzida por meio de modelos de regressão com dados em painel com dimensões temporal e espacial, que permitem avaliar a variação do consumo de água entre os municípios e ao longo do tempo. Este trabalho possui relevância, pois oferece informações para a gestão sustentável dos recursos hídricos em Santa Catarina. Em um contexto global de crescente demanda por água devido ao crescimento populacional, mudanças climáticas e urbanização, a compreensão detalhada dos fatores que influenciam o consumo de água é necessária para a formulação de políticas públicas eficazes e para a preservação deste recurso essencial. Os dados de PIB e de consumo de água *per capita* foram completados por meio de técnicas de imputação. Foram inicialmente desenvolvidos modelos não espaciais, incluindo Mínimos Quadrados Ordinários (OLS), efeitos fixos de tempo, efeitos fixos individuais e efeitos fixos de duas vias. Com base nos resultados obtidos, optou-se pelo modelo de efeitos fixos de tempo em conjunto com o modelo espacial *Spatial Durbin Model* (SDM). Os resultados do modelo apresentaram R^2 e R^2 ajustado de 0,27. A variável consumo de água *per capita* apresentou influência espacial positiva e significativa, ou seja, o aumento de consumo de água per capita em um município tende a influenciar o aumento nos municípios vizinhos. As variáveis temperatura média, valor adicionado pela indústria, valor adicionado pelo comércio e valor adicionado por serviços, proporção de área urbana e proporção de área não vegetada apresentaram efeitos diretos significativos no modelo.

Palavras-chave: Consumo per capita de água; Dados em painel; Modelo espacial.

ABSTRACT

This study aims to analyze the relationship between climatic, sociodemographic, urban expansion and economic variables, and their influence on urban per capita water consumption in the municipalities of Santa Catarina between 2012 and 2021. The data used include average annual temperature, daily annual precipitation, municipal GDP, value added by economic sector, and land use classification. The analysis is conducted using panel data regression models with temporal and spatial dimensions which allow for the evaluation of water consumption variation between municipalities and over time. This study is relevant as it provides information for the sustainable management of water resources in Santa Catarina. In a global context of increasing water demand driven by population growth, climate change, and urbanization, a detailed understanding of the factors influencing water consumption is essential for the development of effective public policies and for the preservation of this resource. The variables GDP and per capita water consumption were completed through imputation techniques. Initially, non-spatial models were developed, including Ordinary Least Squares (OLS), time fixed effects, individual fixed effects, and two-way fixed effects models. Based on the results obtained, the time fixed effects model was chosen, along with the spatial model Spatial Durbin Model (SDM). The model results showed R^2 and adjusted R^2 values of 0.27. The per capita water consumption variable showed a positive and significant spatial influence, meaning that an increase in per capita water consumption in one municipality tends to influence an increase in neighboring municipalities. The variables average temperature, value added by industry, commerce, and services, proportion of urban area, and proportion of non-vegetated area showed significant direct effects in the model.

Keywords: Per capita water consumption; Panel data; Spatial model

LISTA DE FIGURAS

Figura 1 - Diagrama da revisão sistemática	20
Figura 2 - Distribuição geográfica das áreas de estudo dos artigos selecionados	22
Figura 3 - Produção científica anual da base Scopus e WOS (2010-2024)	23
Figura 4 - Nuvem de palavras de palavras gerada a partir das palavras-chaves dos artigos analisados	24
Figura 5 - Transição do uso do solo (a) de 2000 a 2010 e (b) de 2010 a 2020	32
Figura 6 - Estrutura hierárquica do consumo de água e dos indicadores socioeconômicos relacionados	42
Figura 7 - Localização da área de estudo	45
Figura 8 - Zonas climáticas de Santa Catarina.....	46
Figura 9 - Diagrama de coleta de dados	47
Figura 10 - Diagrama de procedimentos para classificação do uso do solo	50
Figura 11 - Diagrama de coleta de dados climáticos.....	53
Figura 12 - Contiguidade em uma rede regular	55
Figura 13 - Ordem de contiguidade.....	56
Figura 14 - Valores ausentes de consumo de água por município por ano	64
Figura 15 - Porcentagem de dados ausentes de consumo de água <i>per capita</i> para os municípios de Santa Catarina (2006-2022)	65
Figura 16 - Porcentagem de dados ausentes de consumo de água <i>per capita</i> para os municípios de Santa Catarina (2012-2022)	65
Figura 17 - Histograma do consumo de água <i>per capita</i>	67
Figura 18 - Histograma do consumo de água <i>per capita</i> após tratamento de <i>outliers</i>	69
Figura 19 - Valores observados e imputados de consumo de água <i>per capita</i>	71
Figura 20 - Valores observados e imputados de PIB <i>per capita</i>	72
Figura 21 - Valores imputados x valores observados de consumo de água <i>per capita</i>	73
Figura 22 – Gráfico boxplot do consumo de água <i>per capita</i> (litros/hab.dia) para os municípios de Santa Catarina (2012-2021)	75
Figura 23 - Mapa de quebras naturais do consumo de água <i>per capita</i> médio (litros/hab./dia) dos municípios de Santa Catarina	76

Figura 24 - Mapa boxplot do consumo de água <i>per capita</i> médio (litros/hab./dia) dos municípios de Santa Catarina	77
Figura 25 – Gráfico boxplot da temperatura média (°C) dos municípios de Santa Catarina por ano	79
Figura 26 - Distribuição da temperatura média em Santa Catarina	80
Figura 27 - Precipitação média diária municipal anual	81
Figura 28 - Distribuição da precipitação média diária em Santa Catarina	82
Figura 29 – Gráfico boxplot do valor adicionado industrial <i>per capita</i> (R\$/hab.) municipal anual	84
Figura 30 - Distribuição do valor adicionado industrial <i>per capita</i> em Santa Catarina	85
Figura 31 – Gráfico boxplot do valor adicionado de serviço <i>per capita</i> municipal anual	86
Figura 32 - Distribuição do valor adicionado de serviço <i>per capita</i> em Santa Catarina	87
Figura 33 – Gráfico boxplot do valor adicionado de comércio <i>per capita</i> (R\$/hab.) municipal anual	88
Figura 34 - Distribuição do valor adicionado de comércio em Santa Catarina	89
Figura 35 – Gráfico boxplot do PIB <i>per capita</i> (R\$/hab.) municipal anual	90
Figura 36 - Distribuição do PIB <i>per capita</i> anual médio em Santa Catarina	91
Figura 37 – Gráfico boxplot da População (hab.) municipal anual	92
Figura 38 - Distribuição da população em Santa Catarina	93
Figura 39 - Uso do solo em Santa Catarina (2012)	94
Figura 40 - Uso do solo em Santa Catarina (2021)	94
Figura 41 - Transição do uso do solo (2012 - 2021)	95
Figura 42 – Gráfico boxplot da área de floresta (km ²) municipal anual	97
Figura 43 - Distribuição da área de floresta em Santa Catarina	98
Figura 44 – Gráfico boxplot da área de formação natural não florestal (km ²) municipal anual	99
Figura 45 - Distribuição área de formação natural não florestal em Santa Catarina	100
Figura 46 – Gráfico boxplot da área agropecuária (km ²) municipal anual	101
Figura 47 - Distribuição da área de agropecuária em Santa Catarina	102
Figura 48 – Gráfico boxplot da área urbana (km ²) municipal anual	103

Figura 49 –Distribuição da área urbana em Santa Catarina	104
Figura 50 – Gráfico da área de corpo d'água (km ²) municipal anual	105
Figura 51 - Distribuição da área de corpo d'água em Santa Catarina.....	105
Figura 52 – Gráfico da área não vegetada (km ²) municipal anual.....	107
Figura 53 - Distribuição da área não vegetada em Santa Catarina.....	108
Figura 54 - Matriz de correlação das variáveis.....	109
Figura 55 - Gráfico real x estimado	118
Figura 56 - Efeito fixo de tempo	119
Figura 57 - Gráfico QQ dos resíduos	120
Figura 58 - Histograma dos resíduos do modelo SDM com efeito fixo de tempo....	121

LISTA DE TABELAS

Tabela 1 - Artigos com aprendizado em máquina e técnicas de otimização	26
Tabela 2 - Artigos com regressão, regressão espacial, modelos em painel e misto e séries temporais e previsão	27
Tabela 3 - Variáveis físicas	30
Tabela 4 - Variáveis climáticas	34
Tabela 5 - Variáveis sociodemográficas.....	37
Tabela 6 - Variáveis econômicas	40
Tabela 7 - Variáveis utilizadas no estudo	44
Tabela 8 - Classes da classificação do uso do solo	50
Tabela 9 - Sumário estatístico do consumo de água <i>per capita</i> (litros/hab./dia)	66
Tabela 10 - Percentis para a variável consumo de água <i>per capita</i>	67
Tabela 11 - Sumário estatístico do consumo de água <i>per capita</i> (litros/hab./dia) após tratamento de <i>outliers</i>	68
Tabela 12 - Sumário estatístico PIB <i>per capita</i>	69
Tabela 13 - Sumário estatístico consumo de água <i>per capita</i> (litros/hab./dia) por imputação	73
Tabela 14 - Índice de Moran para o consumo de água <i>per capita</i> (2012-2021)	77
Tabela 15 - Sumário estatístico da temperatura média anual	78
Tabela 16 - Sumário estatístico de precipitação média diária anual municipal	80
Tabela 17 - Sumário estatístico do valor adicionado industrial <i>per capita</i>	82
Tabela 18 - Sumário estatístico do valor adicionado de serviço <i>per capita</i>	85
Tabela 19 - Sumário estatístico do valor adicionado de comércio <i>per capita</i>	87
Tabela 20 - Sumário estatístico do PIB <i>per capita</i>	89
Tabela 21 - Sumário estatístico população municipal anual	91
Tabela 22 – Sumário estatístico de área de floresta municipal anual	96
Tabela 23 - Sumário estatístico área de formação natural não florestal municipal anual	98
Tabela 24 - Sumário estatístico área de agropecuária municipal.....	100
Tabela 25 - Sumário estatístico da área urbana municipal	102
Tabela 26 - Sumário estatístico área de corpo d'água.....	104
Tabela 27 - Sumário estatístico área não vegetada	106
Tabela 28 – Verificação de multicolinearidade	109

Tabela 29 - Modelos em painel sem efeitos espaciais	110
Tabela 30 - Coeficientes do SDM com efeitos fixos de tempo	113
Tabela 31 - Efeitos direto, indireto e total do modelo SDM com efeito fixo de tempo	114

SUMÁRIO

1	INTRODUÇÃO	15
1.1	JUSTIFICATIVA	16
1.2	OBJETIVOS	16
1.2.1	Objetivo geral.....	16
1.2.2	Objetivos específicos.....	17
1.3	LIMITAÇÕES DE PESQUISA.....	17
2	REVISÃO BIBLIOGRÁFICA	18
2.1	INTRODUÇÃO	18
2.2	MATERIAIS E MÉTODOS.....	19
2.3	RESULTADOS E DISCUSSÃO	20
2.3.1	Escala temporal e espacial.....	24
2.3.2	Algoritmos e modelos aplicados nos estudos	25
2.3.3	Fatores físicos	30
2.3.4	Fatores climáticos	34
2.3.5	Fatores sociodemográficos.....	36
2.3.6	Fatores econômicos.....	39
2.4	CONSIDERAÇÕES FINAIS DA REVISÃO SISTEMÁTICA	43
3	MÉTODO.....	44
3.1	ÁREA DE ESTUDO	45
3.1.1	Caracterização climática.....	46
3.2	COLETA E PROCESSAMENTO DE DADOS	46
3.2.1	Dados de consumo de água	47
3.2.2	Dados econômicos.....	48
3.2.3	Dados de classificação do uso do solo.....	49
3.2.4	Dados climáticos	52
3.3	ANÁLISE ESTATÍSTICA	53
3.3.1	Análise descritiva	53
3.3.2	Regressão em painel.....	56
3.3.3	Modelos espaciais para dados em painel	59
3.3.4	Tratamento de outliers e imputação de dados	62
4	RESULTADOS E DISCUSSÕES	64
4.1	TRATAMENTO DE <i>OUTLIERS</i> E <i>IMPUTAÇÃO DE DADOS</i>	64

4.2	DADOS DE CONSUMO DE ÁGUA <i>PER CAPITA</i>	74
4.3	DADOS CLIMÁTICOS.....	78
4.3.1	Temperatura média	78
4.3.2	Precipitação média diária	80
4.4	DADOS ECONÔMICOS.....	82
4.4.1	Valor adicionado industrial <i>per capita</i>.....	82
4.4.2	Valor adicionado de serviço <i>per capita</i>	85
4.4.3	Valor adicionado de comércio <i>per capita</i>.....	87
4.4.4	PIB <i>per capita</i>.....	89
4.5	POPULAÇÃO	91
4.6	DADOS CLASSIFICAÇÃO DE USO DO SOLO	93
4.6.1	Área de floresta	96
4.6.2	Área de formação natural não florestal	98
4.6.3	Área de agropecuária.....	100
4.6.4	Área urbana	102
4.6.5	Área de corpo d'água.....	104
4.6.6	Área não vegetada.....	106
4.7	REGRESSÃO EM PAINEL.....	108
5	CONSIDERAÇÕES FINAIS	123
5.1	SUGESTÕES PARA TRABALHOS FUTUROS.....	124
	REFERÊNCIAS.....	125

1 INTRODUÇÃO

A escassez global de água é uma realidade que transcende fronteiras, afetando mesmo regiões consideradas com abundância deste recurso, e a rápida urbanização, característica marcante do cenário contemporâneo, intensifica a demanda por água, aproximando-a do limite dos recursos hídricos disponíveis na região ou da capacidade hídrica regional (Sohn, 2011). A água desempenha um papel insubstituível no desenvolvimento social e econômico sustentável como um recurso natural primário e um recurso econômico estratégico que sustenta a produção humana e a vida (Sun, 2023). Portanto, a identificação dos fatores críticos que delinham a demanda por água é essencial para a formulação de políticas específicas que possam mitigar o impacto da crescente demanda (Sohn, 2011).

Compreender os padrões de uso da água é fundamental em uma era de crescentes preocupações sobre a disponibilidade deste recurso em quantidade e qualidade adequadas (March; Saurí, 2010). O fornecimento de água limpa e confiável é crucial para apoiar o crescimento das populações e a atividade econômica nas cidades (Stoker *et al.*, 2019a). No entanto, analisar e prever a demanda por água urbana é uma tarefa complexa, mas imperativa para que as cidades atendam às necessidades de seus residentes (House-Peters; Chang, 2011).

A previsão da demanda por água, seja para períodos de curto ou longo prazo, é uma necessidade para as concessionárias de água, entretanto, essa tarefa revela-se complexa devido à diversidade de fatores a serem considerados, desde mudanças climáticas e desenvolvimento econômico até dinâmicas populacionais e padrões de comportamento do consumidor (Qi; Chang, 2011). Muitos dos dados utilizados em análises de demanda por água são agregados em unidades geográficas mais amplas, o que pode obscurecer nuances do uso da água em escala micro (House-Peters; Chang, 2011). Embora a análise em escala possa apresentar algumas limitações, como a incapacidade de capturar variações dentro dos municípios, essa escolha é frequentemente justificada por razões metodológicas, uma vez que muitos dados, incluindo o consumo de água, não estão disponíveis em níveis mais detalhados (March; Saurí, 2010). Além disso, os municípios também são entidades para ação política, como campanhas locais para alcançar reduções no consumo de água (March; Saurí, 2010).

A presente dissertação visou analisar as relações entre variáveis climáticas, fatores sociodemográficos, uso do solo e indicadores econômicos, e como esses elementos influenciam o consumo de água *per capita* nos municípios de Santa Catarina ao longo do período de 2012 a 2021. Utilizando modelos estatísticos para dados em painel, a pesquisa busca fornecer uma compreensão detalhada e regionalmente diferenciada dos fatores que impactam a demanda por água.

1.1 JUSTIFICATIVA

Nas últimas décadas, o crescimento populacional, as mudanças climáticas, o desenvolvimento agrícola e industrial, e as mudanças no estilo de vida têm intensificado a demanda por água em todo o mundo (Namdari; Haghighi; Ashrafi, 2023). Um modelo estatístico apropriado é necessário para capturar as principais propriedades de mudança do consumo de água e disponibilizar aos formuladores de políticas um bom suporte para a gestão dos recursos hídricos, dados os fatores influenciadores de consumo de água, que são complexos e numerosos (Wong; Zhang; Chen, 2010).

Segundo Zhao, Fan e Liang (2017), o desenvolvimento econômico, o crescimento populacional e os processos de urbanização, desempenham um papel determinante como principais forças motrizes na demanda por água. Diferenças nas características socioeconômicas, demográficas, nas condições climáticas e nas atitudes em relação ao consumo de água em cada cidade causam diferenças regionais nos níveis de consumo de água (Sun *et al.*, 2023).

Nesse contexto, propõe-se o desenvolvimento de uma análise exploratória que busque compreender as relações entre variáveis climáticas, econômicas, sociodemográficas e do uso do solo e o consumo de água em diferentes municípios. A pesquisa busca avaliar de que maneira essas variáveis influenciam o consumo de água, levando em conta as variações espaciais e temporais, com ênfase nas particularidades regionais de Santa Catarina.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Analisar as relações entre variáveis climáticas e sociodemográficas, o uso do solo e fatores econômicos, e suas influências no consumo de água *per capita* nos municípios de Santa Catarina ao longo do período de 2012 a 2021.

1.2.2 Objetivos específicos

No contexto mencionado, os objetivos específicos deste trabalho são listados a seguir:

- a) analisar a relação entre o uso do solo e o consumo de água *per capita* nos municípios de Santa Catarina;
- b) identificar o impacto das variáveis climáticas (temperatura e precipitação) sobre o consumo de água *per capita*;
- c) determinar a influência de indicadores econômicos e demográficos no consumo de água *per capita* ao longo do período de estudo;
- d) avaliar a eficácia dos modelos espaciais para dados em painel na explicação das variações do consumo de água;
- e) identificar a existência de dependência espacial no consumo de água dos municípios de Santa Catarina.

1.3 LIMITAÇÕES DE PESQUISA

A pesquisa apresentou limitações relacionadas à disponibilidade de variáveis para o período analisado e à confiabilidade dos dados de consumo de água *per capita* disponíveis no Sistema Nacional de Informações sobre Saneamento (SNIS). Para resolver a primeira limitação, optou-se por variáveis com série histórica para o período de estudo. Quanto à segunda limitação, aplicaram-se técnicas estatísticas para identificação e tratamento de *outliers*. Apesar dessas medidas reduzirem os impactos, tais aspectos permanecem como limitações a serem consideradas na interpretação dos resultados.

2 REVISÃO BIBLIOGRÁFICA

A revisão bibliográfica desenvolvida neste trabalho adotou uma abordagem sistemática, buscando reunir e analisar os principais estudos relacionados ao tema. Este capítulo está dividido em quatro seções: introdução, materiais e método, resultados e discussão e considerações finais do capítulo.

2.1 INTRODUÇÃO DA REVISÃO SISTEMÁTICA

Com o rápido desenvolvimento da sociedade global e a rápida expansão populacional, a demanda urbana por água aumentou drasticamente (Wang *et al.*, 2024). Analisar e prever a demanda urbana de água é uma tarefa complexa, mas essencial, já que as cidades precisam atender às demandas hídricas de seus habitantes (House-Peters; Chang, 2011). A eficácia das políticas hídricas depende de uma compreensão aprofundada dos fatores determinantes do uso da água (Yang; Chen, 2019). A falta dessa compreensão pode resultar em um diagnóstico impreciso do problema da escassez de água (Yang; Chen, 2019).

Prever e gerenciar a demanda urbana de água é complicado pela estreita relação que existe entre os sistemas humanos e naturais nas áreas urbanas House-Peters e Chang (2011). Essa relação resulta de múltiplas interações entre processos e padrões em microescala (nível individual, domiciliar ou de lote) e macroescala (nível municipal ou regional) House-Peters e Chang (2011).

Há estudos sobre o consumo de água que utilizam abordagens transversais, séries temporais e dados em painel. Cada uma dessas metodologias oferece perspectivas distintas sobre os aspectos analisados. Os estudos transversais, que analisam dados de um único ponto no tempo, são úteis para capturar um "instantâneo" de uma situação ou fenômeno, permitindo comparações entre diferentes unidades em um momento específico (Levin, 2006). Uma série temporal é um conjunto de observações dos valores que uma variável assume em diferentes momentos do tempo (Gujarati; Porter, 2011). Os dados de painel combinam séries temporais com várias seções transversais, permitindo observar unidades fixas, como municípios, ao longo de múltiplos anos (Toth; Bragalli; Neri, 2018).

Em sua revisão da literatura, House-Peters e Chang (2011) colocaram que o aumento da riqueza de dados levou a avanços na identificação e quantificação das

relações entre diversas variáveis sociais, climáticas e de consumo de água, mas ainda é necessário desenvolver metodologias capazes de incorporar esses diversos tipos de dados e aproveitar essa vasta informação para esclarecer as relações em múltiplas escalas. Nesse viés, propõe-se nova revisão da literatura, cujo objetivo é analisar os diferentes modelos utilizados para estudar o consumo de água em macro escala e identificar as principais variáveis utilizadas nesses estudos.

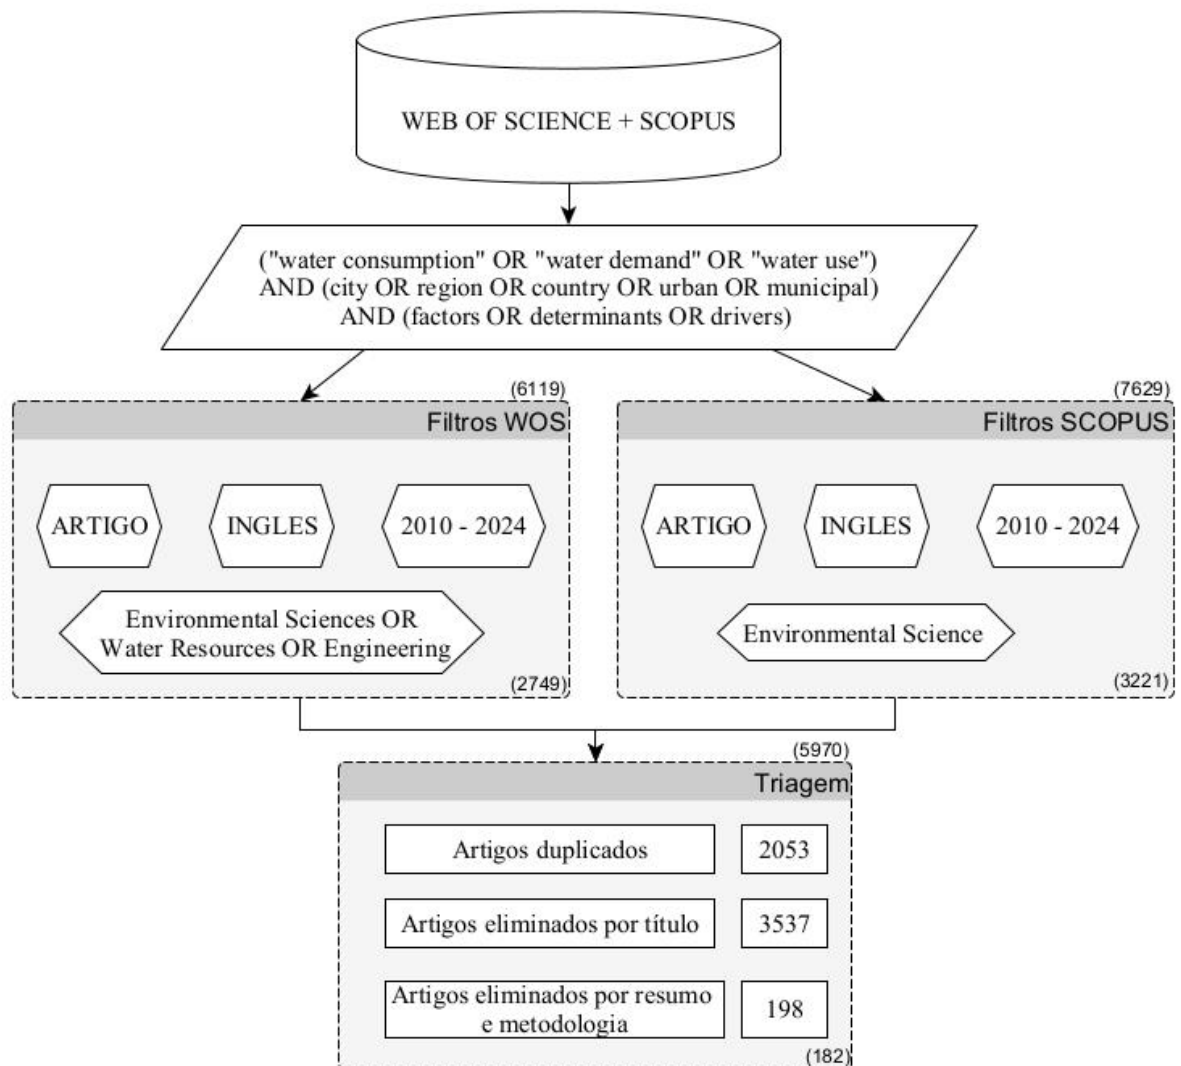
2.2 MATERIAIS E MÉTODOS

A principal finalidade desta revisão sistemática é coletar e analisar artigos que enfoquem o consumo de água em nível macro, com ênfase na avaliação dos padrões de consumo e nas variáveis que influenciam esse consumo. Essa análise busca responder as seguintes perguntas: quais são os fatores investigados em estudos sobre consumo de água em escala macro? Quais modelos estatísticos são empregados nesses estudos?

Os artigos selecionados para a revisão sistemática foram coletados da base *Web of Science* e *Scopus*. As *strings* de busca foram definidas após extensa análise de termos encontrados em artigos relevantes ao tema da pesquisa. A lógica da *string* de busca foi estruturada com base no tema central (consumo de água, demanda de água ou uso da água), área de abrangência (cidade, região, país, urbano ou municipal), e fatores que influenciam o consumo de água (fatores ou determinantes).

Com o intuito de eliminar artigos fora do escopo da pesquisa, foram aplicados filtros. Apenas artigos no idioma inglês, do tipo artigo e publicados no período de 2010 a julho de 2024 classificados nos seguintes assuntos Ciências Ambientais, Recursos Hídricos e Engenharia. Em seguida, procedeu-se à triagem, que envolveu etapas de exclusão. Os artigos duplicados nas duas bases foram removidos. Posteriormente, compreendeu-se a leitura dos títulos dos artigos, seguida pelos resumos e, por último, a análise da metodologia utilizada. Esta revisão sistemática engloba 182 artigos (Figura 1). Observa-se uma considerável eliminação durante a triagem, principalmente devido ao foco em temas relacionados à agricultura, saúde, gestão e políticas de água, ou à abordagem do consumo de água em uma escala micro, que fogem ao escopo da pesquisa.

Figura 1 - Diagrama da revisão sistemática



Fonte: Elaborado pela autora (2025)

Foi realizada a análise bibliométrica dos 182 artigos selecionados. Para tal finalidade foi utilizado o *software Bibliometrix* (Aria; Cuccurullo, 2017). Este procedimento permitiu uma avaliação quantitativa da produção científica relacionada ao tema em estudo, incluindo a elaboração de gráfico de publicações por ano e geração de nuvem de palavras-chave.

2.3 RESULTADOS E DISCUSSÃO

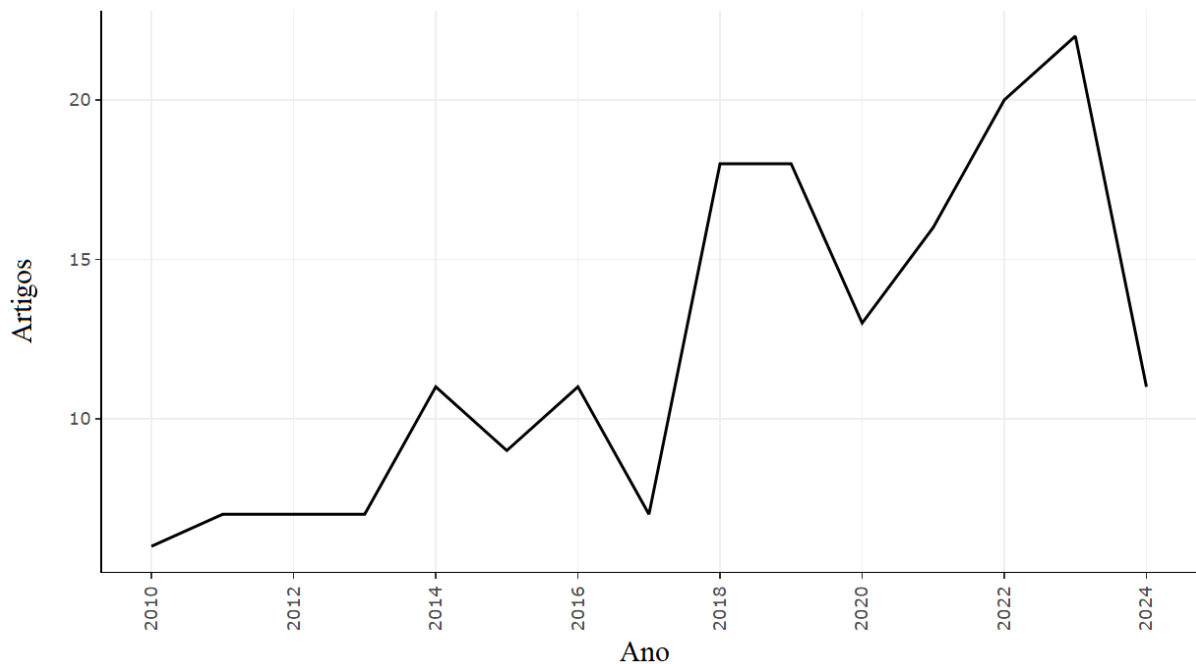
Os artigos selecionados para a revisão tiveram suas respectivas áreas de estudo identificadas e agregadas por país (Figura 2). Observa-se que a China e os Estados

Unidos destacam-se com o maior número de publicações nessa área, refletindo a importância estratégica e os desafios que ambos os países enfrentam em relação à gestão de recursos hídricos. A China lidera a produção científica, o que pode ser atribuído às políticas rigorosas implementadas para o gerenciamento de recursos hídricos, especialmente em resposta às pressões causadas pela urbanização e industrialização aceleradas (Zhang *et al.*, 2020).

Embora comumente associada a países menos desenvolvidos, a escassez de água também afeta outras regiões, como a Europa, onde a disponibilidade e o uso de água são desiguais, apesar da abundância em algumas áreas (Baigorri; Montañés; Simón-Fernández, 2022). A Agência Europeia do Ambiente (EEA) estimou que a demanda por água na Europa aumentou nos últimos 50 anos, reduzindo os recursos hídricos renováveis e expondo um terço do território da União Europeia a estresse hídrico, seja de forma temporária ou permanente (Baigorri; Montañés; Simón-Fernández, 2022). Esse problema atinge tanto países do sul, como Portugal, Espanha e Grécia, quanto regiões do norte, como o Reino Unido e a Alemanha, e é agravado pelas ameaças das mudanças climáticas (Baigorri; Montañés; Simón-Fernández, 2022).

Outras nações como o Iraque, o Canadá, a Índia, Austrália também contribuem para a literatura científica sobre o tema, trazendo as perspectivas e desafios locais. Essa distribuição geográfica da produção científica evidencia a natureza global das preocupações com a gestão da água, e como diferentes contextos nacionais influenciam a abordagem e o foco das pesquisas.

Figura 3 - Produção científica anual da base Scopus e WOS (2010-2024)



Fonte: Elaborado pela autora (2025)

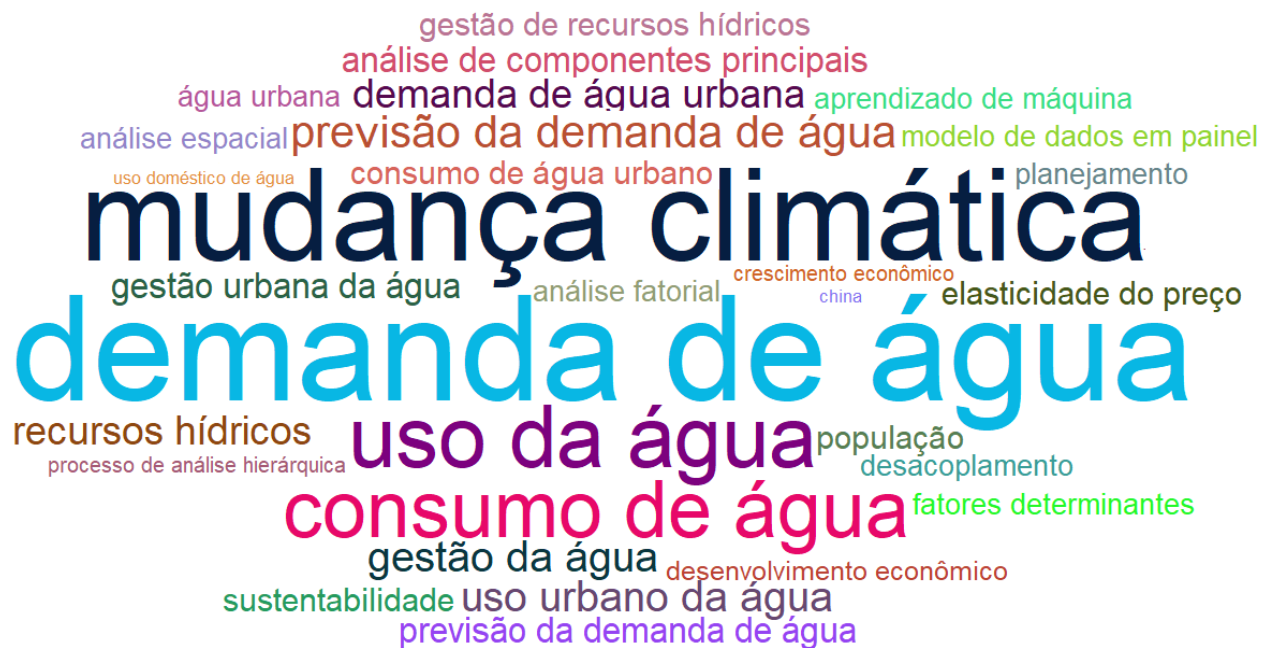
A Figura 4 foi gerada utilizando o software *Bibliometrix*, a partir da análise das 30 palavras-chave mais frequentes nos artigos selecionados para esta revisão sistemática. Esta nuvem de palavras destaca visualmente os termos que os autores mais frequentemente utilizaram para descrever o foco de suas pesquisas. Entre as palavras que mais se sobressaem estão mudança climática, demanda de água, consumo de água e uso da água. A predominância desses termos sugere que grande parte dos estudos analisados está concentrada na avaliação dos impactos das mudanças climáticas sobre a demanda e o consumo de água, bem como na gestão desses recursos.

Além disso, termos como população e crescimento econômico indicam a análise de como o crescimento populacional e econômico afetam o consumo de água, enquanto elasticidade do preço destaca estudos que exploram a sensibilidade do consumo de água às variações de preço.

A presença de termos como desacoplamento, previsão, processo de hierarquia analítica, análise fatorial, análise espacial, aprendizado de máquina e análise de componentes principais aponta para o uso de modelos estatísticos e técnicas avançadas de análise nos estudos revisados. Essas metodologias são fundamentais para entender as complexas interações entre os diversos fatores que influenciam o

consumo de água, bem como para prever tendências futuras e avaliar a eficácia de diferentes estratégias de gestão hídrica.

Figura 4 - Nuvem de palavras gerada a partir das palavras-chaves dos artigos analisados



Fonte: Elaborado pela autora (2025)

2.3.1 Escala temporal e espacial

Os artigos selecionados apresentam diversidade em escala temporal e espacial. As análises encontradas variam desde valores agregados a nível de vizinhança, setor censitário, bairro, município, até cidades, estados e países. A escala temporal das análises também é variada, abrangendo desde estudos que avaliam o consumo de água em intervalos horários, diários, mensais, bimestrais, trimestrais até anuais.

O estudo de Medina-Rivas *et al.* (2022) analisaram o consumo de água bimestral agregado em um ano para 1647 vizinhanças da Cidade do México para avaliar a configuração dos padrões espaciais que definem as diferenças no consumo de água nas residências da Cidade do México, bem como sua associação com possíveis fatores causais. A metodologia incluiu análise espacial e do uso de sistemas de informação geográfica e confirmaram a existência de dois clusters de residências cuja localização destaca áreas onde a desigualdade no consumo de

água está presente (Medina-Rivas *et al.*, 2022). Em outro estudo, Anil Kumar e Ramachandran (2019) analisaram 198 distritos municipais da Índia com dado mensal do consumo de água e investigaram as influências de variáveis demográficas e de infraestrutura que impulsionam a demanda de água nas residências.

Com a finalidade de compreender os efeitos das variáveis climáticas sobre a demanda de água diária em um município da Austrália, Zubaidi *et al.* (2018) conseguiram simular padrões sazonais e anuais de consumo utilizando um modelo de rede neural artificial. Namdari *et al.* (2023) implementaram rede neural convolucional unidimensional para previsão de água de curto prazo, o estudo foi aplicado a dados horários de consumo de água de um município do Irã.

Com o intuito de compreender a variedade de perfis nacionais, Balata, Pinto e Silva (2022) elaboraram uma análise transversal com dados de 195 países e seu respectivo uso da água em um ano. O estudo utilizou análise fatorial e técnica de clusterização para definir dimensões no nexo entre uso da água e desenvolvimento socioeconômico e para realizar o agrupamento de países (Balata; Pinto; Silva, 2022). Os resultados da clusterização esclarecem as conexões entre as condições de uso da água e o desenvolvimento socioeconômico (Balata; Pinto; Silva, 2022).

2.3.2 Algoritmos e modelos aplicados nos estudos

Na literatura há diferentes modelos e algoritmos utilizados na previsão da demanda de água e na avaliação dos fatores que influenciam o consumo. A escolha do método mais adequado depende não apenas dos dados disponíveis, mas também da escala em que esses dados são analisados. Essa diversidade de metodologias permite adaptar as previsões e avaliações às necessidades específicas de cada estudo ou aplicação.

A previsão da demanda urbana de água é crucial para reduzir o desperdício de recursos hídricos e aumentar a proteção ambiental (Zhou *et al.*, 2022). Com o aprimoramento da tecnologia computacional, técnicas de inteligência artificial, como Redes Neurais Artificiais (RNA) e Máquinas de Vetores de Suporte (SVM), tornaram-se ferramentas eficazes para a previsão de demanda de água (Huang *et al.*, 2014). As RNA são modelos matemáticos frequentemente utilizados para sistemas

complexos e podem fornecer suposições probabilísticas para previsões (Liu; Zhao; Wang, 2015).

Utilizando técnicas de aprendizado de máquina é possível realizar previsões do consumo de água de curto e longo prazo. Um dos desafios significativos ao utilizar métodos de aprendizado de máquina é escolher características apropriadas que afetam diretamente os resultados da previsão (Namdari; Ashrafi; Haghighi, 2024). Zhou *et al.* (2022) propõem uma estrutura híbrida para a previsão da demanda diária de água urbana com múltiplas variáveis, que combina Rede Neural Convolucional (CNN) e memória de curto e longo prazo (LSTM). Para prever a demanda de água mensal urbana, Xu *et al.* (2022) utilizam o modelo Rede de Características Temporais com *Embedding* de Palavras (WE-TFN). Outra técnica de aprendizado de máquina, Florestas Aleatórias, pode ser aplicada para classificar a importância das variáveis que influenciam o consumo de água (Fan *et al.*, 2017; Guo; Sun; Du, 2022; Nunes Carvalho; De Souza Filho; Porto, 2021).

Há artigos que utilizam técnicas de otimização em seus estudos de consumo de água. Há algoritmos de otimização, algoritmos de inteligência de enxame, a partir do comportamento animal, como o Algoritmo Genético, o Algoritmo de Otimização por Colônia de Formigas, o Algoritmo de Cardume de Peixes Artificiais, o Algoritmo de Imunidade Artificial, a Otimização por Enxame de Partículas (PSO) e o Algoritmo de Otimização da Mosca-das-frutas (FFOA) (Lu; Matthews; Han, 2020). O estudo de Liu Zhao e Wang (2015) utiliza a técnica de otimização chamada Programação Genética (GP) para identificar os determinantes mais importantes do uso urbano de água em 47 cidades do norte da China. Liu, Zhao, Wang e (2015) utilizaram a técnica de otimização para prever a demanda mensal de água municipal, utilizando um modelo híbrido que combina o algoritmo de otimização FFOA, o Fator de Cruzamento Genético (GCF), o Algoritmo de Recozimento Simulado (SA) e a SVM. A otimização foi aplicada para ajustar os parâmetros da SVM com o objetivo de melhorar a precisão das previsões (Liu; Zhao; Wang, 2015). A Tabela 1 apresenta os artigos que utilizam técnicas de aprendizado de máquina e de otimização.

Tabela 1 - Artigos com aprendizado em máquina e técnicas de otimização

Artigos	Aprendizado de máquina	Técnicas de otimização
(Lu; Matthews; Han, 2020; Zubaidi <i>et al.</i> , 2018b)	X	X

Artigos	Aprendizado de máquina	Técnicas de otimização
(Al-Zahrani; Abo-Monasar, 2015; Fan <i>et al.</i> , 2017; Gharabaghi; Stahl; Bonakdari, 2019; Guo; Sun; Du, 2022; Koo <i>et al.</i> , 2021; Li; Huicheng, 2010; Li <i>et al.</i> , 2023; Liu <i>et al.</i> , 2024; Lü <i>et al.</i> , 2018; Mo <i>et al.</i> , 2024; Namdari; Ashrafi; Haghighi, 2024; Namdari; Haghighi; Ashrafi, 2023, 2023; Nunes Carvalho; De Souza Filho; Porto, 2021; Ou <i>et al.</i> , 2023; Roushangar; Alizadeh, 2018; Toth; Bragalli; Neri, 2018; Wu; Wang; Dong, 2021; Xu <i>et al.</i> , 2022; Yang; Chen, 2019; Yang <i>et al.</i> , 2016, 2022; Zhou <i>et al.</i> , 2022; Zubaidi <i>et al.</i> , 2018a, 2020b, 2023)	X	
(Liu; Zhao; Wang, 2015; Shabani; Gharneh; Niaki, 2020; Wang <i>et al.</i> , 2024; Yilmaz, 2022; Yilmaz; Alpars, 2023)		X
Fonte: Elaborado pela autora (2025)		

A Tabela 2 contém os artigos que apresentam modelos estatísticos para a análise de dados, incluindo modelos de regressão, regressão espacial, modelos em painel, além de métodos de séries temporais e previsão encontradas na revisão.

Tabela 2 - Artigos com regressão, regressão espacial, modelos em painel e misto e séries temporais e previsão

Artigos	1	2	3	4
(Chang <i>et al.</i> , 2017; Chen <i>et al.</i> , 2021; Ramos-Bueno; Perevochtchikova; Chang, 2021)	X	X		
(Expósito; Pablo-Romero; Sánchez-Braza, 2019; Ghavidelfar; Shamseldin; Melville, 2018; Sousa; Teixeira; Fouto, 2022)	X		X	
(Alsulaili; Alkandari; Buqammaz, 2022; Fontdecaba <i>et al.</i> , 2012; He; Tao, 2014; Hemati <i>et al.</i> , 2016)	X			X
(Anil Kumar; Ramachandran, 2019; Ashoori; Dzombak; Small, 2016, 2017; Brelsford; Abbott, 2017; Breyer; Chang, 2014; Capt <i>et al.</i> , 2021; Connolly; Hagelman, 2015; Veiga; Kalbusch; Henning, 2023; Garcia; Islam, 2018; García-López; Montano, 2020; Hao; Hu; Chen, 2019; Haque <i>et al.</i> , 2018; Johnson <i>et al.</i> , 2023; Klaiber <i>et al.</i> , 2014; Lawens; Mutsvangwa, 2018; Li; Huicheng, 2010; Lins <i>et al.</i> , 2010; Liu; Cheng; Zhang, 2013; Morain; Anandhi, 2022; Msongaleli <i>et al.</i> , 2023, p. 1992–2029; Polebitski; Palmer; Waddell, 2011; Polidori; Paulson; Gronewold,		X		

Artigos	1	2	3	4
2024; Qi; Chang, 2011; Runfola <i>et al.</i> , 2013; Shandas; Parandvash, 2010; Tayebi <i>et al.</i> , 2022; Timotewos; Barjenbruch; Behailu, 2022; Villarín, 2019; Vonk; Cirkel; Blokker, 2019; Worland; Steinschneider; Hornberger, 2018; Zhao; Fan; Liang, 2017)				
(Medina-Rivas <i>et al.</i> , 2022; Sohn, 2011; Song <i>et al.</i> , 2022; Sun <i>et al.</i> , 2023)		X		
(Acuña <i>et al.</i> , 2020; Aggarwal <i>et al.</i> , 2012; Barker <i>et al.</i> , 2021; Ding <i>et al.</i> , 2019; Ding; Fu; Jia, 2019; Fercovic; Foster; Melo, 2019; Ghavidelfar; Shamseldin; Melville, 2017; Maldonado-Devis; Almenar-Llongo, 2021; March; Perarnau; Saurí, 2012; O'Donnell; Berrens, 2018; Opalinski; Bhaskar; Manning, 2020; Ouyang <i>et al.</i> , 2014; Romano; Salvati; Guerrini, 2014, 2016; Stoker <i>et al.</i> , 2019b; Toth; Bragalli; Neri, 2018)			X	
(Alnsour; Ijam, 2023; Al-Zahrani; Abo-Monasar, 2015; Daw; Ali; Toriman, 2019; Gharabaghi; Stahl; Bonakdari, 2019; Guo; Sun; Du, 2022; Guo; Wang, 2023; Huang <i>et al.</i> , 2014; Koo <i>et al.</i> , 2021; Li; Song, 2023; Makpiboon, 2020; Moglia; Nygaard, 2024; Renzetti <i>et al.</i> , 2015; Taştan, 2018; Telfah; Jaradat; Ismail, 2024; Wang <i>et al.</i> , 2024; Wong; Zhang; Chen, 2010; Wu; Meng, 2023)				X
1 = modelos de regressão, 2 = modelos de regressão espacial, 3 = modelos de dados em painel e 4 = modelos de séries temporais e previsão				

Fonte: Elaborado pela autora (2025)

Na revisão sistemática, observou-se que os modelos de regressão, lineares e não lineares, são predominantemente associados a estudos transversais. Esses modelos têm como objetivo identificar os fatores que impactam o consumo de água em diferentes regiões. Anil Kumar e Ramachandran (2019) utilizam modelos lineares e não lineares em seu estudo transversal para estimar os fatores que afetam o consumo de água em municípios da Índia, empregando o método dos mínimos quadrados ordinários (OLS). No estudo de Anil Kumar e Ramachandran (2019), como as cidades analisadas compartilham fronteiras, foi aplicado o índice de Moran para verificar se há dependência espacial, o que viola a suposição de independência das observações, um pressuposto do OLS. Com a confirmação da dependência espacial, Anil Kumar e Ramachandran (2019) realizaram regressões separadas para os diferentes *clusters* encontrados na área de estudo.

Existem modelos que incorporam a estrutura espacial dos dados, como é o caso dos modelos de regressão espacial. No estudo transversal de Chang *et al.* (2017) foram analisados os fatores que influenciam o consumo de água residencial unifamiliar a nível de setor censitário em quatro municípios dos Estados Unidos, utilizando OLS e regressão de erro espacial. Chang *et al.* (2017) colocam que como o uso da água

é, ao menos em parte, um fenômeno espacial, os modelos de erro espacial devem fornecer uma representação mais precisa dos fatores que influenciam o uso da água nas residências nas áreas de estudo. Os resultados indicaram que os modelos de regressão de erro espacial apresentaram valores do coeficiente de explicação do modelo (R^2) mais elevados do que os equivalentes por OLS, uma vez que os erros dos modelos de regressão OLS não são espacialmente aleatórios (Chang *et al.*, 2017). Assim, a inclusão do termo de erro espacial como parte dos modelos de regressão melhorou a capacidade dos modelos de explicar as variações no uso de água residencial unifamiliar (Chang *et al.*, 2017). Ramos-Bueno, Perevochtchikova e Chang (2021) exploraram, em seu estudo transversal, os modelos OLS e regressão ponderada geograficamente (GWR) na análise do consumo de água em vizinhanças no México. Os resultados do GWR apresentaram maior R^2 e menor Akaike Information Criterion (AIC), indicando que o GWR apresentou melhor ajuste (Ramos-Bueno; Perevochtchikova; Chang, 2021). No estudo de Sun *et al.* (2023), foram analisados dados em painel de 41 cidades da China entre 2010 e 2019, utilizando métodos econométricos espaciais e de regressão com limiar. Os resultados mostram as diferenças espaciais no consumo de água entre as cidades (Sun *et al.*, 2023).

Ghavidelfar, Shamseldin e Melville (2017) estudaram em diferentes escalas o consumo de água em um município da Nova Zelândia para um período de 6 anos. O modelo em painel de efeitos fixos foi utilizado para a análise em micro escala (residências), e para a análise em escala de setor censitário, o modelo mais apropriado foi o de efeitos aleatórios (Ghavidelfar; Shamseldin; Melville, 2017). O estudo teve como objetivo analisar a heterogeneidade das respostas à demanda por água em diferentes grupos de consumidores, utilizando a escala domiciliar, e avaliar o padrão espacial de consumo de água e os efeitos da estrutura urbana, como a densidade populacional, utilizando dados agregados (Ghavidelfar; Shamseldin; Melville, 2017).

Os modelos de séries temporais e de previsão podem capturar padrões, tendências e sazonalidades no consumo de água ao longo do tempo, assim como nas variáveis explicativas. Makpiboon (2020) explorou regressão linear múltipla de séries temporais para analisar o impacto de variáveis climáticas em diferentes escalas temporais (diária, mensal e sazonal) no consumo de água urbano da região metropolitana da Tailândia. Para analisar somente o impacto das variáveis climáticas, estudou-se a tendência de aumento do consumo de água urbano devido a fatores

como economia e crescimento populacional (Makpiboon, 2020). Wang *et al.* (2024) utilizam um modelo de previsão cinza multivariável com acumulação adjacente para prever o consumo de água anual em uma cidade da China com dados de 15 anos para construção e validação do modelo. A análise relacional cinza foi utilizada para escolher as variáveis independentes mais apropriadas (Wang *et al.*, 2024).

2.3.3 Fatores físicos

As principais variáveis físicas identificadas na revisão sistemática são importantes para a compreensão das dinâmicas que influenciam o consumo de água. Estas variáveis incluem o uso do solo, que se refere à forma como a terra é utilizada em diferentes áreas; o crescimento urbano e a urbanização, que refletem o aumento da população e a expansão das cidades; a caracterização urbana; a densidade de construção, que diz a respeito ao número de edificações em uma determinada área; e as características dos domicílios, que incluem aspectos físicos das residências, como número de banheiros, área da residência e presença de aquecedores de água, geralmente obtidos a partir de censos demográficos. As variáveis selecionadas são apresentadas na Tabela 3.

Tabela 3 – Artigos com variáveis físicas

Artigo	1	2	3	4	5
(Tayebi <i>et al.</i> , 2022)	X		X		X
(Shandas; Parandvash, 2010)	X			X	X
(Deng <i>et al.</i> , 2021; Prasood <i>et al.</i> , 2021)	X	X			
(Morote; Hernández, 2016)	X		X		
(Droogers <i>et al.</i> , 2012; Expósito; Pablo-Romero; Sánchez-Braza, 2019; Guo <i>et al.</i> , 2013, p. 1985–2009; Harma; Johnson; Cohen, 2012; Li; Yang; Tan, 2019; Morain; Anandhi, 2022; Nivesh <i>et al.</i> , 2022; Willuweit; O’Sullivan, 2013; Yang <i>et al.</i> , 2022; Yuan <i>et al.</i> , 2024)		X			
(Connolly; Hagelman, 2015; Fercovic; Foster; Melo, 2019)		X			X
(Anil Kumar; Ramachandran, 2019)			X	X	X
(Ghavidelfar; Shamseldin; Melville, 2017; Ouyang <i>et al.</i> , 2014; Polebitski; Palmer; Waddell, 2011)				X	X
(Bouziotas; Rozos; Makropoulos, 2015; Ding <i>et al.</i> , 2019; Ding; Fu; Jia, 2019; Guo; Wang, 2023; Huang <i>et al.</i> , 2014; Lyu <i>et al.</i> , 2021; Mo <i>et al.</i> , 2024; Msongaleli <i>et al.</i> , 2023, p. 1992–2029; Ou <i>et al.</i> , 2023; Shiklomanov; Babkin;		X			

Artigo	1	2	3	4	5
Balonishnikov, 2011; Sun <i>et al.</i> , 2023; Zhang <i>et al.</i> , 2020; Zhao; Fan; Liang, 2017; Zhou; Su; Zhang, 2019)					
(Worland; Steinschneider; Hornberger, 2018)			X	X	
(Li; Huicheng, 2010; Panagopoulos <i>et al.</i> , 2012; Stoker <i>et al.</i> , 2019b)			X		
(Villarín, 2019)				X	
(Acuña <i>et al.</i> , 2020; Aggarwal <i>et al.</i> , 2012; Barker <i>et al.</i> , 2021; Brelsford; Abbott, 2017; Chang <i>et al.</i> , 2017; Chen <i>et al.</i> , 2021; Veiga; Kalbusch; Henning, 2023; Dang; Li; Fan, 2022; Fan <i>et al.</i> , 2017; Fontdecaba <i>et al.</i> , 2012; Ghavidelfar; Shamseldin; Melville, 2016, 2018; Han <i>et al.</i> , 2021; House-Peters; Pratt; Chang, 2010; Liu; Zhao; Wang, 2015; Maldonado-Devis <i>et al.</i> , 2021; Maldonado-Devis; Almenar-Llongo, 2021; March; Perarnau; Saurí, 2012; Runfola <i>et al.</i> , 2013; Sohn, 2011)					X

1 = uso do solo, 2 = crescimento urbano/urbanização, 3 = caracterização urbana, 4 = densidade de construção e 5 = característica dos domicílios

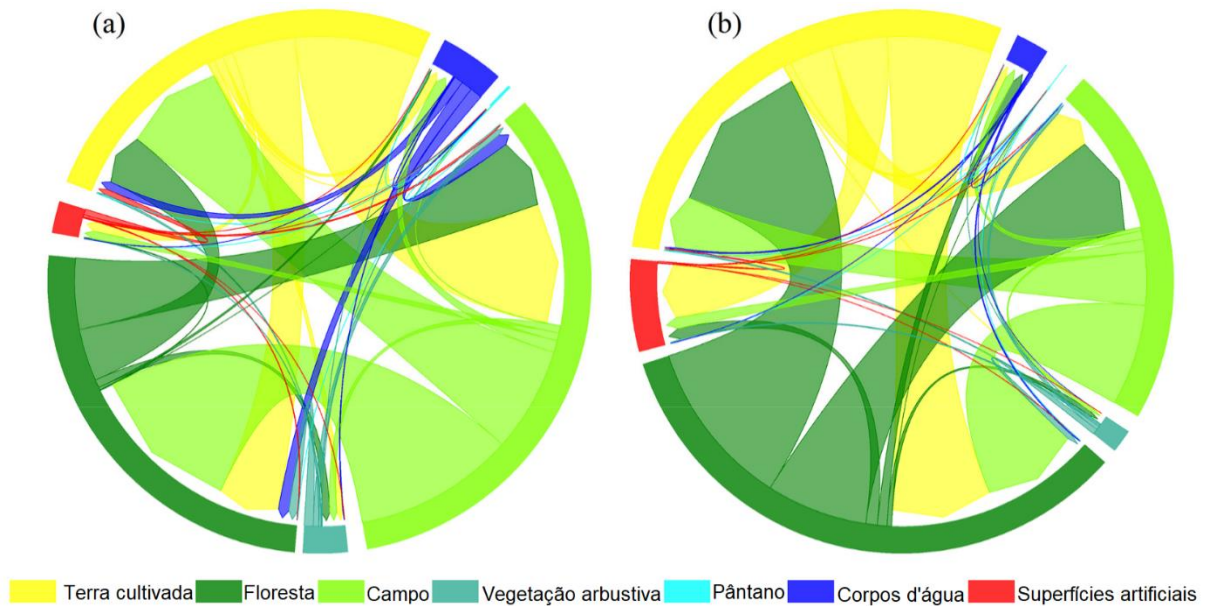
Fonte: Elaborado pela autora (2025)

O processo de urbanização tem sido tendência crescente em todo o mundo (Tayebi *et al.*, 2022). A urbanização abrange diferentes perspectivas disciplinares, resultando em diversas formas de mensurá-la (Sun *et al.*, 2023). Sob uma ótica socioeconômica, é vista como um processo natural de transição de uma sociedade agrícola para uma sociedade urbana moderna, refletindo no crescimento populacional urbano, expansão da área urbana, melhoria dos padrões de vida e transformação da estrutura industrial (Sun *et al.*, 2023). Essas mudanças indicam uma reestruturação socioeconômica significativa e um grande desenvolvimento (Sun *et al.*, 2023). A rápida expansão das áreas urbanas, impulsionada por fatores econômicos, resulta em sistemas cada vez mais complexos (Tayebi *et al.*, 2022). No estudo de Sun *et al.* (2023), a urbanização é calculada com base no método de pesos de entropia, utilizando variáveis como população urbana, valor adicionado do setor terciário, renda *per capita* e proporção de área construída. Sun *et al.*, (2023) colocam que o aumento do nível de urbanização de uma cidade eleva o consumo doméstico de água, enquanto o aumento da urbanização em cidades vizinhas reduz esse consumo.

A urbanização traz desenvolvimento econômico e crescimento tecnológico e educação, no entanto causa extensivas mudanças no uso do solo e consumo de recursos naturais (Tayebi *et al.*, 2022). Yuan *et al.* (2024) analisaram o uso do solo na província de Guizhou entre 2000 e 2020 (Figura 5). No diagrama de Sankey é possível

notar que o processo de urbanização está associado à contínua diminuição das áreas de terras cultivadas, pastagens e florestas, com a transferências dessas áreas para superfícies artificiais (Yuan *et al.*, 2024). A migração populacional e a rápida expansão urbana contribuem para o aumento das superfícies artificiais (Yuan *et al.*, 2024).

Figura 5 - Transição do uso do solo (a) de 2000 a 2010 e (b) de 2010 a 2020



Fonte: Adaptado de Yuan *et al.* (2024)

Tayebi *et al.* (2022) colocam que Teerã, capital do Irã, passou por grandes mudanças no uso da terra devido ao crescimento populacional, com áreas agrícolas sendo substituídas por construções urbanas, aumentando a demanda por infraestrutura. O estudo destaca que o uso da terra, especialmente em áreas residenciais e verdes, tem um impacto significativo no consumo de água, ressaltando a importância de gestão hídrica, das políticas populacionais e do planejamento urbano (Tayebi *et al.*, 2022). Shandas e Parandvash (2010) utilizaram um sistema de informações geográficas (SIG) para caracterizar 122.550 parcelas de diferentes usos de terra em uma cidade dos Estados Unidos e associaram estatisticamente as formas urbanas (quantidade de área construída em uma determinada paisagem) e os dados sociodemográficos dos usuários de água com dados empíricos sobre o consumo de água ao longo de 5 anos. O estudo concluiu que, para a área de estudo, o desenvolvimento de áreas residenciais unifamiliares está associado a um maior consumo de água (Shandas; Parandvash, 2010).

Shandas e Parandvash (2010) colocam que uma redução no tamanho das construções diminui a quantidade de área que contribui diretamente para o consumo de água. Uma redução de 25% no tamanho médio de residências unifamiliares, de 265 m² para 195 m², resultou em um decréscimo de 25 milhões de litros de água por ano na região estudada (Shandas; Parandvash, 2010). Para um novo empreendimento residencial unifamiliar com 100 unidades, essa redução no tamanho das construções poderia levar a uma economia de quase 2 bilhões de litros de água por ano (Shandas; Parandvash, 2010). No estudo de Maldonado-Devis e Almenar-Llongo (2021) o consumo de água residencial aumenta 0,24% para o aumento de 1% na área da residência.

O aumento da densidade residencial está significativamente relacionado de forma negativa ao consumo de água (Ghavidelfar; Shamseldin; Melville, 2017; Shandas; Parandvash, 2010). Sem qualquer alteração no tamanho das construções, um aumento de uma unidade habitacional por 4046,86 m² (um acre) reduziria o consumo em 1,6 milhão de litros por ano (Shandas; Parandvash, 2010). Segundo Expósito, Pablo-Romero e Sánchez-Braza (2019) com relação à urbanização e à densidade populacional, os coeficientes estimados mostram valores positivos e negativos significativos, respectivamente. Nesse sentido, o aumento da população e da urbanização requer medidas efetivas de conformidade cruzada entre as políticas de uso da terra e da água, uma vez que as mudanças no uso da terra impactam a sustentabilidade dos recursos hídricos (Expósito; Pablo-Romero; Sánchez-Braza, 2019).

Morote e Hernández (2016) estudaram as mudanças do uso do solo em cidades litorâneas da Espanha e colocam que a expansão residencial nas cidades foi acompanhada por uma transformação no modelo urbano. De um modelo urbano concentrado passou-se para modelos de baixa densidade (casas isoladas com piscina e jardim), de densidade média (casas germinadas) e, em muito menor grau, para edifícios de grande altura (Morote; Hernández, 2016). Segundo Morote e Hernández (2016) o aumento no número de moradias, especialmente, a adoção de tipologias urbanas extensivas, dada a natureza horizontal de seu desenvolvimento, requer um alto consumo de água. Em áreas dominadas pela urbanização de baixa densidade (composta em grande parte por casas isoladas), a densidade populacional é menor, mas, por outro lado, o consumo de água é proporcionalmente maior, pois a maioria dessas residências possui piscinas privadas e jardins (Morote; Hernández, 2016). No

entanto, em áreas dominadas por empreendimentos de casas geminadas ou apartamentos, a densidade populacional é maior, mas o consumo de água é menor, já que as piscinas e os jardins são compartilhados com os demais moradores (Morote; Hernández, 2016).

2.3.4 Fatores climáticos

As variáveis climáticas são amplamente estudadas em pesquisas sobre consumo de água, abrangendo desde a variabilidade diária, como mudanças na temperatura e precipitação ao longo do dia, até padrões sazonais. Além disso, essas variáveis mostram diferenças importantes entre regiões, destacando as variações geográficas nos padrões climáticos. A Tabela 4 reúne as principais variáveis climáticas identificadas na revisão sistemática.

Tabela 4 – Artigos com variáveis climáticas

Artigos	1	2	3	4	5	6	7	8
(Zubaidi <i>et al.</i> , 2018b)		X		X	X			
(Zubaidi <i>et al.</i> , 2023)	X	X	X		X	X	X	
(Zubaidi <i>et al.</i> , 2020b)	X	X	X		X	X		X
(Yuan <i>et al.</i> , 2024)	X	X	X		X		X	X
(Li <i>et al.</i> , 2023; Liu <i>et al.</i> , 2024; Yilmaz, 2022; Yilmaz; Alpars, 2023)	X	X	X			X	X	
(Alsulaili; Alkandari; Buqammaz, 2022; Al-Zahrani; Abo-Monasar, 2015)	X	X	X				X	
(Namdari; Ashrafi; Haghighi, 2024; Roushangar; Alizadeh, 2018; Sohn, 2011; Timotewos; Barjenbruch; Behailu, 2022; Wu; Wang; Dong, 2021)	X	X	X					
(Barker <i>et al.</i> , 2021; Hamlat <i>et al.</i> , 2024; Haque <i>et al.</i> , 2018, 2015; Vonk; Cirkel; Blokker, 2019)	X	X		X				
(Zubaidi <i>et al.</i> , 2018a)	X	X			X	X		
(Blanc <i>et al.</i> , 2014; Droogers <i>et al.</i> , 2012; Fabre <i>et al.</i> , 2015; Harma; Johnson; Cohen, 2012; Kahlerras <i>et al.</i> , 2018; Opalinski; Bhaskar; Manning, 2020; Warziniack <i>et al.</i> , 2022)	X	X						X
(Acuña <i>et al.</i> , 2020; Alamanos, 2021; Alnsour; Ijam, 2023; Arampatzis <i>et al.</i> , 2016; Ashoori; Dzombak; Small, 2016, 2017; Baigorri; Montañés; Simón-Fernández, 2022; Brelsford; Abbott, 2017; Breyer; Chang, 2014; Capt <i>et al.</i> , 2021; Chang <i>et al.</i> , 2017; Chhetri, 2011; Daw; Ali; Toriman, 2019; Fercovic; Foster; Melo,	X	X						

Artigos	1	2	3	4	5	6	7	8
2019; Gebreyohannes Hiben; Gebeyehu Awoke; Adugna Ashenafi, 2024; Gharabaghi; Stahl; Bonakdari, 2019; Ghavidelfar; Shamseldin; Melville, 2017, 2018; Graham <i>et al.</i> , 2018; Hemati <i>et al.</i> , 2016; Huang <i>et al.</i> , 2014; Johnson <i>et al.</i> , 2023; Karahan; Elçi, 2023; Klaiber <i>et al.</i> , 2014; Lins <i>et al.</i> , 2010; Liu; Cheng; Zhang, 2013; Liu; Zhao; Wang, 2015; Makpiboon, 2020; Mazzoni <i>et al.</i> , 2022; Moglia; Nygaard, 2024; Nivesh <i>et al.</i> , 2022; O'Donnell; Berrens, 2018; Ou <i>et al.</i> , 2023; Ouyang <i>et al.</i> , 2014; Polebitski; Palmer; Waddell, 2011; Renzetti <i>et al.</i> , 2015; Reynaud; Pons; Pesado, 2018; Romano; Salvati; Guerrini, 2014, 2016; Sebri, 2014; Shiklomanov; Babkin; Balonishnikov, 2011; Taştan, 2018; Toth; Bragalli; Neri, 2018; Wong; Zhang; Chen, 2010; Worland; Steinschneider; Hornberger, 2018; Xiao-jun <i>et al.</i> , 2015; Yang <i>et al.</i> , 2016)								
(He; Zhao; Wen, 2022; Karahan; Elçi, 2023; Shabani; Gharneh; Niaki, 2020)	X			X				
(Ahmad; Haie, 2018; Deng <i>et al.</i> , 2021; Parkinson <i>et al.</i> , 2016; Prasood <i>et al.</i> , 2021; Willuweit; O'Sullivan, 2013)	X							X
(Connolly; Hagelman, 2015; Fabre <i>et al.</i> , 2016; Fan <i>et al.</i> , 2017; Ghavidelfar; Shamseldin; Melville, 2016; Li; Yang; Tan, 2019; Panagopoulos, 2014; Telfah; Jaradat; Ismail, 2024; Wu; Liu; Deng, 2023; Yan <i>et al.</i> , 2020; Zhang <i>et al.</i> , 2018; Zhou; Su; Zhang, 2019)	X							
(Lu; Matthews; Han, 2020; Xu <i>et al.</i> , 2022)		X	X					
(Aggarwal <i>et al.</i> , 2012; Almutaz <i>et al.</i> , 2012, 2013; Veiga; Kalbusch; Henning, 2023; Fabre <i>et al.</i> , 2016; Guo; Sun; Du, 2022; He; Tao, 2014; Li; Huicheng, 2010; Sun <i>et al.</i> , 2023; Younis; Kizhisseri; Mohamed, 2023; Zhou <i>et al.</i> , 2022)		X						
1 = precipitação, 2 = temperatura, 3 = umidade, 4 = evaporação, 5 = radiação solar, 6 = pressão, 7 = velocidade do vento e 8 = evapotranspiração								

Fonte: Elaborado pela autora (2025)

O clima e as condições meteorológicas desempenham um papel importante na demanda de água (Roushangar; Alizadeh, 2018). A forma com que as variáveis climáticas impactam o consumo de água está relacionada a fatores físicos. Barker *et al.* (2021) colocam que a demanda de água em habitações unifamiliares é mais sazonal e responde mais às condições climáticas do que a demanda em apartamentos e geminados, devido a fatores como a presença de áreas de jardim e piscinas. Ghavidelfar, Shamseldin e Melville (2017) observam que residências com maior renda

apresentam um aumento no consumo de água em 20% no verão, sendo que essas residências consomem mais água na área externa, principalmente devido à maior incidência de piscinas.

Aggarwal *et al.* (2012) exploraram como a urbanização, por meio de seu papel na evolução da Ilha de Calor Urbana, afeta o consumo residencial de água. No estudo, utilizaram-se dados temporais e foram analisadas como as variações na temperatura da superfície ao nível do setor censitário impactaram o uso de água em residências unifamiliares em Phoenix, Arizona (Aggarwal *et al.*, 2012). Os resultados mostram que cada aumento de um grau Fahrenheit na temperatura noturna eleva o consumo de água em 1,4% (Aggarwal *et al.*, 2012). Makpiboon (2020) analisou a relação entre a demanda de água urbana, a temperatura e a precipitação na região metropolitana da Tailândia. Os resultados indicam que o aumento de 1°C na temperatura causa o aumento em 1,52%, 1,87% e 2,38% na demanda de água nas escalas temporais diárias, mensais e sazonais, respectivamente (Makpiboon, 2020). O aumento em 10 mm/dia na precipitação causou diminuição de 0,017%, 0,018% e 0,219% na demanda de água nas escalas temporais diárias, mensais e sazonais, respectivamente (Makpiboon, 2020).

Johnson *et al.* (2023) investigaram o impacto de considerar as influências climáticas na demanda de água em sistemas municipais. Os autores concluíram que ignorar as influências climáticas gera erros e compromete a precisão da simulação do sistema (Johnson *et al.*, 2023). Em seu estudo, Roushangar e Alizadeh (2018) realizaram a previsão do consumo de água diário e concluíram que a temperatura alta e a baixa umidade relativa aumentam o consumo de água urbano. Com o objetivo de prever a demanda de água urbana a curto prazo, Zubaidi *et al.* (2018b) utilizaram dados de radiação solar, temperatura e evapotranspiração. O estudo apresentou melhores resultados para a previsão do consumo de água no período de inverno em que as variáveis meteorológicas apresentaram menor variabilidade (Zubaidi *et al.*, 2018b).

2.3.5 Fatores sociodemográficos

Com a revisão sistemática foi possível elencar as variáveis sociodemográficas mais recorrentes nos estudos. Essas variáveis incluem população, densidade

populacional, crescimento populacional, número de pessoas por residência, população urbana ou rural, nível de educação, idade e gênero (Tabela 5).

Tabela 5 – Artigos com variáveis sociodemográficas

Artigos	1	2	3	4	5	6	7	8
(Fontdecaba <i>et al.</i> , 2012)	X	X	X			X	X	X
(García-López; Montano, 2020)	X	X	X					
(Ou <i>et al.</i> , 2023)	X	X						
(Veiga; Kalbusch; Henning, 2023)	X			X				X
(Le <i>et al.</i> , 2022; Xiao-jun <i>et al.</i> , 2015; Zhao; Fan; Liang, 2017; Zubaidi <i>et al.</i> , 2020a)	X				X			
(Ashoori; Dzombak; Small, 2016; Balacco <i>et al.</i> , 2018, 2020; Blanc <i>et al.</i> , 2014; Breyer; Chang, 2014; Capt <i>et al.</i> , 2021; Chen <i>et al.</i> , 2021; Daw; Ali; Toriman, 2019; Du <i>et al.</i> , 2022; Fabre <i>et al.</i> , 2015; Graham <i>et al.</i> , 2018; He; Tao, 2014; He; Zhao; Wen, 2022; Huang <i>et al.</i> , 2014; Lawens; Mutsvangwa, 2018; Li; Yang; Tan, 2019; Liu; Zhao; Wang, 2015; Long <i>et al.</i> , 2022; Lu; Matthews; Han, 2020; Lü <i>et al.</i> , 2018; Lyu <i>et al.</i> , 2021; Mazzoni <i>et al.</i> , 2022; Mo <i>et al.</i> , 2024; Morain; Anandhi, 2022; Morote; Hernández, 2016; Msongaleli <i>et al.</i> , 2023, p. 1992–2029; Panagopoulos, 2014; Polidori; Paulson; Gronewold, 2024; Prasood <i>et al.</i> , 2021; Qi; Chang, 2011; Renzetti <i>et al.</i> , 2015; Romano; Salvati; Guerrini, 2014, 2016; Roushangar; Alizadeh, 2018; Shi <i>et al.</i> , 2023; Taştan, 2018; Toth; Bragalli; Neri, 2018; Vanham <i>et al.</i> , 2011; Wang <i>et al.</i> , 2024; Wang; Wang, 2020; Wang; Li, 2019; Wu; Liu; Deng, 2023; Wu; Wang; Dong, 2021; Wu; Meng, 2023; Xiangmei <i>et al.</i> , 2021; Xu <i>et al.</i> , 2022; Yan <i>et al.</i> , 2020; Yang; Chen, 2019; Yang <i>et al.</i> , 2016, 2022; Yilmaz, 2022; Yilmaz; Alpars, 2023; Younis; Kizhisseri; Mohamed, 2023; Zhang <i>et al.</i> , 2020, p. 2002–2017, 2018)	X							
(Sohn, 2011)		X	X				X	
(Wu <i>et al.</i> , 2016)		X	X					
(March; Perarnau; Saurí, 2012)		X		X			X	
(Ramos-Bueno; Perevochtchikova; Chang, 2021)		X		X				
(Dang; Li; Fan, 2022)		X			X	X		
(Nunes Carvalho; De Souza Filho; Porto, 2021)		X				X	X	X
(Connolly; Hagelman, 2015; Expósito; Pablo-Romero; Sánchez-Braza, 2019)		X				X	X	
(Fercovic; Foster; Melo, 2019)		X				X		

Artigos	1	2	3	4	5	6	7	8
(Anil Kumar; Ramachandran, 2019; Barker <i>et al.</i> , 2021; Deng <i>et al.</i> , 2021; Hao; Hu; Chen, 2019; Johnson <i>et al.</i> , 2023; Lee; Wentz; Gober, 2010; Medina-Rivas <i>et al.</i> , 2022; Panagopoulos <i>et al.</i> , 2012; Parkinson <i>et al.</i> , 2016; Song <i>et al.</i> , 2022; Tayebi <i>et al.</i> , 2022; Yuan <i>et al.</i> , 2024; Zhang <i>et al.</i> , 2019; Zhou; Su; Zhang, 2019)		X						
(Worland; Steinschneider; Hornberger, 2018)			X	X	X	X		
(Almutaz <i>et al.</i> , 2013)			X	X				
(Ahmad; Haie, 2018; Alnsour; Ijam, 2023; Garcia; Islam, 2018; Gebreyohannes Hiben; Gebeyehu Awoke; Adugna Ashenafi, 2024, 2024; Guo; Wang, 2023; Harma; Johnson; Cohen, 2012; Karahan; Elçi, 2023; Shabani; Gharnah; Niaki, 2020)			X					
(House-Peters; Pratt; Chang, 2010)				X		X	X	
(Acuña <i>et al.</i> , 2020; Maldonado-Devis <i>et al.</i> , 2021; Sun <i>et al.</i> , 2023; Villarín, 2019)				X			X	
(Almutaz <i>et al.</i> , 2012; Ghavidelfar; Shamseldin; Melville, 2016, 2017, 2018; Long <i>et al.</i> , 2019; Maldonado-Devis; Almenar-Llongo, 2021; Polebitski; Palmer; Waddell, 2011; Telfah; Jaradat; Ismail, 2024)				X				
(Sankarasubramanian <i>et al.</i> , 2017)					X	X		
(Bao; Xu, 2023; Guo <i>et al.</i> , 2013, p. 1985–2009; Li; Huicheng, 2010; Ramos Filho <i>et al.</i> , 2023)					X			
(Fan <i>et al.</i> , 2017; Shandas; Parandvash, 2010)						X		
(Baigorri; Montañés; Simón-Fernández, 2022; Stoker <i>et al.</i> , 2019b)							X	
(Sousa; Teixeira; Fouto, 2022)								X

1 = população, 2 = densidade populacional, 3 = crescimento populacional, 4 = número de pessoas por residência, 5 = população urbana ou rural, 6 = nível de educação, 7 = idade, 8 = gênero

Fonte: Elaborado pela autora (2025)

Garcia e Islam (2018) colocam que a densidade populacional é determinada pelo tamanho de lote e do tamanho da residência. A relação entre tamanho de lote e consumo de água *per capita* e tamanho da residência e consumo de água *per capita* indicam que quanto maior a densidade populacional, menor o consumo de água *per capita* (Garcia; Islam, 2018). Em um estudo em Sydney, Austrália, Barker *et al.* (2021) estimam o consumo futuro de água, examinando se as tendências futuras refletem mudanças populacionais e/ou climáticas. Os resultados indicam que o crescimento populacional é o principal fator de aumento da demanda de água, com um incremento de 11,2% por década, enquanto as mudanças climáticas contribuem com impacto menor, variando entre 0,4 e 0,5% por década (Barker *et al.*, 2021).

Na revisão sistemática, foram encontrados diversos estudos que avaliam como o número de pessoas por residência impacta o consumo de água. Cada pessoa adicional em uma residência implicou em consumo adicional de 7,2% no consumo doméstico (Maldonado-Devis; Almenar-Llongo, 2021). No estudo de Ghavidelfar, Shamseldin e Melville (2017), o aumento de 10% no número de pessoas em uma residência resulta em um aumento de 3,6% no consumo de água residencial. Veiga, Kalbusch e Henning (2023) estudaram o consumo de água *per capita* de forma transversal em 1746 municípios do Brasil e encontraram que o consumo de água *per capita* diminui com o aumento do número de residentes por habitação. Segundo Veiga, Kalbusch e Henning (2023), o consumo *per capita* de água diminui pois diversos usos da água, como lavar roupa, limpar a casa, cuidar do jardim e até cozinhar, são atividades compartilhadas.

Com relação à faixa etária da população, Sun *et al.* (2023) colocam que há um efeito da composição familiar sobre o nível de consumo doméstico de água, uma vez que quanto maior o número de idosos e crianças na família, menor é o consumo de água. Por outro lado, o estudo de Expósito, Pablo-Romero e Sánchez-Braza (2019) conclui que a idade da população tem impacto de redução no uso de água residencial e de serviços. Em relação ao nível educacional da população, pessoas com níveis educacionais mais altos tendem a apresentar consumo de água menor, pois o nível de educação geralmente está relacionado a preocupações e atitudes ambientais (Expósito; Pablo-Romero; Sánchez-Braza, 2019).

2.3.6 Fatores econômicos

A revisão sistemática permitiu identificar as variáveis econômicas mais frequentes nos artigos selecionados. Essas variáveis incluem renda, PIB, participação setorial na economia e preço da água (Tabela 6).

Tabela 6 – Artigos com variáveis econômicas

Artigo	1	2	3	4
(Huang <i>et al.</i> , 2014)	X	X	X	X
(Ou <i>et al.</i> , 2023)	X	X	X	
(Veiga; Kalbusch; Henning, 2023; Dang; Li; Fan, 2022; He; Tao, 2014; Long <i>et al.</i> , 2019; Shi <i>et al.</i> , 2023; Wang <i>et al.</i> , 2024; Xiao-jun <i>et al.</i> , 2015; Zhou; Su; Zhang, 2019)	X	X		
(Acuña <i>et al.</i> , 2020; Aggarwal <i>et al.</i> , 2012; Ashoori; Dzombak; Small, 2016; Baigorri; Montañés; Simón-Fernández, 2022; Daw; Ali; Toriman, 2019; Fercovic; Foster; Melo, 2019; García-López; Montano, 2020; Ghavidelfar; Shamseldin; Melville, 2016, 2017; Liu; Zhao; Wang, 2015; Maldonado-Devis <i>et al.</i> , 2021; Maldonado-Devis; Almenar-Llongo, 2021; Namdari; Ashrafi; Haghighi, 2024; O'Donnell; Berrens, 2018; Panagopoulos, 2014; Polebitski; Palmer; Waddell, 2011; Renzetti <i>et al.</i> , 2015; Romano; Salvati; Guerrini, 2014, 2016; Sebri, 2014; Sohn, 2011; Worland; Steinschneider; Hornberger, 2018)	X			X
(Almutaz <i>et al.</i> , 2012, 2013; Alnsour; Ijam, 2023; Chen <i>et al.</i> , 2021; Connolly; Hagelman, 2015; Expósito; Pablo-Romero; Sánchez-Braza, 2019; Fontdecaba <i>et al.</i> , 2012; Ghavidelfar; Shamseldin; Melville, 2018; House-Peters; Pratt; Chang, 2010; Lins <i>et al.</i> , 2010; March; Perarnau; Saurí, 2012; Nunes Carvalho; De Souza Filho; Porto, 2021; Ouyang <i>et al.</i> , 2014; Parkinson <i>et al.</i> , 2016; Polidori; Paulson; Gronewold, 2024; Qi; Chang, 2011; Sankarasubramanian <i>et al.</i> , 2017; Shandas; Parandvash, 2010; Sousa; Teixeira; Fouto, 2022; Yilmaz, 2022; Yilmaz; Alpars, 2023)	X			
(Graham <i>et al.</i> , 2018)		X		X
(Balata; Pinto; Silva, 2022; Blanc <i>et al.</i> , 2014; Deng <i>et al.</i> , 2021; Ding <i>et al.</i> , 2019; Du <i>et al.</i> , 2022; Fan <i>et al.</i> , 2017; Guo; Wang, 2023; Hao; Hu; Chen, 2019; Le <i>et al.</i> , 2022; Li; Huicheng, 2010; Long <i>et al.</i> , 2022; Lü <i>et al.</i> , 2018; Lyu <i>et al.</i> , 2021; Roushangar; Alizadeh, 2018; Song <i>et al.</i> , 2022; Telfah; Jaradat; Ismail, 2024; Wang; Li, 2019; Wu; Wang; Dong, 2021; Xiangmei <i>et al.</i> , 2021; Yang; Chen, 2019; Yang <i>et al.</i> , 2016, 2022; Yuan <i>et al.</i> , 2024; Zhao; Fan; Liang, 2017)		X		
(Zhang <i>et al.</i> , 2018)			X	X
(Bao; Xu, 2023; Guo <i>et al.</i> , 2013, p. 1985–2009; Hao; Hu; Chen, 2019; He; Zhao; Wen, 2022; Le <i>et al.</i> , 2022; Li; Yang; Tan, 2019; Mo <i>et al.</i> , 2024; Wu; Wang; Dong, 2021; Wu; Meng, 2023; Yan <i>et al.</i> , 2020; Yang; Chen, 2019; Yang <i>et al.</i> , 2016, 2022; Zhao; Fan; Liang, 2017; Zubaidi <i>et al.</i> , 2020a)			X	
(Alamanos, 2021; Ashoori; Dzombak; Small, 2017; Barker <i>et al.</i> , 2021; Garcia; Islam, 2018; Graham <i>et al.</i> , 2018; Haque <i>et al.</i> , 2018, 2015; Klaiber <i>et al.</i> , 2014; Reynaud; Pons; Pesado, 2018; Taştan, 2018; Toth; Bragalli; Neri, 2018; Zhang <i>et al.</i> , 2018)				X

1 = renda, 2 = PIB, 3 = participação setorial na economia, 4 = preço da água

Fonte: Elaborado pela autora (2025)

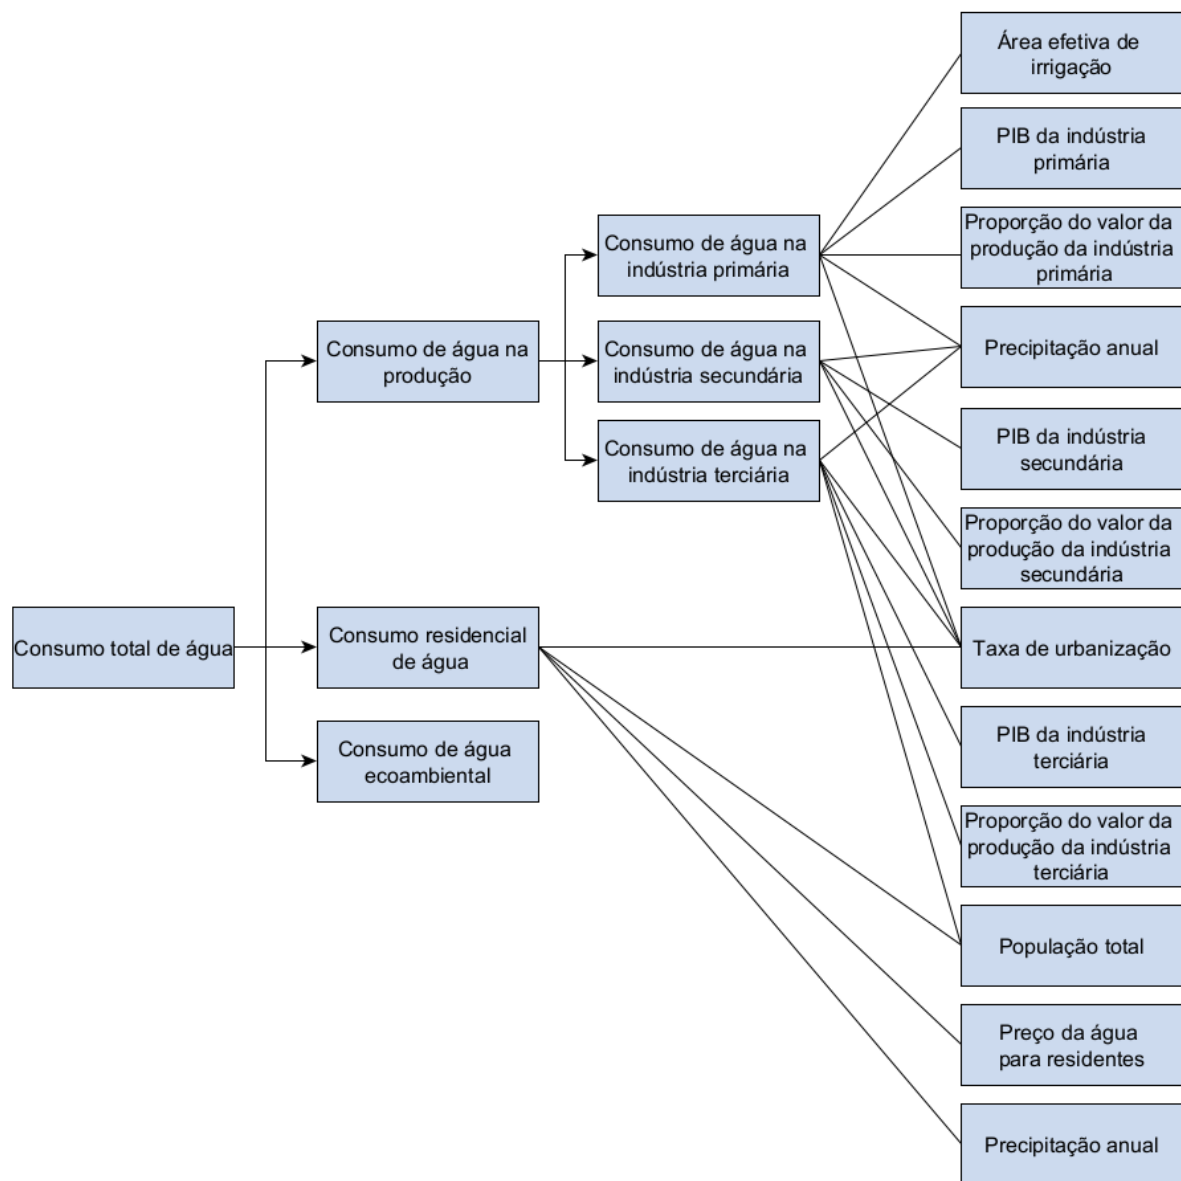
O uso da água e o desenvolvimento socioeconômico estão interconectados, e sua relação é complexa (Balata; Pinto; Silva, 2022). A renda *per capita* desempenha um papel importante na determinação do consumo de água, influenciando tanto a demanda quanto o padrão de uso em diferentes contextos socioeconômicos. Segundo Fontdecaba *et al.* (2012) grupos com menor renda *per capita* apresentam menor consumo de água e grupos com maior renda *per capita* apresentam maior consumo de água. Os resultados do estudo de Ghavidelfar, Shamseldin e Melville (2017) indicaram que os subúrbios de baixa e alta renda apresentam maior consumo de água por domicílio em comparação com áreas de renda média. A diferença se deve, em parte, à maior demanda de água externa nas áreas de alta renda (13,4% com presença de piscinas) e ao maior uso de água interna nas áreas de baixa renda (número médio de pessoas por residência é de 4,1, enquanto em áreas de alta e média renda são 3,1 pessoas por residência) (Ghavidelfar; Shamseldin; Melville, 2017). Embora os subúrbios de baixa renda tenham maior consumo por domicílio, o consumo *per capita* é semelhante ao das áreas de renda média (Ghavidelfar; Shamseldin; Melville, 2017). Em contraste, as áreas de alta renda têm o maior consumo *per capita*, com uma média de 196 litros/pessoa/dia (Ghavidelfar; Shamseldin; Melville, 2017).

No estudo de Expósito, Pablo-Romero e Sánchez-Braza (2019) a renda foi identificada como o principal fator com efeito positivo sobre o consumo de água urbano, com uma elasticidade crescente em relação à renda. Por conseguinte, espera-se que, à medida que os municípios enriquecem, o consumo de água aumente (Expósito; Pablo-Romero; Sánchez-Braza, 2019). Fan *et al.* (2017) estudaram o consumo de água urbano em 286 cidades da China. Os resultados indicaram que cidades que apresentam alto PIB *per capita* apresentaram maior consumo de água *per capita*. Segundo Fan *et al.* (2017) isso ocorre porque as residências dessas cidades apresentam mais equipamentos consumidores de água e são menos sensíveis ao preço da água. Com relação ao preço da água, diversos estudos analisam a sua elasticidade com relação ao consumo de água. Reynaud, Pons e Pesado (2018) colocam que diante a um aumento de preço de 10%, os domicílios reagirão em curto prazo reduzindo o consumo de água em 7%.

O consumo de água é influenciado pelo nível econômico da cidade (Dang; Li; Fan, 2022). Zhang *et al.* (2018) analisaram os fatores externos no uso da água e

separaram o consumo em três principais categorias (Figura 6). Utilizando o método de processo de análise hierárquica foi possível estabelecer a estrutura hierárquica do consumo de água (Zhang *et al.*, 2018). Entre os resultados obtidos, Zhang *et al.* (2018) encontraram que o aumento do PIB da indústria primária, secundária e terciária significa que a expansão da escala industrial requer o consumo de mais recursos hídricos.

Figura 6 - Estrutura hierárquica do consumo de água e dos indicadores socioeconômicos relacionados



Fonte: Adaptado de Zhang *et al.* (2018)

2.4 CONSIDERAÇÕES FINAIS DA REVISÃO SISTEMÁTICA

A revisão sistemática da literatura, baseada na análise de artigos das bases Scopus e WoS, demonstra que os estudos sobre o consumo de água em escala macro investigam uma diversidade de fatores. Entre os fatores físicos, destacam-se o uso do solo, urbanização, caracterização urbana, densidade de construções e caracterização dos domicílios. Os fatores climáticos incluem variáveis como precipitação, temperatura, umidade, evaporação, radiação solar, pressão, velocidade do vento e evapotranspiração. No âmbito sociodemográfico, são analisados elementos como população, densidade populacional, crescimento populacional, número de pessoas por residência, população urbana ou rural, nível de educação, idade e gênero. Em termos econômicos, os principais fatores investigados incluem renda, PIB, participação setorial na economia e o preço da água.

Os modelos estatísticos utilizados para avaliar esses fatores e prever a demanda de água variam amplamente, abrangendo regressões lineares, regressão espacial, modelos em painel e de séries temporais. Na revisão, foi possível identificar artigos que empregam técnicas de aprendizado em máquina e algoritmos de otimização, refletindo a pluralidade de abordagens metodológicas. A escolha do modelo mais adequado depende da natureza dos dados disponíveis e da escala de análise, permitindo uma adaptação das metodologias às particularidades de cada estudo.

3 MÉTODO

Este capítulo contém os procedimentos metodológicos utilizados para o alcance dos objetivos deste trabalho, que tem como área de estudo os municípios de Santa Catarina. O período de análise selecionado (2011-2021) foi definido com base na disponibilidade de dados de consumo de água *per capita* para esses municípios. As variáveis selecionadas fundamentam-se na revisão sistemática da literatura. A partir das variáveis identificadas na revisão, foram coletadas aquelas disponíveis para a área e o período de estudo. A Tabela 7 apresenta as variáveis estudadas.

Tabela 7 - Variáveis utilizadas no estudo

Variável	Descrição	Unidade	Fonte
Consumo de água <i>per capita</i>	Consumo de água <i>per capita</i> anual para cada município	litro/hab./dia	SNIS
Temperatura média	Temperatura média municipal anual	°C	ERA5-Land
Precipitação	Precipitação média diária	mm	ERA5
Valor adicionado industrial <i>per capita</i>	Valor adicionado pelas atividades que compõem o setor industrial para cada município anualmente	R\$/hab.	SEF-SC
Valor adicionado serviço <i>per capita</i>	Valor adicionado pelas atividades que compõem o setor de serviço para cada município anualmente	R\$/hab.	SEF-SC
Valor adicionado comércio <i>per capita</i>	Valor adicionado pelas atividades que compõem o setor de comércio para cada município anualmente	R\$/hab.	SEF-SC
PIB <i>per capita</i>	Produto interno bruto medido anualmente para cada município	R\$/hab.	IBGE
População	População municipal anual	hab.	IBGE
Floresta	Classificação do uso do solo como florestal medido anualmente para cada município	km ²	MapBiomias
Formação natural não florestal	Classificação do uso do solo como formação natural não florestal medido anualmente para cada município	km ²	MapBiomias
Agropecuária	Classificação do uso do solo como agropecuária medido anualmente para cada município	km ²	MapBiomias

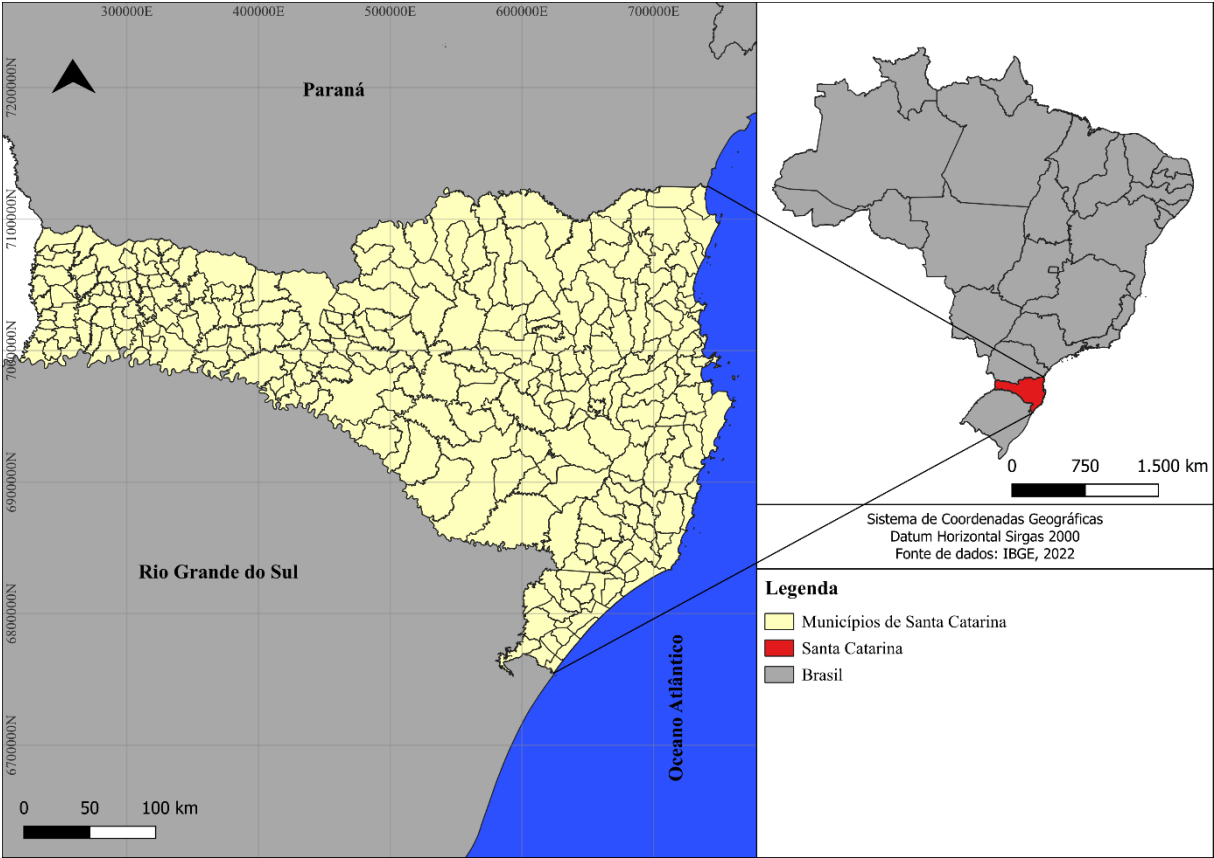
Variável	Descrição	Unidade	Fonte
Área urbanizada	Classificação do uso do solo como área urbanizada medido anualmente para cada município	km²	MapBiomias
Corpo d'água	Classificação do uso do solo como corpo d'água medido anualmente para cada município	km²	MapBiomias
Área não vegetada	Classificação do uso do solo como área não vegetada excluindo a área urbanizada medido anualmente para cada município	km²	MapBiomias

Fonte: Elaborado pela autora (2025)

3.1 ÁREA DE ESTUDO

Este trabalho teve como área de estudo os municípios do estado de Santa Catarina (Figura 7). O estado está localizado na região sul do Brasil, possui área 95.730,69 km² e 295 municípios, sua população é de 7.610.361 habitantes (IBGE, 2022c).

Figura 7 - Localização da área de estudo

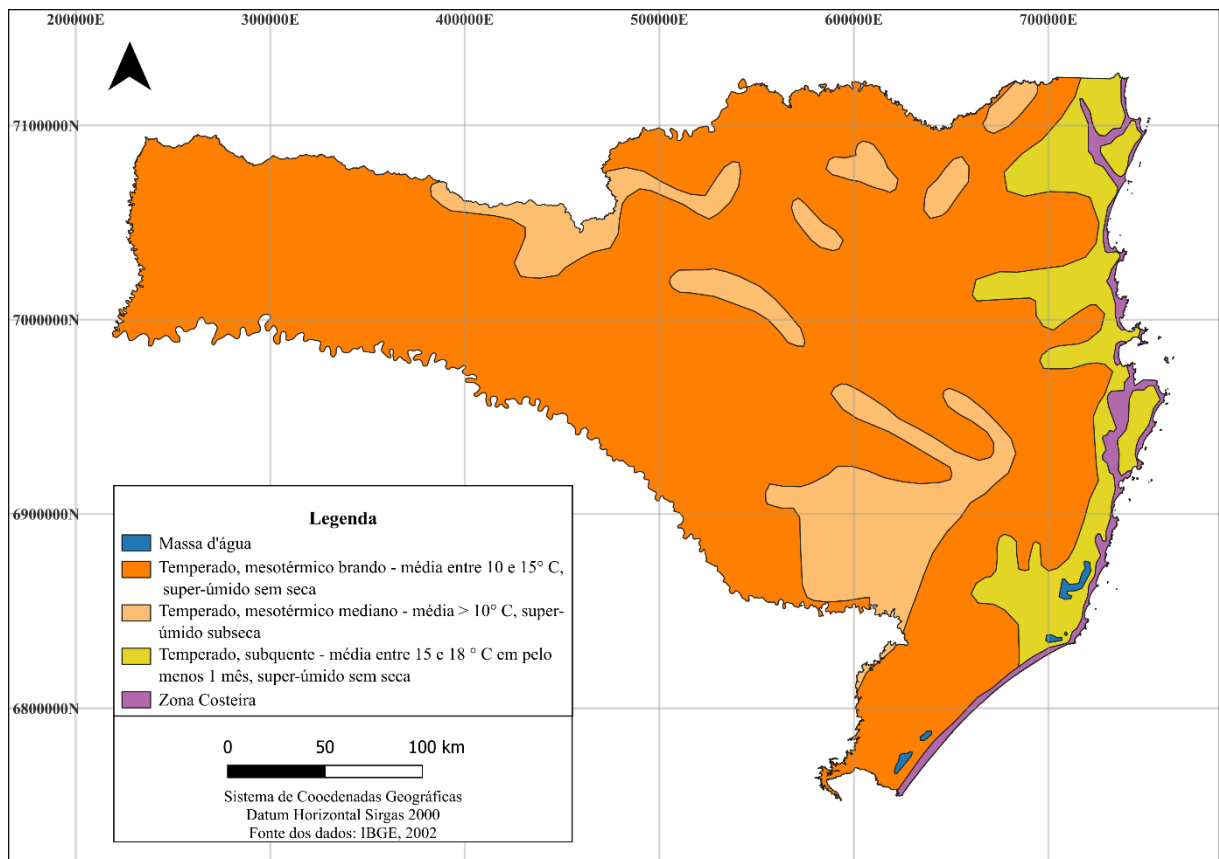


Fonte: Elaborado pela autora com dados do IBGE (2022a)

3.1.1 Caracterização climática

O Estado de Santa Catarina apresenta características térmicas das mais amenas do Brasil, pela classificação de Köeppen, é classificada com clima mesotérmico úmido (sem estação seca) Cf, compreendendo dois subtipos, Cfa e Cfb, distintos em verão quente e verão fresco, respectivamente (Braga; Ghellre, 1999). A classificação de zonas climáticas apresentada pelo IBGE (2002) divide Santa Catarina em três tipos de clima temperado conforme a Figura 8.

Figura 8 - Zonas climáticas de Santa Catarina



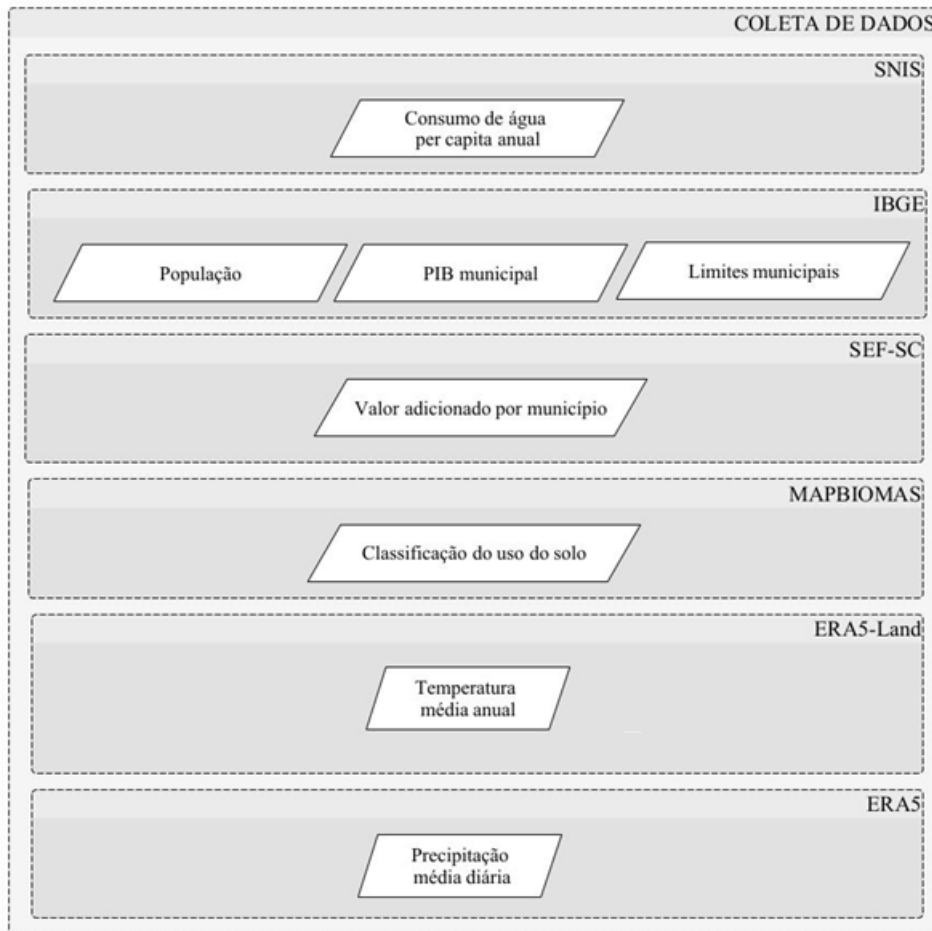
Fonte: Elaborado pela autora com dados do IBGE (2002)

3.2 COLETA E PROCESSAMENTO DE DADOS

Nesta pesquisa, serão utilizados dados em painel, que combinam elementos de séries temporais e dados em corte transversal. Isso permitirá analisar as variáveis climáticas, classificação do uso do solo, dados econômicos, sociodemográficos e consumo de água *per capita* na dimensão temporal, e na dimensão transversal serão

incluídos os municípios de Santa Catarina, conforme a Figura 9. A combinação dessas dimensões permitirá comparar municípios entre si em um dado ano, bem como observar as mudanças para cada município ao longo do tempo.

Figura 9 - Diagrama de coleta de dados



Fonte: Elaborado pela autora (2025)

3.2.1 Dados de consumo de água

Neste estudo, foram utilizados dados de consumo de água *per capita* anual de cada município de Santa Catarina, coletados do Sistema Nacional de Informações sobre Saneamento (SNIS). O consumo médio *per capita* de água (IN022) (litros/hab./dia) é calculado utilizando a Equação 1 (SNIS, 2024).

$$\text{Consumo médio per capita de água} = \frac{AG10-AG019}{AG001} \times \frac{1000000}{365} \quad (1)$$

em que AG001 é a população total atendida com abastecimento de água, medida em número de habitantes (hab.). AG010 é o volume de água consumido, que representa o volume anual de água consumido por todos os usuários (1000 m³/ano). Este valor inclui o volume micromedido, consumo estimado para ligações sem hidrômetro ou com hidrômetro parado, e o volume de água tratada exportado para outro prestador de serviços (AG019). AG019 (1000 m³/ano) é o volume de água tratada exportado, que se refere ao volume anual de água potável transferido para outros distribuidores. Esse volume é computado no volume de água consumido (AG010).

O SNIS utiliza essas informações para obter o consumo médio diário de água por habitante, expresso em litros por habitante por dia (litros/hab./dia). O cálculo leva em consideração o volume de água efetivamente consumido, excluindo o volume exportado, e a população atendida com abastecimento de água. O consumo médio *per capita* de água (IN022) é a média diária, por indivíduo, dos volumes utilizados para satisfazer os consumos domésticos, comercial, público e industrial (Brasil; Ministério do Desenvolvimento Regional; Secretaria Nacional de Saneamento – SNS, 2020). É uma informação importante para as projeções de demanda, para o dimensionamento de sistemas de água e de esgotos e para o controle operacional (Brasil; Ministério do Desenvolvimento Regional; Secretaria Nacional de Saneamento, 2020).

3.2.2 Dados econômicos

Os dados de PIB anual por município foram obtidos junto ao IBGE para o período em estudo (IBGE, 2022b). O PIB mede a produção de bens e serviços, dentro das fronteiras, em um determinado intervalo de tempo (Froyen, 2015). A disponibilidade desses dados em nível municipal permite uma análise do desenvolvimento econômico municipal em Santa Catarina.

Além do PIB, foram coletados dados sobre o Valor Adicionado por Município, disponibilizados pela Secretaria da Fazenda do Estado de Santa Catarina (SEF-SC). O Valor Adicionado municipal é apurado anualmente para fins tributários conforme a legislação (Brasil, 1990). Conforme Santa Catarina (2012) o valor adicionado tem como base o movimento econômico municipal. Os dados de valor adicionado são fornecidos pela SEF-SC para cada município no período de estudo com a classificação da atividade econômica conforme a Classificação Nacional de Atividade Econômica (CNAE) (SEF/SC, 2016). Estes dados são úteis para identificar quais

setores econômicos são mais proeminentes em cada município. A correção monetária do Valor Adicionado e do PIB foi feita com base no IGP-DI, que é o Índice Geral de Preços – Disponibilidade interna. O IGP é composto por três índices: o Índice de Preços ao Produtor Amplo (IPA) (60%), o Índice de Preços ao Consumidor (IPC) (30%) e pelo Índice Nacional de Custo da Construção (INCC) (10%) (Fundação Getúlio Vargas, 2020).

3.2.3 Dados de classificação do uso do solo

Os algoritmos de processamento digital de imagens usados para extrair informações dos dados de sensores remotos estão em constante evolução, o que resulta em um aumento na capacidade de extrair dados biofísicos quantitativos (temperatura, biomassa, precipitação) e informações sobre o uso/cobertura do solo a partir dos dados de sensores remotos (Jensen, 2005). Informações explícitas sobre as trajetórias históricas de uso e cobertura do solo no Brasil são essenciais para informar o planejamento e a gestão sustentável dos recursos naturais, a formulação de políticas, entre outras aplicações sociais (Souza *et al.*, 2020).

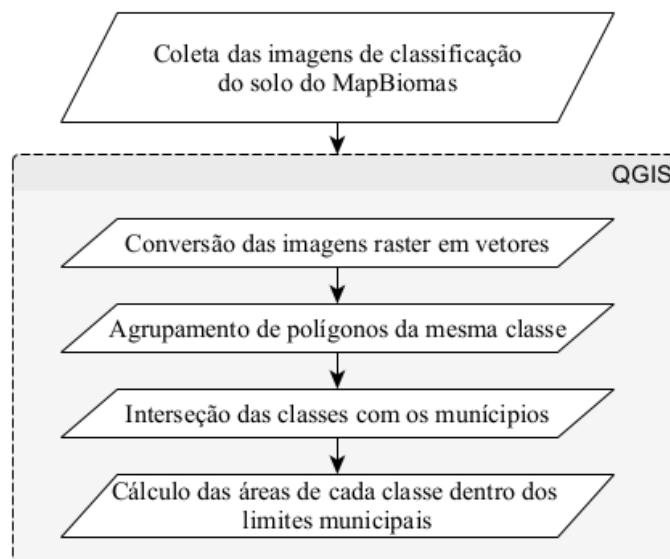
O MapBiomas é uma iniciativa do Sistema de Estimativas de Emissões de Gases de Efeito Estufa do Observatório do Clima produzido por uma rede colaborativa formada por ONGs, universidades e empresas de tecnologia (MapBiomas, 2024a). O MapBiomas realiza anualmente o mapeamento da cobertura e do uso da terra.

A metodologia do MapBiomas (2024b) envolve o uso de imagens de satélite *Landsat*, com resolução espacial de 30 metros, disponíveis na plataforma *Google Earth Engine* (GEE), para mapear a cobertura e uso da terra no Brasil ao longo de mais de 30 anos. Essas imagens são processadas para remover nuvens e outros ruídos, gerando mosaicos anuais que representam o comportamento de cada pixel com até 105 camadas de informações, eles são usados para classificar a cobertura e o uso da terra utilizando o algoritmo de Aprendizado de Máquina (*Machine Learning*) denominado Florestas Aleatórias (*Random Forest*), treinado com amostras obtidas de mapas de referência e interpretação visual (MapBiomas, 2024c). Os mapas resultantes são integrados em um único mapa para cada ano, representando a cobertura e uso da terra em todo o território.

Para o desenvolvimento deste trabalho, optou-se por utilizar a coleção 8, que contém a classificação do solo com imagens do satélite *Landsat*, pois a coleção com

o satélite *Sentinel* inicia apenas a partir de 2016. As imagens de classificação foram coletadas para o período de estudo. Para extração das áreas de cada classe foi utilizado o software QGIS 3.32.1. A Figura 10 apresenta a metodologia utilizada para obter as áreas de cada classe de uso do solo para cada município de Santa Catarina para o período estudado.

Figura 10 - Diagrama de procedimentos para classificação do uso do solo



Fonte: Elaborado pela autora (2025)

As classes de uso e cobertura da terra presentes no estado de Santa Catarina estão detalhadas na Tabela 8. Essas classes abrangem diversas formações naturais, agropecuárias, áreas não vegetadas e corpos d'água, cada uma com suas subcategorias e descrições específicas.

Tabela 8 - Classes da classificação do uso do solo

Classe	Subclasse	Descrição
Floresta	Formação florestal	Bioma Mata atlântica: floresta Ombrófila Densa, Aberta e Mista e Floresta Estacional Semi-Decidual, Floresta Estacional Decidual e Formação Pioneira Arbórea.
	Mangue	Formações florestais, densas, sempre-verdes, frequentemente inundadas pela maré e associadas ao ecossistema costeiro de Manguezal.

Classe	Subclasse	Descrição
	Restinga arbórea	Mata Atlântica: formações florestais que se estabelecem sobre solos arenosos ou sobre dunas na zona costeira.
Formação natural não florestal	Campo alagado e área pantanosa	Mata Atlântica: vegetação com influência fluvial e/ou lacustre.
	Formação campestre	Mata Atlântica: savanas-Estépicas Parque e Gramíneo-Lenhosa, Estepe e Pioneiras Arbustivas e Herbáceas
	Apicum	Apicuns ou Salgados são formações quase sempre desprovidas de vegetação arbórea, associadas a uma zona mais alta, hipersalina e menos inundada do manguezal, em geral na transição entre este e a terra firme.
	Afloramento rochoso	Mata Atlântica: rochas naturalmente expostas na superfície terrestre sem cobertura de solo, muitas vezes com presença parcial de vegetação rupícola e alta declividade.
	Restinga herbácea	Mata Atlântica: vegetação herbácea com influência fluviomarinha.
Agropecuária	Pastagem	Áreas de pastagem predominantemente plantadas, diretamente relacionadas à atividade agropecuária. As áreas de pastagem natural, por sua vez, são predominantemente caracterizadas como formações campestres ou campo alagado, podendo ser submetidas ou não a práticas de pastejo.
	Silvicultura	Espécies arbóreas plantadas para fins comerciais (ex. pinus, eucalipto, araucária).
	Soja	Áreas cultivadas com a cultura da soja.
	Arroz	Áreas cultivadas com cultura de arroz, exclusivamente sob sistema de irrigação, nos estados do Rio Grande do Sul, Tocantins, Santa Catarina e Litoral do Paraná.

Classe	Subclasse	Descrição
	Outras lavouras temporárias	Áreas ocupadas com cultivos agrícolas de curta ou média duração, geralmente com ciclo vegetativo inferior a um ano, que após a colheita necessitam de novo plantio para produzir.
	Mosaicos de uso	Mata Atlântica: áreas de uso agropecuário onde não foi possível distinguir entre pastagem e agricultura.
Área não vegetada	Praia, duna e areal	Cordões arenosos, de coloração branco brilhante, onde não há o predomínio de vegetação de nenhum tipo.
	Área urbanizada	Áreas com significativa densidade de edificações e vias, incluindo áreas livres de construções e infraestrutura.
	Outras áreas não vegetadas	Mata Atlântica: áreas de superfícies não permeáveis (infra-estrutura, expansão urbana ou mineração) não mapeadas em suas classes.
	Mineração	Áreas referentes a extração mineral de porte industrial ou artesanal (garimpos), havendo clara exposição do solo por ação por ação antrópica.
Corpo d'água	Aquicultura	Área referente a lagos artificiais, onde predominam atividades aquícolas e/ou de salicultura.
	Rio, lago e oceano	Rios, lagos, represas, reservatórios e outros corpos d'água.

Fonte: Adaptado de MapBiomias, 2024d

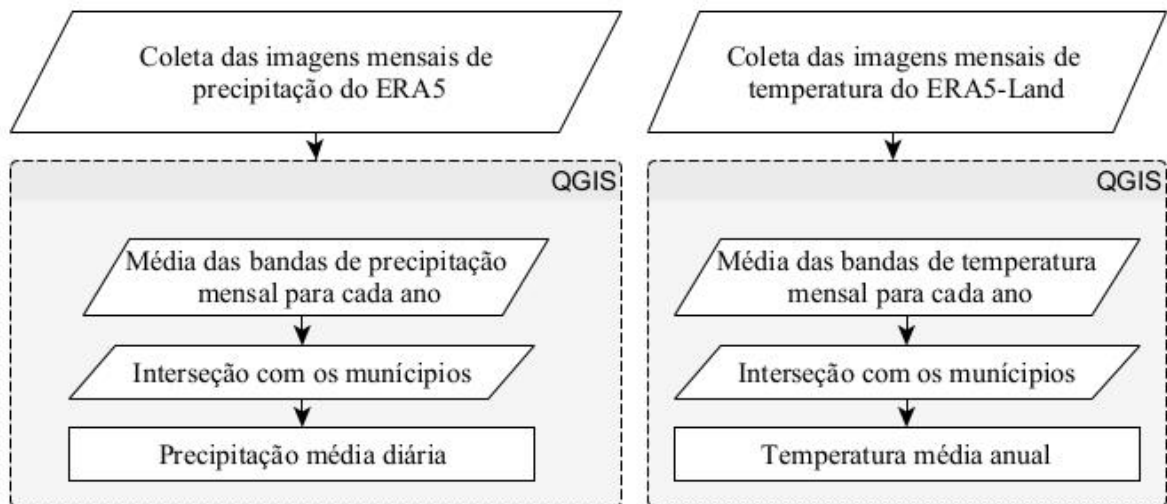
3.2.4 Dados climáticos

Neste estudo, foram utilizados dados de temperatura extraídos do conjunto de dados ERA5-Land e dados de precipitação provenientes do conjunto ERA5. O ERA5-Land foi produzido reproduzindo o componente terrestre da reanálise climática do ERA5 do Centro Europeu de Previsões Meteorológicas de Médio Prazo (ECMWF) (Muñoz Sabater, 2019). A reanálise combina dados de modelos com observações de todo o mundo em um conjunto de dados completo e consistente, utilizando as leis da

física (Muñoz Sabater, 2019). A reanálise produz dados que retrocedem várias décadas, fornecendo descrição precisa do clima do passado (Muñoz Sabater, 2019).

Para o estado de Santa Catarina, foram coletadas camadas *raster* mensais de temperatura do ar a 2 metros de altura e precipitação diária mensal média, conforme Figura 11. Foram obtidos dados mensais, com uma resolução espacial de $0,1^\circ \times 0,1^\circ$ (9 km x 9 km) para temperatura e de $0,25^\circ \times 0,25^\circ$ (28 km x 28 km) para precipitação. Para a análise da temperatura média anual, foram calculadas as médias das bandas de temperatura mensal para cada ano. Para a precipitação média diária foi calculada a média das bandas mensais de precipitação média diária.

Figura 11 - Diagrama de coleta de dados climáticos



Fonte: Elaborado pela autora (2025)

3.3 ANÁLISE ESTATÍSTICA

A análise estatística empregada no trabalho consiste em realizar análise descritiva e espacial das variáveis e aplicar métodos de regressão para dados em painel.

3.3.1 Análise descritiva

Primeiramente, foi realizada análise exploratória dos dados coletados. A análise foi realizada com gráficos, mapas temáticos e dados numéricos com sumário

estatístico para cada variável. O sumário estatístico contém as seguintes medidas descritivas: média, mediana, mínimo, máximo e desvio padrão.

A análise descritiva espacial foi conduzida por meio da criação de mapas utilizando o software GeoDa (Anselin; Syabri; Kho, 2006). Para esta análise, foi considerada a média do período de estudo das variáveis econômicas, sociodemográficas, climáticas e de classificação do uso do solo. Os mapas gerados são do tipo box e de quebras naturais. O mapa box é o correspondente cartográfico de um boxplot, possuindo 6 categorias (*outlier*¹ inferior, <25%, 25%-50%, 50%-75%, >75% e *outlier* superior) (Anselin, 2023). A definição de *outliers* é determinada por um múltiplo da amplitude interquartil (IQR), que é a diferença entre os valores dos percentis 75 e 25 (Anselin, 2023). Como é habitual, existem duas opções para os valores de corte, conhecidos como *hinges*, em um boxplot: 1,5 e 3,0 (Anselin, 2023). Para a definição de *outliers*, foi escolhido o valor de corte de 1,5. Para o mapa de quebras naturais, o GeoDa utiliza um algoritmo de agrupamento para determinar os pontos de quebra que resultam em grupos com menor variância interna (Anselin, 2023).

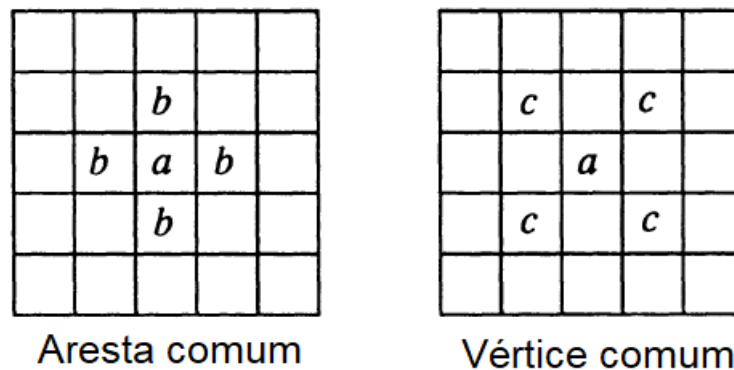
As ferramentas de autocorrelação espacial testam se o valor observado de uma variável em uma localidade é independente dos valores da mesma variável nas localidades vizinhas (Mathur, 2015). A autocorrelação espacial das variáveis foi medida utilizando o índice de Moran. A estatística de Moran é o indicador mais comumente utilizado de autocorrelação global (Anselin, 2023). O cálculo do índice de Moran é realizado pela divisão da covariação espacial pela variação total, e os valores resultantes variam de -1 a 1 (Mathur, 2015). A hipótese nula do índice de Moran é que o atributo analisado distribui-se aleatoriamente entre as feições da área de estudo (Mathur, 2015). Quando o p-valor é muito pequeno a hipótese nula é rejeitada, o que significa que é muito improvável (pequena probabilidade) que o padrão espacial observado seja o resultado de processos aleatórios (Mathur, 2015).

A consideração das relações espaciais entre as unidades é definida pelo peso espacial. Considerando uma grade regular (Figura 12), uma borda comum entre a célula “a” e as células circundantes pode ser considerada de várias maneiras (Anselin, 1988). Pode ser considerada uma aresta comum, com as células rotuladas de “b” como contíguas, ou um vértice comum poderia ser considerado, com células rotuladas

¹ *Outlier* significa ponto discrepante/espúrio. Neste trabalho será adotado o termo em inglês.

de “c” como contíguas, ou uma combinação dos dois poderia ser utilizada (Anselin, 1988). Em analogia com o jogo de xadrez, essas situações foram chamadas de caso da torre (*rook case*) (apenas arestas são consideradas), caso do bispo (*bishop case*) (apenas vértices são considerados) e caso da rainha (*queen case*) (arestas e vértices são considerados) (Anselin, 1988).

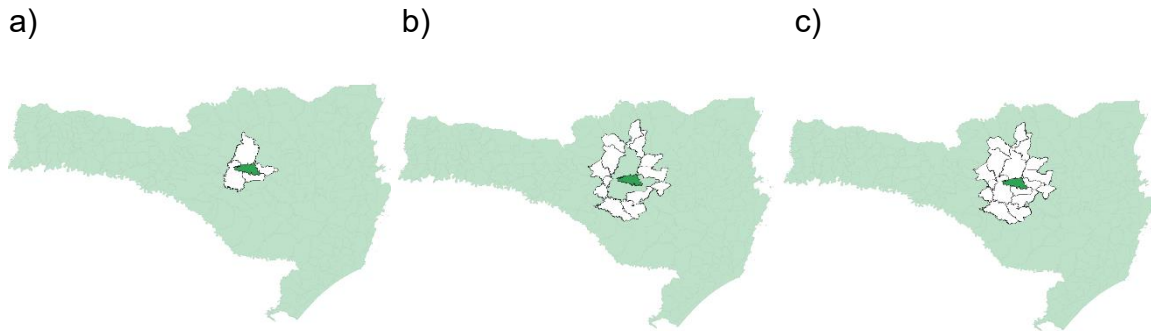
Figura 12 - Contiguidade em uma rede regular



Fonte: Adaptado e traduzido de Anselin (1988)

Quando as unidades espaciais são pontos, a contiguidade pode ser entendida como o caminho mais curto em uma rede formada por esses pontos, e os nós são considerados vizinhos se estiverem dentro de uma distância máxima entre si (Anselin, 1988). Alternativamente, a contiguidade pode ser determinada pelas fronteiras das tesselações espaciais, que dividem o espaço em polígonos ou células relacionadas à localização dos pontos (Anselin, 1988). Assim, a representação original das unidades espaciais como pontos é substituída por um mapa de polígonos, no qual a contiguidade é avaliada de maneira convencional (Anselin, 1988). Há diferentes ordens de contiguidade que podem ser consideradas em um peso espacial. A contiguidade é de k-ésima ordem quando as unidades espaciais são contíguas de primeira ordem a uma unidade espacial contígua de (k-1)-ésima ordem, e não contíguas de uma ordem menor (Anselin, 1988). Exemplos de diferentes ordens de contiguidade podem ser observadas na Figura 13. Os exemplos se referem a *queen* de primeira ordem (a), *queen* de segunda ordem (b) e *queen* de segunda ordem com inclusão de ordens inferiores (c).

Figura 13 - Ordem de contiguidade



Fonte: Elaborado pela autora (2025)

O trabalho utilizou em suas análises o peso espacial *queen* de primeira ordem considerando as cidades como polígonos.

3.3.2 Regressão em painel

Os dados de painel oferecem informações mais variadas, maior variabilidade e eficiência, além de menos colinearidade entre variáveis, em comparação com estudos de séries temporais, que sofrem com multicolinearidade (Baltagi, 2005). Os dados em painel permitem controlar a heterogeneidade individual, reconhecendo que indivíduos são diferentes entre si (Baltagi, 2005). Além disso, os dados de painel são mais eficazes para estudar dinâmicas de ajuste e identificar efeitos que não seriam detectáveis em análises puramente transversais ou temporais (Baltagi, 2005).

Um painel balanceado tem todas as suas observações; ou seja, as variáveis são observadas para cada indivíduo e para cada período de tempo (Stock; Watson, 2011). Um painel que possui alguns dados ausentes para pelo menos um período de tempo para pelo menos uma entidade é chamada de painel não balanceado (Stock; Watson, 2011). Na análise econométrica de dados em painel, não pode-se supor que as observações sejam independentemente distribuídas ao longo do tempo (Wooldridge, 2023).

A regressão com dados em painel pode ser definida com a Equação 2 (Baltagi, 2005).

$$y_{it} = \alpha + X'_{it}\beta + u_{it} \quad i = 1, \dots, N; t = 1, \dots, T \quad (2)$$

em que i representa o indivíduo, t representa o tempo, α é um escalar, β é uma matriz $K \times 1$, e X_{it} é a i -ésima observação na t -ésima linha das K variáveis explicativas. Modelos em painel de uma via (*one-way*) apresentam a perturbação conforme a Equação 3.

$$u_{it} = \mu_i + v_{it} \quad (3)$$

em que μ_i denota o efeito específico não observável do indivíduo e v_{it} denota a perturbação residual. μ_i é invariante ao longo do tempo e representa qualquer efeito específico do indivíduo que não está incluído na regressão e o distúrbio residual, v_{it} , varia com os indivíduos e o tempo e pode ser considerado como o erro usual na regressão (Baltagi, 2005). A Equação 2 pode ser escrita na forma vetorial conforme Equação 4 (Baltagi, 2005).

$$y = \alpha \iota_{NT} + X\beta + u = Z\delta + u \quad (4)$$

em que y é $NT \times 1$, X é $NT \times K$, $Z = [\iota_{NT}, X]$, $\delta' = (\alpha', \beta')$ e ι_{NT} é um vetor de uns (1) com dimensão NT . A Equação 3 pode ser reescrita como Equação 5 (Baltagi, 2005).

$$u = Z_\mu u + v \quad (5)$$

em que $u' = (u_{11}, \dots, u_{1t}, u_{21}, \dots, u_{2t}, \dots, u_{N1}, u_{NT})$ com as observações organizadas de modo que o índice mais lento se refira aos indivíduos e índice mais rápido se refira ao tempo. Z_μ é definido pela Equação 6 (Baltagi, 2005).

$$Z_\mu = I_N \otimes \iota_T \quad (6)$$

em que I_N é uma matriz identidade de dimensão N , ι_T é um vetor de um com dimensão T e \otimes é o produto de Kronecker. Z_μ é uma matriz seletora de uns e zeros, uma matriz de *dummies* individuais que pode ser incluída na regressão para estimar os μ_i se eles

forem assumidos como parâmetros fixos (Baltagi, 2005). $\mu' = (\mu_1, \dots, \mu_N)$ e $v' = (v_{11}, \dots, v_{1T}, \dots, v_{NT})$ (Baltagi, 2005).

Baltagi (2005) coloca que o modelo de componentes de erro padrão assume que os distúrbios da regressão são homocedásticos, ou seja, possuem a mesma variância ao longo do tempo e entre os indivíduos. Quando o modelo é heterocedástico, é necessário calcular os erros-padrão robustos que corrijam a possível presença de heterocedasticidade (Baltagi, 2005). Os resultados dos coeficientes de regressão ainda apresentarão estimativas consistentes, mas não serão eficientes (Baltagi, 2005).

No caso de modelo de efeitos fixos assume-se que o μ_i são parâmetros fixos para serem estimados para cada indivíduo e as perturbações remanescente são estocásticos, com v_{it} independente e identicamente distribuídos (Baltagi, 2005). O termo efeitos fixos deve-se ao fato de que, embora o intercepto possa diferir entre os indivíduos, o intercepto de cada indivíduo não varia com o tempo; ele é invariante no tempo (Gujarati; Porter, 2011). Assume-se que o termo X_{it} é independente de v_{it} para todo i e t (Equação 7) (Baltagi, 2005).

$$y = \alpha \iota_{NT} + X\beta + Z_\mu \mu + v = Z\delta + Z_\mu \mu + v \quad (7)$$

Utiliza-se mínimos quadrados ordinários (OLS) na Equação (7) para estimar α , β e μ . No modelo de efeitos aleatórios assume-se μ_i como aleatório (Baltagi, 2005). O modelo de efeitos aleatórios é apropriado quando são selecionados N indivíduos aleatoriamente de uma grande população (Baltagi, 2005). No caso de modelos em painel de duas vias (*two-way*) o u_{it} da Equação 2 é definido pela Equação 8 (Baltagi, 2005).

$$u_{it} = \mu_i + \lambda_t + v_{it} \quad i = 1, \dots, N; t = 1, \dots, T \quad (8)$$

em que μ_i denota o efeito individual não observável, λ_t denota o efeito temporal não observável e v_{it} é o termo estocástico residual (Baltagi, 2005). λ_t é invariável entre os indivíduos e representa qualquer efeito específico do tempo que não esteja incluído na regressão (Baltagi, 2005). Se μ_i e λ_t forem assumidos como parâmetros fixos a serem estimados e os distúrbios remanescentes forem estocásticos com

$v_{it} \sim IID(0, \sigma_v^2)$ (os termos de erro v_{it} são independentemente e identicamente distribuídos (IID) com média zero e variância σ_v^2), então a Equação 8 representa efeitos fixos de duas vias (Baltagi, 2005). Assume-se que X_{it} são independentes de v_{it} para todos os i e t (Baltagi, 2005). Se $\mu_i \sim IID(0, \sigma_\mu^2)$, $\lambda_t \sim IID(0, \sigma_\lambda^2)$ e $v_{it} \sim IID(0, \sigma_v^2)$ forem independentes um do outro, então tem-se o modelo aleatório de duas vias (Baltagi, 2005). Além disso, X_{it} é independente de μ_i , λ_t e de v_{it} para todo i e t (Baltagi, 2005).

O teste de especificação de Hausman verifica se os erros no modelo de regressão de componentes de erro são correlacionados com as variáveis explicativas (Baltagi, 2005). A suposição do teste é que as perturbações individuais não observáveis (μ_i) podem estar correlacionadas com X_{it} o que tornaria o estimador por meio do método dos mínimos quadrados generalizados (GLS) viesado (Baltagi, 2005). A transformação *Within* elimina esses efeitos. O teste de Hausman compara o estimador GLS com o estimador *Within* (Baltagi, 2005). A hipótese nula é de que $E\left(\frac{u_{it}}{X_{it}}\right) = 0$, e caso a hipótese nula seja rejeitada, isso indica que o modelo de efeitos fixos é o mais apropriado (Baltagi, 2005). Para estimar os modelos de dados em painel com efeitos fixos e aleatórios, será utilizado o pacote *Panel Linear Models* (plm) na linguagem R (Croissant; Millo, 2008).

3.3.3 Modelos espaciais para dados em painel

Os modelos econométricos espaciais geralmente abrangem três tipos: o modelo autorregressivo espacial (SAR), o modelo de erro espacial (SEM) e o modelo Durbin espacial (SDM) (Sun *et al.*, 2023). O modelo SAR também é conhecido como *Spatial Lag Panel Model* (SLM).

O SAR opera sob várias suposições fundamentais: (i) ele postula a interdependência espacial entre as unidades observadas, o que significa que a variável dependente em uma unidade é influenciada pelos valores localizados em unidades vizinhas, e esse efeito é capturado por meio de um termo de defasagem espacial no modelo (Ramos-Bueno; Galeana-Pizaña; Perevochtchikova, 2024); (ii) o SAR assume a exogeneidade das variáveis explicativas, garantindo estimativas de coeficientes não viesadas e consistentes (Ramos-Bueno; Galeana-Pizaña; Perevochtchikova, 2024); (iii) os erros são considerados independentes e

homocedásticos, sem correlação ao longo do tempo (Ramos-Bueno; Galeana-Pizaña; Perevochtchikova, 2024). O SAR pode ser expresso pela Equação 9 (Ramos-Bueno; Galeana-Pizaña; Perevochtchikova, 2024).

$$Y_{it} = \rho \sum_{j=1}^N W_{ij} Y_{it} + \beta X_{it} + \mu_i + \varepsilon_{it} \quad i = 1, \dots, N \quad t = 1, \dots, T \quad (9)$$

Em que Y_{it} é a variável dependente na localidade i no tempo t . $\sum_{j=1}^N W_{ij} Y_{it}$ representa os efeitos de interação endógena de Y_{it} . X é uma matriz de variáveis explicativas, supondo que haja m variáveis; ρ representa o coeficiente de autorregressão espacial; W_{ij} é um elemento especial da matriz de ponderação espacial.

O SEM incorpora as relações espaciais por meio da dependência espacial entre os termos de erro associados aos vizinhos (Ramos-Bueno; Galeana-Pizaña; Perevochtchikova, 2024). O SEM pode ser definido conforme a Equação 10 (Ramos-Bueno; Galeana-Pizaña; Perevochtchikova, 2024).

$$Y_{it} = \beta X_{it} + \mu_i + \varphi_{it} \quad (10)$$

Em que φ representa o termo de erro de autocorrelação espacial, definido como $\varphi_{it} = \lambda \sum_{j=1}^N W_{ij} \varphi_{it} + \varepsilon_{it}$, enquanto λ é o coeficiente de autocorrelação espacial.

O SDM pode ser definido conforme a Equação 11 (Ramos-Bueno; Galeana-Pizaña; Perevochtchikova, 2024).

$$Y_{it} = \rho \sum_{j=1}^N W_{ij} Y_{it} + \beta X_{it} + \mu_i + \sum_{j=1}^N W_{ij} Y_{it} \gamma + \varepsilon_{it} \quad (11)$$

Em que γ é um vetor ($M \times 1$) de coeficientes de autocorrelação espacial das variáveis explicativas.

Para a seleção do modelo, a prática predominante é observar o índice de Moran para determinar se variáveis espaciais precisam ser introduzidas (Sun *et al.*, 2023). Deve-se aplicar o teste de Hausman para selecionar entre efeitos fixos ou aleatórios (Song *et al.*, 2022). Os testes multiplicadores de Lagrange (LM, do inglês *Lagrange*

Multiplier Test) são utilizados para identificar o tipo de dependência espacial. Anselin *et al.*, (1996) apresentam os testes LM para detectar a autocorrelação no erro (LM-erro e LM-erro robusto) e na variável dependente (LM-defasagem e LM-defasagem robusto). A descrição da variável dependente defasada espacialmente, ou defasagem espacial, é sinônimo de efeitos de interação endógenos, enquanto a descrição de erro auto correlacionado espacialmente, ou erro espacial, é sinônimo de efeitos de interação entre os termos de erro (Elhorst, 2014). Os testes LM clássicos e robustos são baseados nos resíduos do modelo não espacial (Elhorst, 2014). Os testes analisados consistem em LM-erro, o LM-erro robusto, o LM-defasagem e o LM-defasagem robusto para a definição do modelo espacial em painel (Sun *et al.*, 2023). Se todos os quatro testes forem não significativos não utiliza-se modelo espacial; se todos forem significativos, o SDM é escolhido; se alguns forem significativos, o SDM precisa ser comparado com o SAR e o SEM, respectivamente, por meio do teste de razão de verossimilhança (*likelihood ratio tests*) (LR) para julgamento (Sun *et al.*, 2023).

O fator de inflação da variância (VIF) foi utilizado para verificar a existência de multicolinearidade nas variáveis regressoras (Song *et al.*, 2022). Para avaliação da significância dos coeficientes foi utilizado o teste t (Elhorst, 2014), o qual avalia se os coeficientes estimados são diferentes de zero. O coeficiente de explicação do modelo (R^2) e o coeficiente de explicação ajustado (R^2 ajustado) foram utilizados para avaliar a qualidade do modelo escolhido (Elhorst, 2014). Os resíduos do modelo foram avaliados quanto à dependência espacial utilizando o índice de Moran (Anselin; Florax; Rey, 2004) e quanto à normalidade por meio do teste de Jarque-Bera (Das; Imon, 2016).

A análise foi conduzida utilizando o pacote de econometria espacial (LeSage, 2021) no software MATLAB (MathWorks, 2025) que permite a implementação de modelos espaciais em dados em painel. A biblioteca SPML (*Spatial Panel Models Library*) (Millo; Piras; Bivand, 2023) no software R (R Core Team, 2024) foi utilizada para a realização dos testes LM nos modelos não espaciais.

No pacote de LeSage (2021), é possível estimar os modelos espaciais utilizando os métodos de *Markov Chain Monte Carlo* (MCMC) ou *Maximum Likelihood* (ML). Além disso, pode-se especificar o modelo assumindo homoscedasticidade ou heterocedasticidade. LeSage (2021) recomenda a utilização de estimativas robustas/heterocedásticas, pois essa abordagem de estimação pode evitar problemas

causados por *outliers* ou por heterocedasticidade/variância não constante ao longo das regiões e dos períodos de tempo, os quais não são adequadamente tratados pelas estimativas via ML. Por conseguinte, opta-se por utilizar o modelo MCMC heterocedástico neste trabalho.

3.3.4 Tratamento de outliers e imputação de dados

Quando o tamanho da amostra selecionada é suficientemente grande, costuma-se reduzir as extremidades das variáveis contínuas a fim de evitar a influência de *outliers* nos resultados da pesquisa (Zou; Xiong, 2023). Por conseguinte, foi realizada a verificação de *outliers* para a variável consumo de água *per capita*. Os valores extremos foram identificados com base em critério previamente estabelecido e substituídos por valores limites por meio da função *Winsorize* do pacote *DescTools* (Signorell, 2025).

A ausência de dados é uma questão recorrente em pesquisas, podendo reduzir o poder estatístico e gerar vieses nos resultados quando não tratada de maneira adequada (Chhabra; Vashisht; Ranjan, 2017). Dados brutos de baixa qualidade, frequentemente com alta taxa de dados ausentes, podem comprometer a qualidade e a interpretação dos resultados (Ratolojanahary *et al.*, 2019). Para lidar com dados ausentes no estudo, foi realizada a imputação de dados no R com o pacote *Amelia*, o qual permite trabalhar com dados em painel (Honaker; King; Blackwell, 2011).

A imputação múltipla envolve imputar m valores para cada item ausente e criar m conjuntos de dados completos (King *et al.*, 2001). Nos diferentes conjuntos de dados completos, os valores observados são os mesmos, mas os valores ausentes são preenchidos com diferentes imputações para refletir os níveis de incerteza (King *et al.*, 2001). O algoritmo EMB, utilizado pelo algoritmo *Amelia*, combina o método *Expectation-Maximization* (EM) com uma abordagem de *bootstrap* para imputação de dados ausentes (Honaker; King; Blackwell, 2011). O EMB realiza uma reamostragem dos dados por *bootstrap* a fim de incorporar a incerteza da estimação, e em seguida aplica o algoritmo EM para encontrar o modo da distribuição *a posteriori* nessa amostra (Honaker; King; Blackwell, 2011).

O algoritmo *Amelia* assume que os dados seguem uma distribuição normal multivariada (Honaker; King; Blackwell, 2011). As análises econométricas são realizadas em cada um dos m conjuntos de dados imputados, e as Regras de Rubin

(*Rubin's Rule*) podem ser utilizadas para combinar os resultados em uma única inferência (Rubin, 1987).

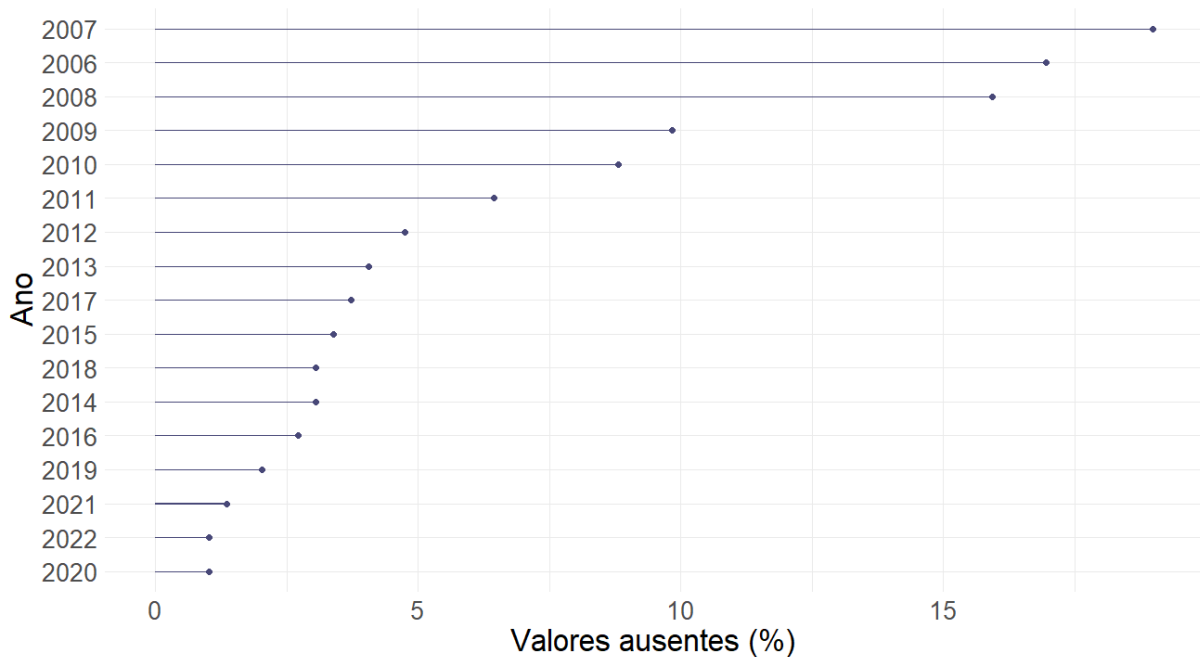
4 RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados do trabalho e suas respectivas discussões.

4.1 TRATAMENTO DE *OUTLIERS* E *IMPUTAÇÃO DE DADOS*

A análise da base de dados para consumo de água *per capita* para os municípios de Santa Catarina de 2006 a 2022 revelou que, a partir de 2012, a completude dos dados sobre o consumo de água *per capita* municipal para os municípios de Santa Catarina atinge um patamar superior a 95% em cada ano, conforme Figura 14.

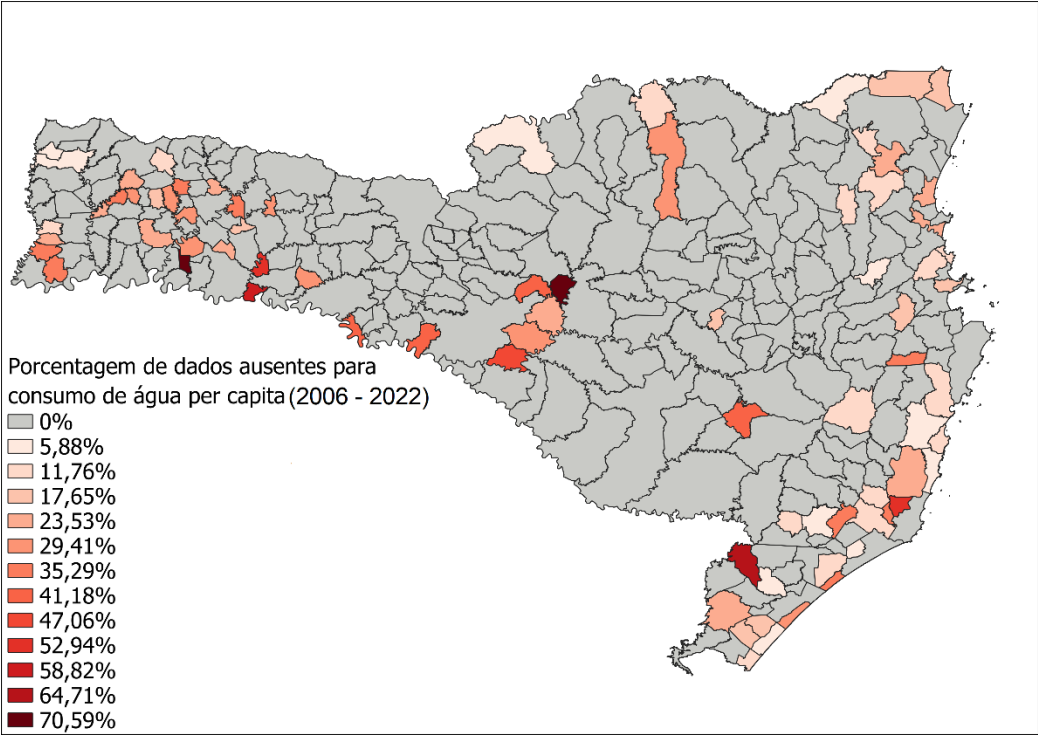
Figura 14 - Valores ausentes de consumo de água por município por ano



Fonte: Elaborado pela autora (2025)

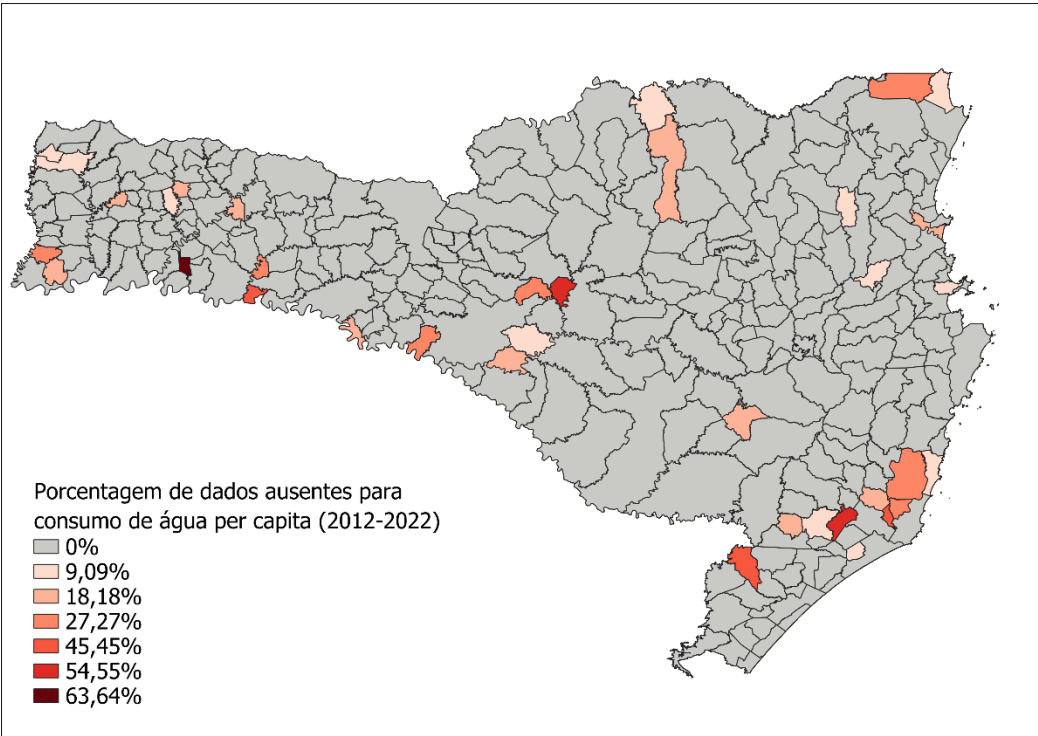
A Figura 15 e a Figura 16 apresentam a porcentagem de dados ausentes para o consumo de água *per capita* para os municípios de Santa Catarina nos períodos de 2006 a 2022 e de 2012 a 2022, respectivamente. Observa-se que, na Figura 16, há um maior número de municípios com menor proporção de dados ausentes em comparação à Figura 15, indicando melhora na disponibilidade dos dados ao longo do tempo. Nota-se que algumas cidades reduziram a quantidade de dados ausentes, o que pode indicar aprimoramento na coleta e no registro desses dados nos anos mais recentes.

Figura 15 - Porcentagem de dados ausentes de consumo de água *per capita* para os municípios de Santa Catarina (2006-2022)



Fonte: Elaborado pela autora (2025)

Figura 16 - Porcentagem de dados ausentes de consumo de água *per capita* para os municípios de Santa Catarina (2012-2022)



Fonte: Elaborado pela autora (2025)

Por conseguinte, definiu-se o período de 2012 a 2022 para análise do consumo de água *per capita*, com intuito de gerar maior confiabilidade e de reduzir possíveis vieses decorrentes de dados ausentes. Contudo, a análise do estudo será realizada com base no período de 2012 a 2021, tendo em vista que os dados de PIB municipal referentes ao ano de 2022 não foram divulgados pelo IBGE até a data de elaboração deste estudo. Os valores faltantes de consumo de água *per capita* para o período de 2012 a 2021 serão estimados por meio de técnicas de imputação de dados. A Tabela 9 apresenta o sumário estatístico do consumo de água *per capita* por ano para os municípios de Santa Catarina.

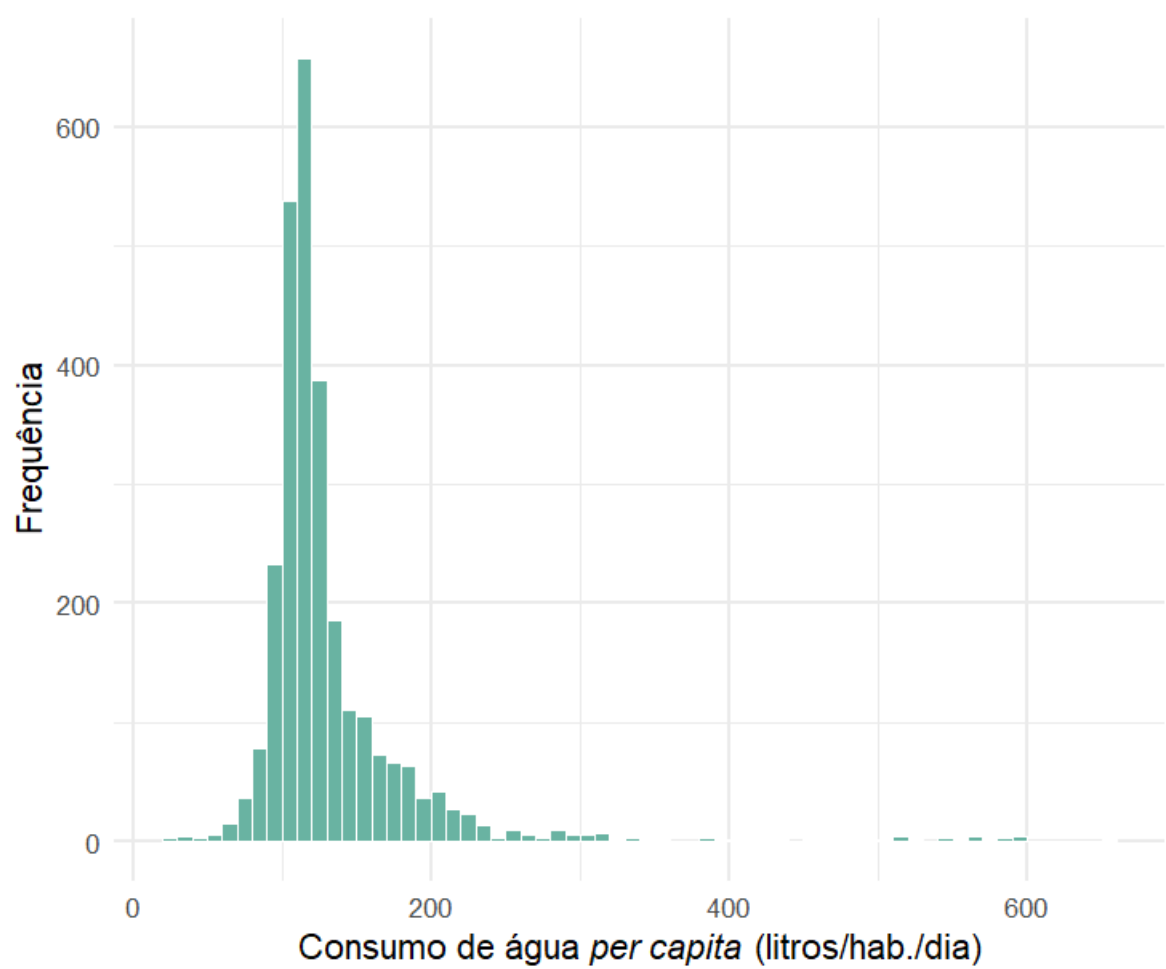
Tabela 9 - Sumário estatístico do consumo de água *per capita* (litros/hab./dia)

Ano	Observações	Mínimo	1º Q	Mediana	Média	3º Q	Máximo	Desvio Padrão
2012	278	73,20	101,58	113,60	126,49	131,55	652,70	52,56
2013	278	41,04	104,56	116,11	130,15	135,17	516,49	54,13
2014	281	31,22	106,96	118,12	135,51	137,33	590,09	66,67
2015	278	67,55	105,68	115,02	134,39	135,52	590,09	66,33
2016	283	53,30	107,24	118,07	134,18	137,89	585,88	61,67
2017	273	34,57	109,83	118,87	134,58	136,99	590,09	61,04
2018	283	26,98	107,15	116,97	130,58	135,30	592,24	56,62
2019	282	25,79	109,92	119,79	136,05	138,76	588,27	62,15
2020	285	50,00	108,01	117,86	137,62	142,75	586,56	64,93
2021	287	60,87	104,95	115,05	134,39	138,57	572,85	60,53

Fonte: Elaborado pela autora (2025)

A Figura 17 apresenta o histograma da variável consumo de água *per capita*. Observa-se que a distribuição é assimétrica à direita. A cauda alongada à direita indica a presença de valores extremos, sugerindo a necessidade de tratamento estatístico para mitigar a influência desses *outliers* na análise.

Figura 17 - Histograma do consumo de água *per capita*



Fonte: Elaborado pela autora (2025)

A Tabela 10 apresenta os valores correspondentes aos percentis 1%, 5%, 95% e 99% da variável consumo de água *per capita*, com o objetivo de identificar possíveis valores extremos.

Tabela 10 - Percentis para a variável consumo de água *per capita*

Percentil	Valor (litros/hab./dia)
1%	66,30
5%	89,84
95%	217,91
99%	476,23

Fonte: Elaborado pela autora (2025)

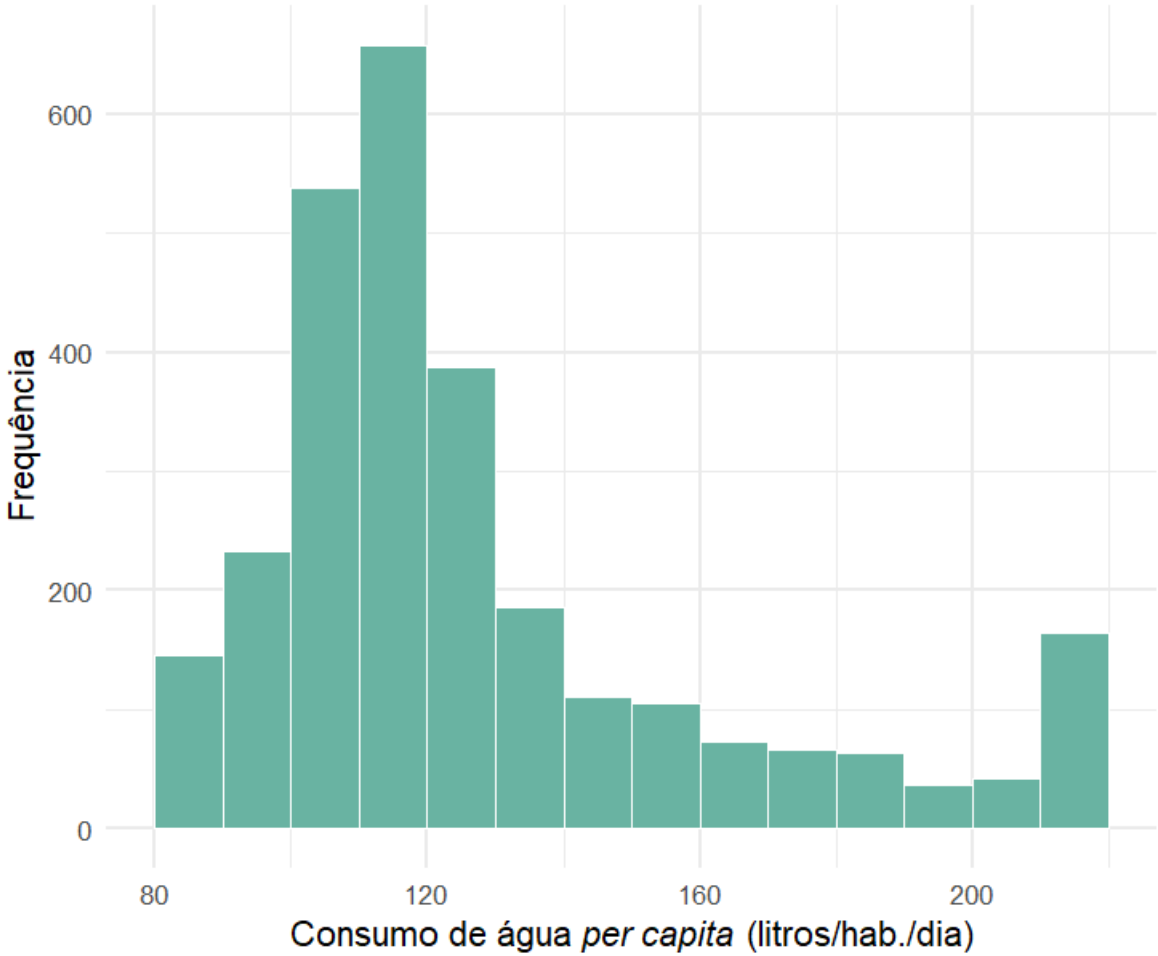
Com base nesses resultados, definiram-se os percentis de 5% e de 95% como limites para a aplicação da função *Winsorize*. A Tabela 11 apresenta o sumário estatístico e a Figura 18 exibe o histograma da variável consumo de água *per capita*, ambos após o tratamento de valores extremos por meio da função *Winsorize*.

Tabela 11 - Sumário estatístico do consumo de água *per capita* (litros/hab./dia) após tratamento de *outliers*

Ano	Observações	Mínimo	1º Q	Mediana	Média	3º Q	Máximo	Desvio Padrão
2012	278	89,84	101,58	113,60	123,25	131,55	217,91	31,89
2013	278	89,84	104,56	116,11	126,40	135,17	217,91	32,69
2014	281	89,84	106,96	118,12	129,24	137,33	217,91	33,76
2015	278	89,84	105,68	115,02	127,50	135,52	217,91	34,42
2016	283	89,84	107,24	118,07	128,51	137,89	217,91	32,20
2017	273	89,84	109,83	118,87	129,13	136,99	217,91	31,63
2018	283	89,84	107,15	116,97	127,26	135,30	217,91	32,21
2019	282	89,84	109,92	119,79	130,50	138,76	217,91	33,76
2020	285	89,84	108,01	117,86	130,75	142,75	217,91	35,81
2021	287	89,84	104,95	115,05	128,59	138,57	217,91	36,51

Fonte: Elaborado pela autora (2025)

Figura 18 - Histograma do consumo de água *per capita* após tratamento de *outliers*



Fonte: Elaborado pela autora (2025)

A variável PIB *per capita* apresenta 2 valores ausentes para o ano de 2012. A Tabela 12 apresenta o sumário estatístico do PIB *per capita*.

Tabela 12 - Sumário estatístico PIB *per capita*

Ano	Obser- vações	Mínimo (R\$x10³)	1º Q (R\$x10³)	Mediana (R\$x10³)	Média (R\$x10³)	3º Q (R\$x10³)	Máximo (R\$x10³)	Desvio Padrão (R\$x10³)
2012	293	20,98	38,11	51,25	56,88	69,12	211,96	26,85
2013	295	10,17	41,09	53,27	59,14	71,32	229,26	27,34
2014	295	13,99	41,22	51,73	58,27	69,83	240,50	26,73
2015	295	16,27	40,18	48,64	57,27	68,51	332,84	28,70
2016	295	15,07	40,21	50,11	55,36	64,05	326,68	26,46
2017	295	15,61	39,22	49,31	54,03	63,56	268,72	25,22
2018	295	16,47	41,47	51,63	56,84	67,27	262,59	25,83
2019	295	15,16	41,75	51,75	57,26	66,08	305,21	27,69

Ano	Observações	Mínimo (R\$ $\times 10^3$)	1º Q (R\$ $\times 10^3$)	Mediana (R\$ $\times 10^3$)	Média (R\$ $\times 10^3$)	3º Q (R\$ $\times 10^3$)	Máximo (R\$ $\times 10^3$)	Desvio Padrão (R\$ $\times 10^3$)
2020	295	15,56	43,08	54,85	59,31	69,15	291,02	28,06
2021	295	13,93	41,28	52,04	57,92	66,69	262,70	29,03

Fonte: Elaborado pela autora (2025)

Ao realizar a imputação, deve-se incluir qualquer variável que estará no modelo de análise (Honaker; King; Blackwell, 2011). Como a imputação é preditiva, quaisquer variáveis que aumentariam o poder preditivo devem ser incluídas, mesmo que incluí-las no modelo de análise produza viés na estimativa de um efeito causal ou que a colinearidade impeça determinar qual variável tem relação com a variável dependente (Honaker; King; Blackwell, 2011).

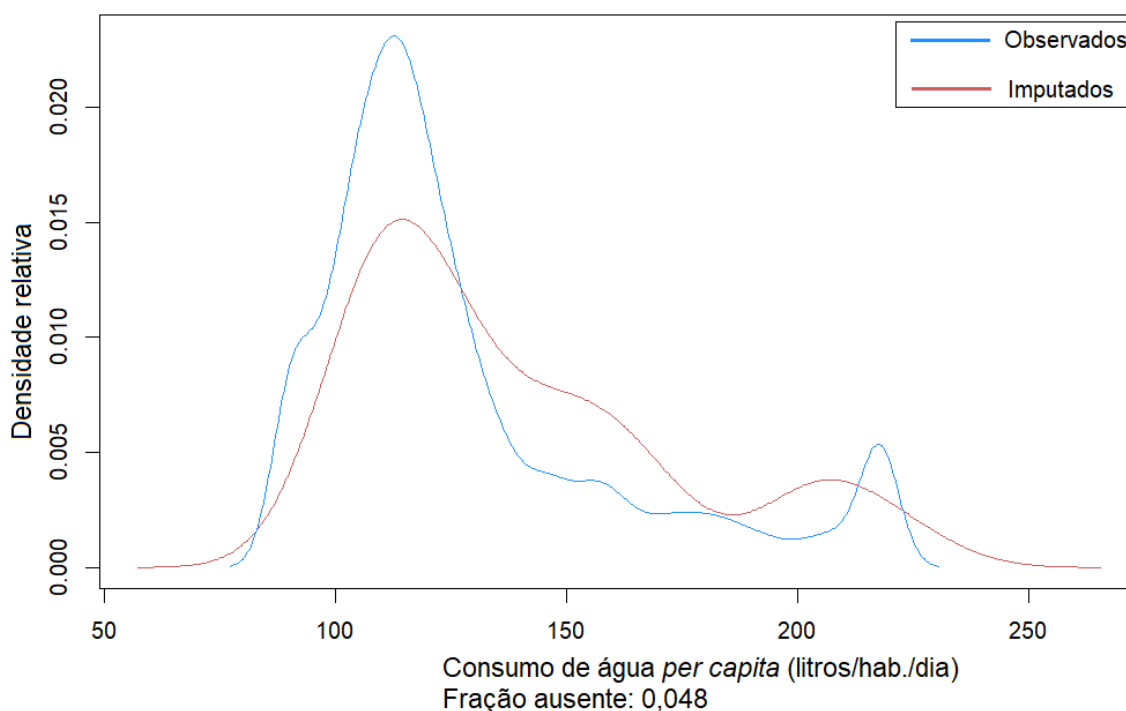
Se uma das variáveis estiver fortemente assimétrica ou tiver *outliers* que possam alterar a imputação de maneira indesejada, pode-se utilizar a transformação por logaritmo natural dessa variável para normalizar sua distribuição (Honaker; King; Blackwell, 2011). Ao utilizar o pacote Amelia para imputação múltipla, foram aplicadas transformações por logaritmo natural às variáveis PIB *per capita* e consumo de água *per capita*. Todas as 14 variáveis foram inseridas no modelo. Schafer (1997) coloca que um número de imputações pequeno (3-5) é suficiente para gerar bons resultados, portanto foi definido $m = 3$, ou seja, três conjuntos imputados foram gerados.

Na imputação foram levadas em consideração a temporalidade e a transversalidade dos dados. Conforme Honaker, King e Blackwell (2011) muitas variáveis observadas ao longo do tempo dentro de uma unidade transversal tendem a apresentar padrões contínuos ou suaves. A incorporação dessas informações temporais pode aumentar substancialmente a qualidade das imputações, especialmente quando os valores ausentes estão cercados por observações próximas no tempo (Honaker; King; Blackwell, 2011). No entanto, tais padrões podem variar entre períodos — por exemplo, de crescimento, estabilidade ou declínio — e também entre diferentes unidades transversais (Honaker; King; Blackwell, 2011). Para capturar essas variações, o Amelia permite a inclusão de uma função polinomial do tempo, que pode ser interagida com as unidades transversais. Essa abordagem possibilita que cada unidade tenha seu próprio padrão temporal estimado. No presente estudo, foi adotada uma função polinomial de grau dois e ativada a opção *intercs = TRUE*, essa opção permite a variação dos efeitos temporais entre unidades.

Durante o processo de imputação múltipla com o pacote Amelia, foi observado que, em determinadas iterações, surgiram avisos os quais indicavam que ocorreu matriz de covariância singular. Para contornar esse problema, conforme recomendado na documentação do Amelia, foi adotada a inclusão de *prior* do tipo *ridge* por meio do argumento *empri*. Esse prior contribui para estabilizar numericamente a imputação ao reduzir as covariâncias entre as variáveis, sem alterar suas médias e variâncias. No presente estudo, foi definido o valor de 0,01 para o argumento *empri*, o que equivale a 1% do número total de observações. Essa medida se mostrou eficaz para garantir a estabilidade do processo de imputação.

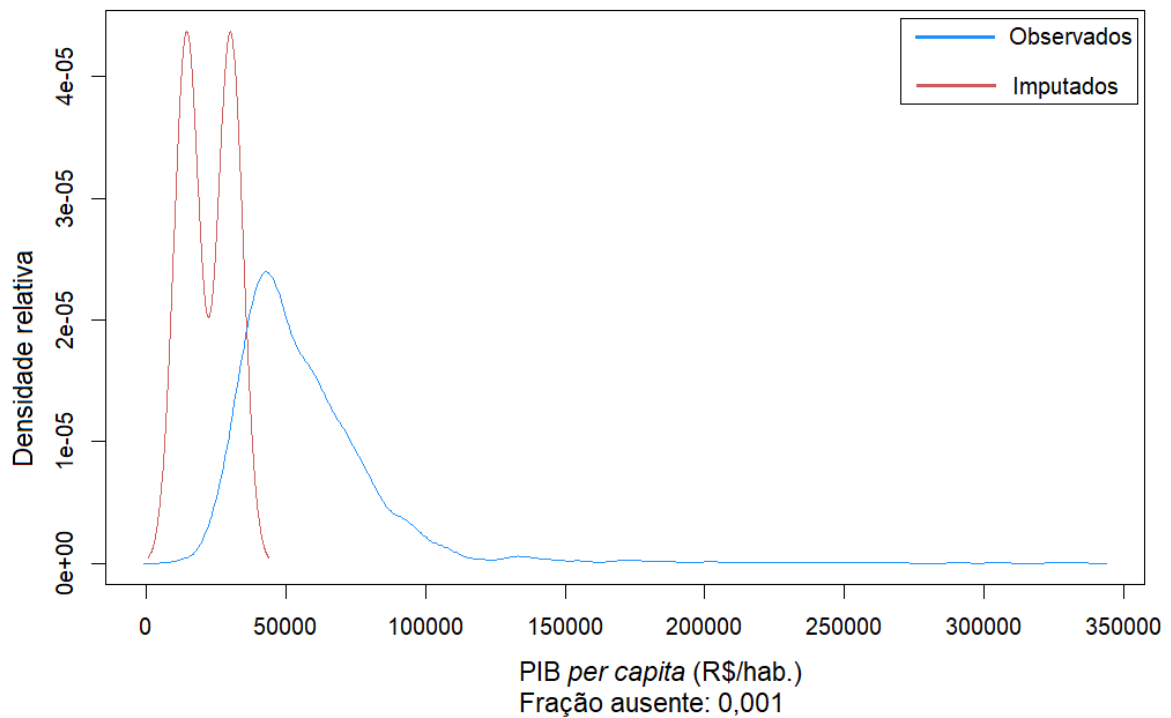
A Figura 19 e a Figura 20 apresentam o gráfico de densidade das variáveis imputadas. A curva em vermelho representa a densidade da imputação média ao longo dos m conjuntos de dados e a curva em azul corresponde a distribuição dos dados observados. Observa-se que, para o consumo de água *per capita*, as distribuições são bastante semelhantes à dos valores observados. Para o PIB *per capita*, foram imputados *apenas* dois valores, refletindo-se nos dois picos destacados na curva vermelha. A fração ausente corresponde ao número de dados que foram imputados, 4,8%.

Figura 19 - Valores observados e imputados de consumo de água *per capita*



Fonte: Elaborado pela autora (2025)

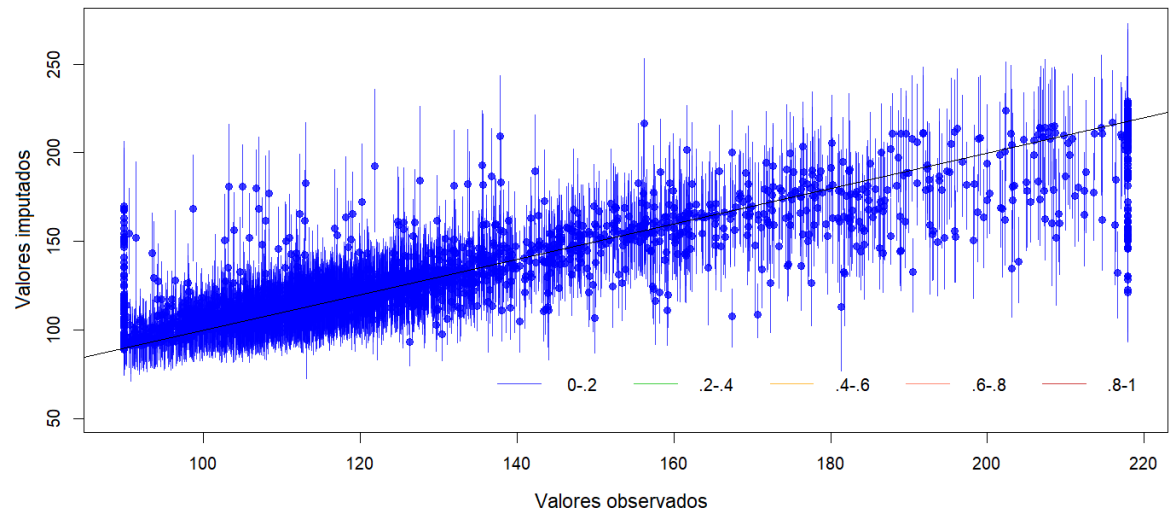
Figura 20 - Valores observados e imputados de PIB *per capita*



Fonte: Elaborado pela autora (2025)

Outra avaliação é o *Overimputing* que testa a qualidade das imputações ao tratar valores observados como se estivessem ausentes. Para cada valor observado, o modelo gera centenas de imputações, como se aquele dado estivesse faltando (Honaker; King; Blackwell, 2011). Os resultados são visualizados em um gráfico em que a linha $y = x$ representa a imputação perfeita (Honaker; King; Blackwell, 2011). Esse gráfico também mostra os intervalos de confiança de 90% para ajudar a avaliar se o modelo consegue prever corretamente os valores verdadeiros. A Figura 21 apresenta o *Overimputing* para a variável consumo de água *per capita*. Os círculos representam a média de todas as imputações e a cor do intervalo de confiança reflete a porcentagem de covariáveis observadas.

Figura 21 – *Overimputing*, valores imputados x valores observados de consumo de água *per capita*



Fonte: Elaborado pela autora (2025)

A Tabela 13 apresenta o sumário estatístico para cada uma das três imputações realizadas.

Tabela 13 - Sumário estatístico consumo de água *per capita* (litros/hab./dia) por imputação

Ano	Imputação	Observações	Mínimo	1ºQ	Mediana	Média	3ºQ	Máximo	Desvio Padrão
2012	m=1	295	89,84	101,85	114,13	124,66	135,08	234,55	32,93
	m=2	295	89,84	101,80	114,80	125,07	135,55	233,33	33,37
	m=3	295	89,84	101,95	114,50	124,54	135,30	219,32	32,79
2013	m=1	295	85,12	104,54	116,28	126,85	135,54	232,37	33,49
	m=2	295	89,84	105,46	116,79	127,57	136,33	227,79	33,46
	m=3	295	85,11	104,62	116,44	127,17	135,94	235,26	33,42
2014	m=1	295	89,84	107,43	118,31	129,68	139,32	221,98	33,82
	m=2	295	89,84	107,29	118,44	130,18	139,21	249,28	34,28
	m=3	295	89,84	107,29	118,44	130,26	140,21	248,09	34,35
2015	m=1	295	86,98	105,69	114,99	127,49	137,16	217,91	34,27
	m=2	295	89,84	106,10	116,05	128,02	137,71	217,91	34,04
	m=3	295	88,84	105,69	115,54	127,80	137,17	217,91	34,35
2016	m=1	295	89,84	107,23	118,15	128,80	138,74	224,36	32,38
	m=2	295	89,84	108,78	118,47	129,15	138,74	243,90	32,50
	m=3	295	89,84	107,40	118,34	129,14	140,73	217,91	32,30
2017	m=1	295	80,24	109,51	118,87	129,34	137,82	240,92	32,31
	m=2	295	89,84	109,74	118,90	129,59	138,08	228,57	32,05
	m=3	295	89,84	109,87	118,93	129,27	137,48	217,91	32,42
2018	m=1	295	89,84	107,15	117,10	127,73	136,26	231,76	32,69

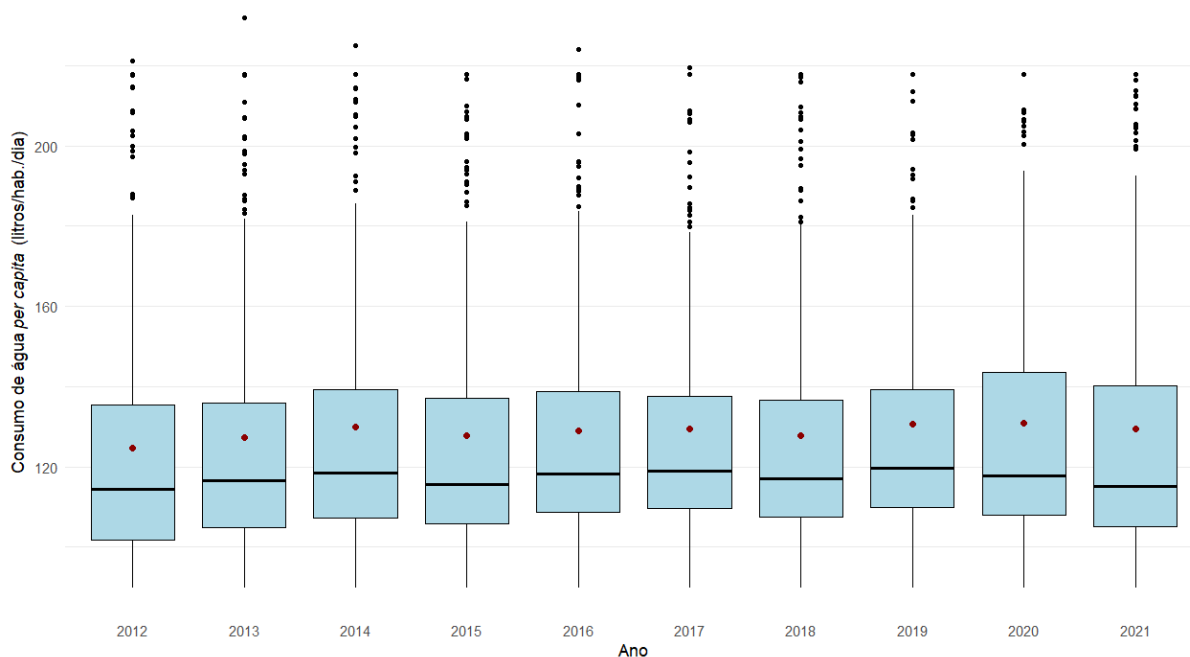
	m=2	295	89,84	107,18	117,23	127,91	136,70	217,91	32,37
	m=3	295	89,84	107,40	117,10	127,67	135,73	217,91	32,41
2019	m=1	295	83,60	109,69	119,83	130,29	139,25	217,91	33,75
	m=2	295	89,84	109,81	119,74	130,52	139,25	217,91	33,71
	m=3	295	89,84	109,81	120,25	130,77	140,00	217,91	33,66
2020	m=1	295	84,60	107,92	117,55	130,43	143,04	217,91	35,61
	m=2	295	89,84	108,07	118,34	131,10	144,29	227,54	35,94
	m=3	295	86,62	108,07	118,47	130,99	143,73	217,91	35,84
2021	m=1	295	89,84	104,95	115,19	129,32	140,12	217,91	36,93
	m=2	295	89,84	105,08	115,19	129,48	140,12	217,91	36,99
	m=3	295	89,84	105,08	115,19	129,62	140,12	223,26	37,22

Fonte: Elaborado pela autora (2025)

4.2 DADOS DE CONSUMO DE ÁGUA *PER CAPITA*

Nesta seção, são apresentadas as estatísticas descritivas do consumo de água *per capita*. O sumário estatístico referente ao período de 2012 a 2021 foi apresentado na Seção 4.1. Para os mapas temáticos e gráficos desta seção, foram utilizadas as médias das três imputações para fins de visualização. A Figura 22 apresenta o boxplot referente ao consumo de água *per capita* para cada município no período de análise. Cada boxplot representa a distribuição de consumo de água *per capita* para o respectivo ano. A linha horizontal dentro de cada caixa indica a mediana do consumo e o ponto vermelho representa a média do consumo.

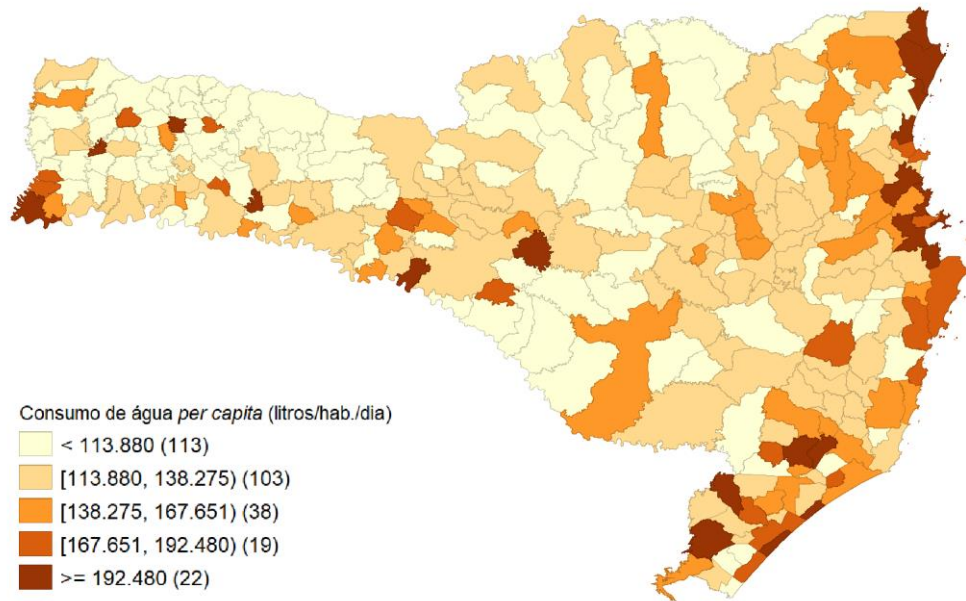
Figura 22 – Gráfico boxplot do consumo de água *per capita* (litros/hab.dia) para os municípios de Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 23 apresenta a mediana do consumo de água *per capita* médio no período de 2012 a 2021 nos municípios de Santa Catarina, utilizando o mapa de quebras naturais. Nota-se algum padrão espacial, uma vez que, em geral, os municípios aparentam apresentar comportamentos similares aos vizinhos.

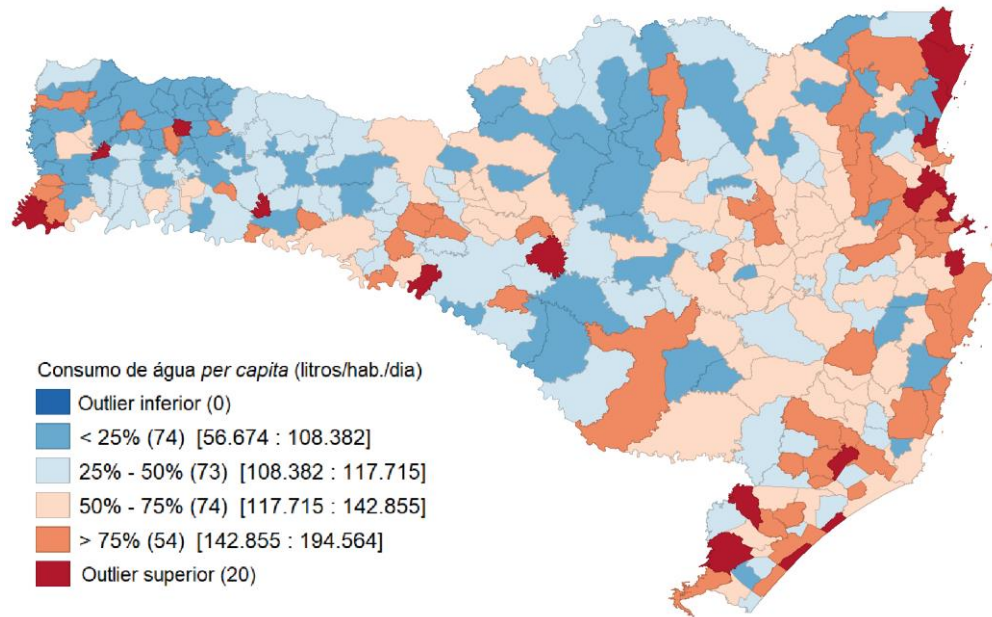
Figura 23 - Mapa de quebras naturais do consumo de água *per capita* médio (litros/hab./dia) dos municípios de Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 24 apresenta o mapa box da mediana do consumo de água *per capita* médio. Utilizando a mediana do consumo *per capita* médio não há presença de *outlier* inferior. Os municípios do litoral catarinense, com exceção de Passo de Torres, Paulo Lopes e Araquari, apresentam-se no quartil superior do boxplot. O mapa apresenta 20 *outliers* superiores, sendo 11 localizados no litoral.

Figura 24 - Mapa boxplot do consumo de água *per capita* médio (litros/hab./dia) dos municípios de Santa Catarina (2012-2021)



Fonte: Elaborada pela autora (2025)

A Tabela 14 apresenta o Índice de Moran para o consumo de água *per capita* médio entre 2012 e 2021. Os resultados indicam uma autocorrelação espacial positiva significativa no período de estudo para todos os anos e imputações. Isso sugere que municípios próximos tendem a ter padrões de consumo de água semelhantes.

Tabela 14 - Índice de Moran para o consumo de água *per capita* (2012-2021)

ano	Índice de Moran		
	m=1	m=2	m=3
2012	0,187***	0,178***	0,188***
2013	0,219***	0,224***	0,195***
2014	0,234***	0,238***	0,229***
2015	0,223***	0,221***	0,224***
2016	0,172***	0,169***	0,186***
2017	0,183***	0,186***	0,199***
2018	0,158***	0,172***	0,169***
2019	0,198***	0,195***	0,191***
2020	0,222***	0,233***	0,232***
2021	0,199***	0,197***	0,191***

***p-valor = 0,001

Fonte: Elaborado pela autora (2025)

4.3 DADOS CLIMÁTICOS

Esta seção apresenta a estatística descritiva dos dados climáticos. As variáveis apresentadas são temperatura média e precipitação média diária.

4.3.1 Temperatura média

A Tabela 15 apresenta o sumário estatístico para a variável temperatura média anual para os municípios de Santa Catarina.

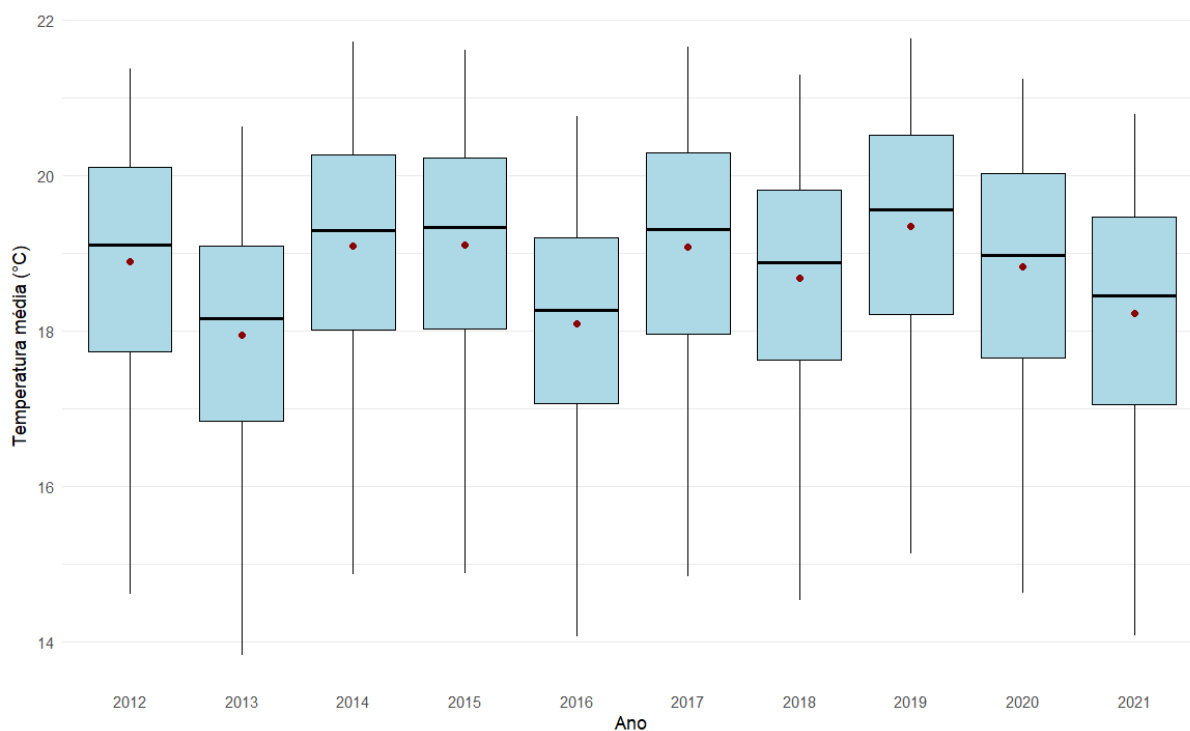
Tabela 15 - Sumário estatístico da temperatura média anual

Ano	Observações	Mínimo (°C)	1° Q (°C)	Mediana (°C)	Média (°C)	3° Q (°C)	Máximo (°C)	Desvio Padrão (°C)
2012	295	14,62	17,73	19,11	18,90	20,10	21,36	1,48
2013	295	13,83	16,84	18,16	17,94	19,09	20,62	1,44
2014	295	14,87	18,02	19,29	19,09	20,26	21,71	1,44
2015	295	14,89	18,02	19,34	19,10	20,22	21,61	1,42
2016	295	14,07	17,06	18,27	18,09	19,20	20,76	1,40
2017	295	14,84	17,96	19,30	19,08	20,30	21,65	1,46
2018	295	14,54	17,63	18,87	18,68	19,81	21,30	1,42
2019	295	15,13	18,22	19,56	19,34	20,52	21,75	1,43
2020	295	14,64	17,65	18,97	18,82	20,02	21,24	1,48
2021	295	14,08	17,05	18,45	18,23	19,47	20,79	1,46

Fonte: Elaborado pela autora (2025)

A Figura 25 exibe a variação anual da temperatura média nos municípios de Santa Catarina utilizando boxplots. Em geral, os valores de média e mediana estão próximos, sugerindo uma distribuição simétrica da temperatura entre os municípios. Nota-se oscilação na temperatura média ao longo do período. Há grande variação entre os valores mínimos e máximos em todos os anos, refletindo a diversidade climática do estado.

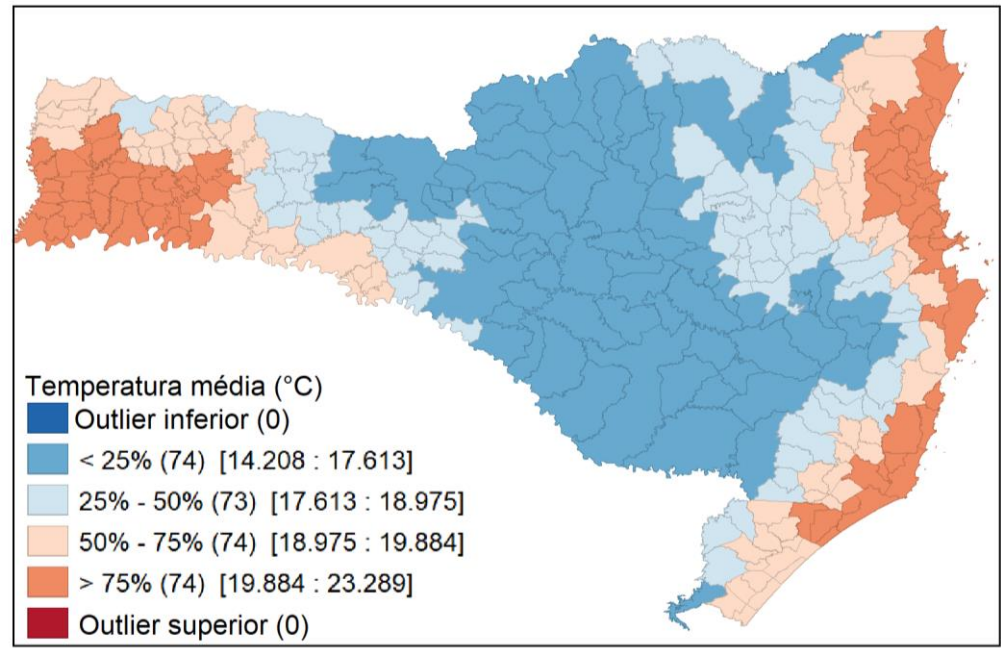
Figura 25 – Gráfico boxplot da temperatura média (°C) dos municípios de Santa Catarina por ano (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 26 apresenta mapa boxplot de temperatura média para o estado de Santa Catarina. Nota-se padrão geográfico na distribuição de temperatura, as regiões centrais, serranas e centro-oeste apresentam menores valores de temperatura média, enquanto as regiões litorâneas, sul e oeste concentram municípios com temperatura média mais elevada.

Figura 26 – Mapa boxplot da temperatura média (°C) em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.3.2 Precipitação média diária

A Tabela 16 contém o sumário estatístico da variável precipitação média diária anual dos municípios de Santa Catarina.

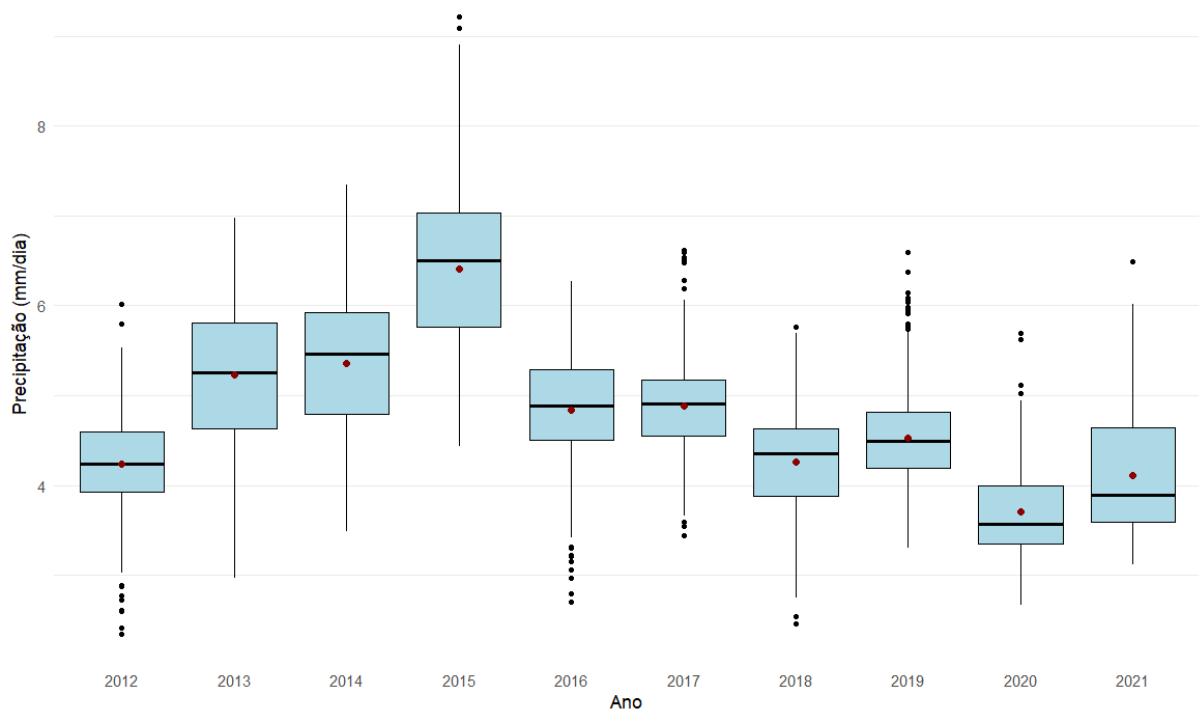
Tabela 16 - Sumário estatístico de precipitação média diária anual municipal

Ano	Observações	Mínimo (mm/dia)	1º Q (mm/dia)	Mediana (mm/dia)	Média (mm/dia)	3º Q (mm/dia)	Máximo (mm/dia)	Desvio Padrão (mm/dia)
2012	295	2,35	3,92	4,24	4,24	4,59	6,02	0,58
2013	295	2,97	4,63	5,26	5,23	5,81	6,97	0,78
2014	295	3,49	4,79	5,46	5,36	5,93	7,34	0,79
2015	295	4,43	5,76	6,50	6,41	7,03	9,21	0,87
2016	295	2,71	4,50	4,88	4,84	5,29	6,27	0,62
2017	295	3,45	4,55	4,91	4,88	5,18	6,62	0,54
2018	295	2,46	3,88	4,36	4,26	4,63	5,76	0,60
2019	295	3,30	4,20	4,46	4,53	4,81	6,59	0,56
2020	295	2,67	3,35	3,58	3,71	3,99	5,70	0,51
2021	295	3,12	3,60	3,89	4,11	4,65	6,48	0,66

Fonte: Elaborado pela autora (2025)

A Figura 27 apresenta boxplots anuais da precipitação média diária dos municípios de Santa Catarina. Observa-se uma considerável variabilidade interanual, com destaque para o ano de 2015, que apresentou os maiores valores de precipitação média diária, tanto em termos de média quanto de dispersão. A presença de *outliers* superiores e inferiores em praticamente todos os anos indica a ocorrência de eventos extremos de chuva e estiagem.

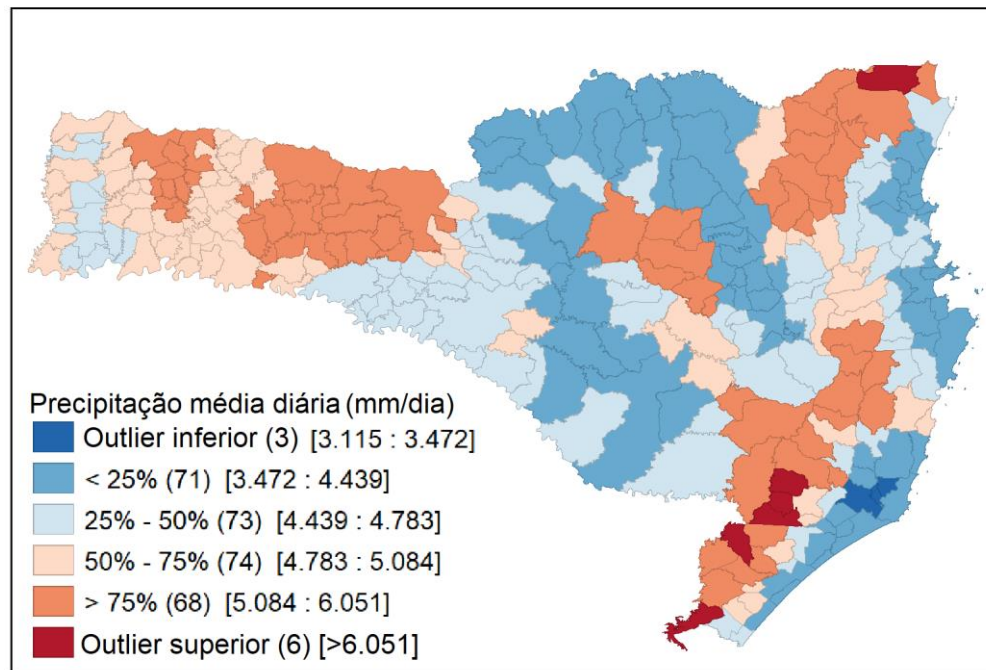
Figura 27 – Gráfico boxplot da precipitação média diária (mm/dia) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 28 apresenta a distribuição espacial da precipitação média diária dos municípios catarinenses em um mapa boxplot. Pode-se identificar agrupamentos com diferentes padrões de precipitação média diária.

Figura 28 – Mapa boxplot da precipitação média diária (mm/dia) em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.4 DADOS ECONÔMICOS

Esta seção apresenta a estatística descritiva dos dados econômicos. As variáveis analisadas incluem os valores adicionados *per capita* nas seguintes categorias: indústria, serviço e comércio, além PIB *per capita*.

4.4.1 Valor adicionado industrial *per capita*

A Tabela 17 apresenta o sumário estatístico do valor adicionado industrial *per capita* para os municípios de Santa Catarina.

Tabela 17 - Sumário estatístico do valor adicionado industrial *per capita*

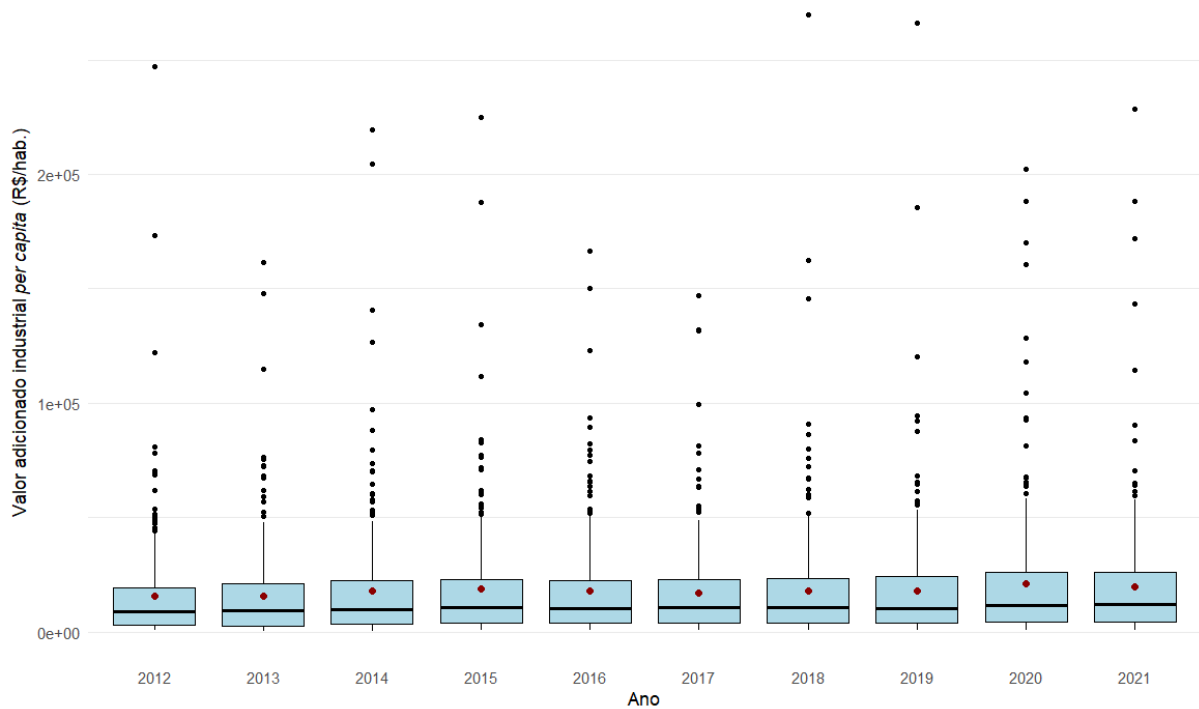
Ano	Observações	Mínimo (R\$)	1º Q (R\$)	Mediana (R\$)	Média (R\$)	3º Q (R\$)	Máximo (R\$)	Desvio Padrão (R\$)
2012	295	518,12	2.934,25	8.813,74	15.637,04	19.346,92	246.917,65	23.201,60
2013	295	301,84	2.725,01	9.322,35	15.844,54	21.130,14	161.285,98	20.413,14

Ano	Observações	Mínimo (R\$)	1º Q (R\$)	Mediana (R\$)	Média (R\$)	3º Q (R\$)	Máximo (R\$)	Desvio Padrão (R\$)
2014	295	387,91	3.201,17	9.660,27	17.928,78	22.297,57	219.286,75	25.410,83
2015	295	592,23	3.979,26	10.789,38	18.735,81	22.718,35	224.934,19	24.720,37
2016	295	659,05	3.962,59	10.298,29	17.694,74	22.518,99	166.283,49	21.787,21
2017	295	560,65	3.698,42	10.634,96	16.852,39	22.940,29	147.045,06	20.179,38
2018	295	488,61	4.011,85	10.444,43	18.051,77	23.147,72	269.563,74	24.728,30
2019	295	745,05	3.977,84	10.109,95	17.982,19	24.120,27	266.166,87	24.696,00
2020	295	679,43	4.498,92	11.695,92	21.134,54	26.190,15	202.285,09	27.485,57
2021	295	600,84	4.353,52	12.144,10	19.644,63	25.964,44	228.718,57	25.985,10

Fonte: Elaborado pela autora (2025)

A Figura 29 apresenta boxplots do valor adicionado industrial *per capita* por ano para os municípios de Santa Catarina. Os municípios com maior valor adicionado industrial são Joinville, Jaraguá do Sul e Blumenau, com destaque para a fabricação de eletrodomésticos, fabricação de geradores, transformadores e motores elétricos e confecção de artigos do vestuário e acessórios, respectivamente. Piratuba e Itá, localizados no oeste catarinense, apresentam os maiores valores adicionados industriais *per capita*, sendo a atividade mais expressiva a geração, transmissão e distribuição de energia elétrica.

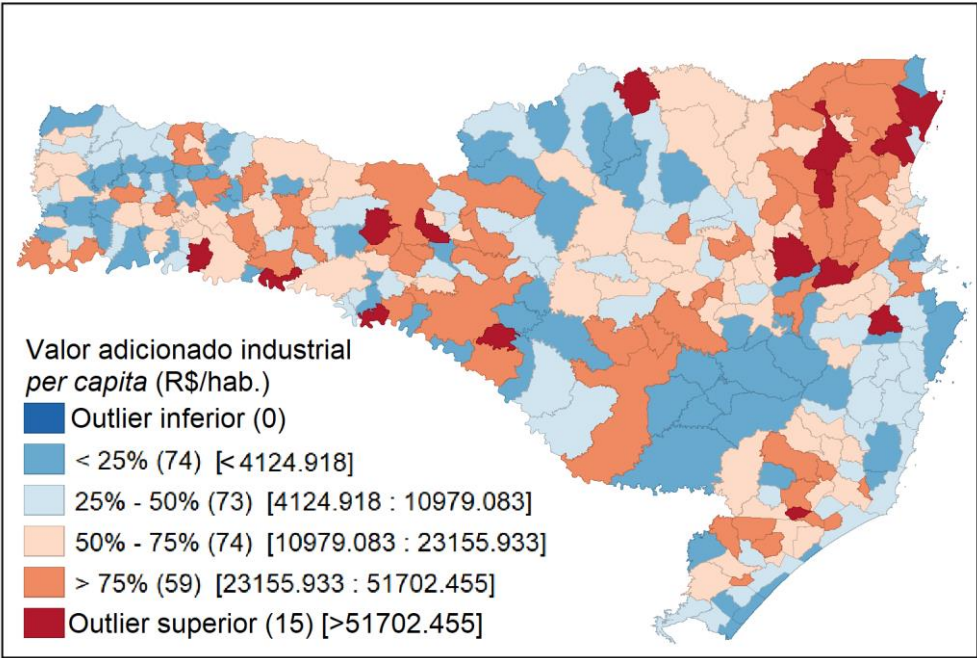
Figura 29 – Gráfico boxplot do valor adicionado industrial *per capita* (R\$/hab.) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 30 apresenta a distribuição do valor adicionado industrial *per capita* para os municípios de Santa Catarina. A região com maior valor adicionado industrial *per capita* médio é a Norte, seguida pelo Vale do Itajaí e as com menor valor adicionado industrial *per capita* médio são a Grande Florianópolis, seguida pela região serrana.

Figura 30 - Distribuição do valor adicionado industrial *per capita* (R\$/hab.) em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.4.2 Valor adicionado de serviço *per capita*

A Tabela 18 apresenta o sumário estatístico do valor adicionado de serviço *per capita* para os municípios de Santa Catarina.

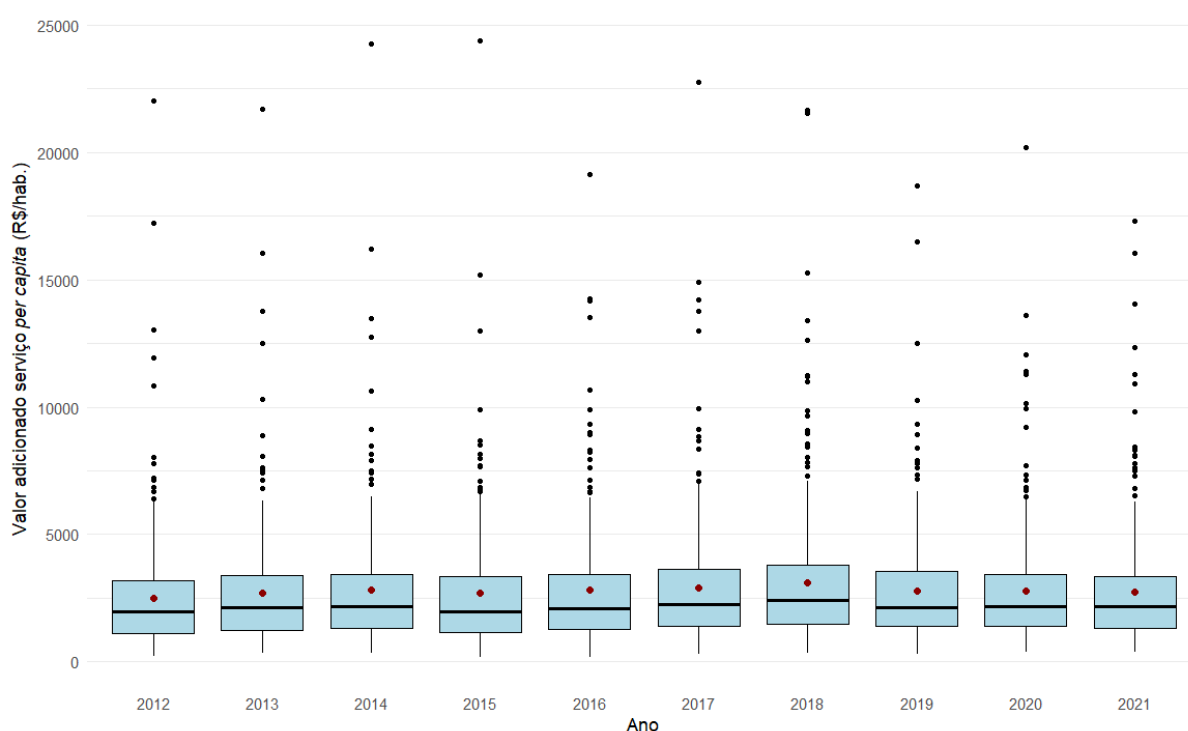
Tabela 18 - Sumário estatístico do valor adicionado de serviço *per capita*

Ano	Obser- vações	Mínimo (R\$)	1º Q (R\$)	Mediana (R\$)	Média (R\$)	3º Q (R\$)	Máximo (R\$)	Desvio Padrão (R\$)
2012	295	206,74	1.103,46	1.956,26	2.508,52	3.200,19	22.041,40	2.332,94
2013	295	311,82	1.234,60	2.118,21	2.711,34	3.388,35	21.704,81	2.371,50
2014	295	321,73	1.321,63	2.174,86	2.814,04	3.423,29	24.263,00	2.467,94
2015	295	173,81	1.135,20	1.973,10	2.693,66	3.344,38	24.377,74	2.439,88
2016	295	181,99	1.287,08	2.097,53	2.801,34	3.431,81	19.160,48	2.414,56
2017	295	302,05	1.385,39	2.231,82	2.892,78	3.628,81	22.761,46	2.520,65
2018	295	341,68	1.478,69	2.393,01	3.111,47	3.786,62	21.649,21	2.770,14
2019	295	276,29	1.397,82	2.105,85	2.765,88	3.533,15	18.696,94	2.217,13
2020	295	365,07	1.390,97	2.179,35	2.754,18	3.405,75	20.196,58	2.244,52
2021	295	354,04	1.312,40	2.143,29	2.724,82	3.353,45	17.299,27	2.282,84

Fonte: Elaborado pela autora (2025)

A Figura 31 apresenta os boxplots de valor adicionado de serviço *per capita* anual para os municípios de Santa Catarina. Destacam-se os municípios de São Francisco do Sul e Itapoá, localizados no norte catarinense, cujos desempenhos estão relacionados ao transporte rodoviário de carga e às atividades auxiliares dos transportes aquaviários, respectivamente.

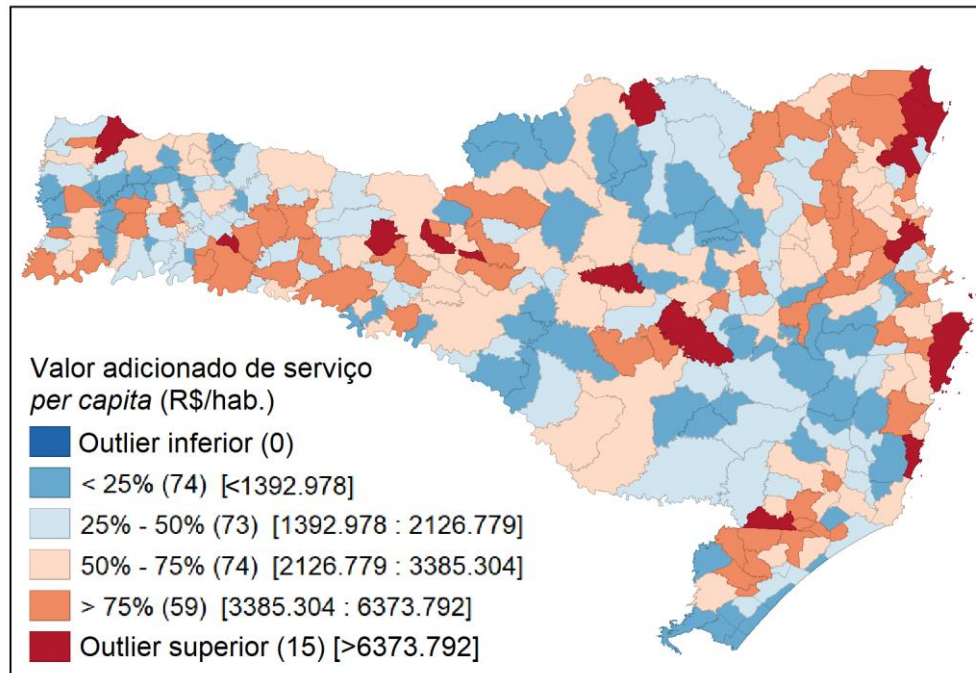
Figura 31 – Gráfico boxplot do valor adicionado de serviço *per capita* (R\$/hab.) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 32 apresenta mapa boxplot referente ao valor adicionado de serviço *per capita* médio em Santa Catarina. A região que se destaca com a maior média de valor adicionado de serviço *per capita* é a região Norte, enquanto a que apresenta o menor valor médio é a região Serrana.

Figura 32 – Mapa boxplot do valor adicionado de serviço *per capita* (R\$/hab.) em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.4.3 Valor adicionado de comércio *per capita*

A Tabela 19 apresenta o sumário estatístico do valor adicionado de comércio *per capita* para os municípios de Santa Catarina.

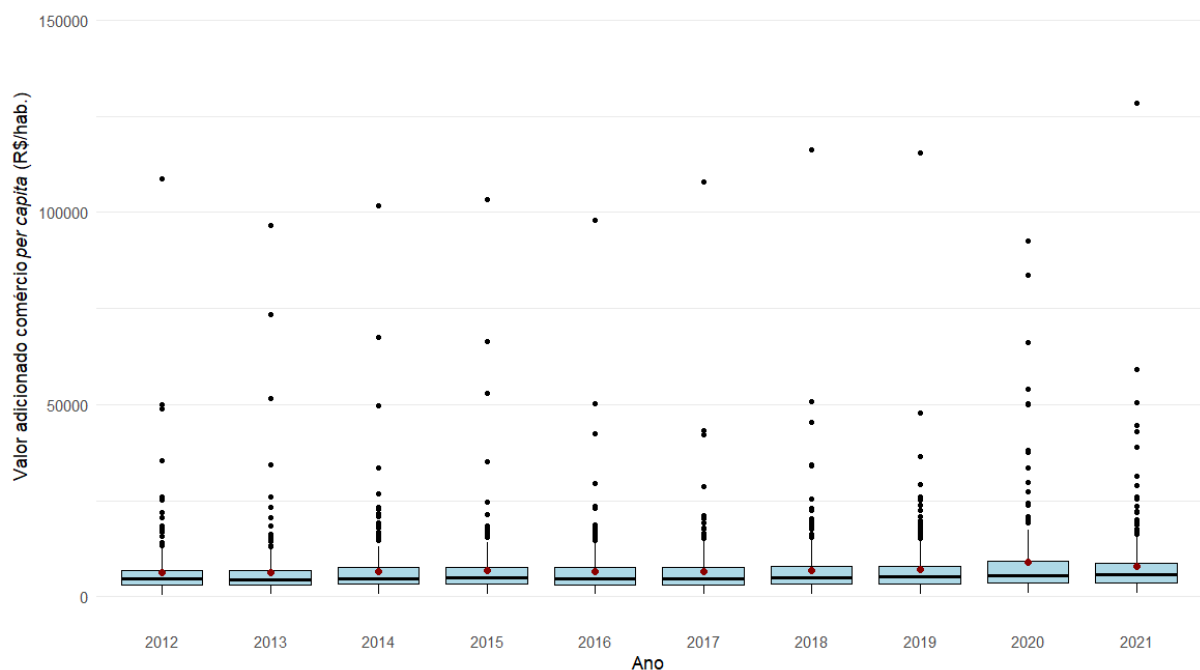
Tabela 19 - Sumário estatístico do valor adicionado de comércio *per capita*

Ano	Observações	Mínimo (R\$)	1º Q (R\$)	Mediana (R\$)	Média (R\$)	3º Q (R\$)	Máximo (R\$)	Desvio Padrão (R\$)
2012	295	418,91	3.075,08	4.576,28	6.242,90	6.945,28	108.775,77	8.172,03
2013	295	590,07	2.987,84	4.465,21	6.238,10	6.799,01	96.622,69	8.190,82
2014	295	680,82	3.224,37	4.755,05	6.674,46	7.521,22	101.691,48	8.356,01
2015	295	620,46	3.227,18	4.868,14	6.743,08	7.753,48	103.221,59	8.388,01
2016	295	538,25	3.204,85	4.660,20	6.503,28	7.726,32	97.865,75	7.536,79
2017	295	631,44	3.206,92	4.672,20	6.448,61	7.766,54	107.932,49	7.738,66
2018	295	624,01	3.280,94	5.052,27	6.976,22	8.055,44	116.128,04	8.640,69
2019	295	702,21	3.388,06	5.257,66	7.054,35	8.036,64	115.467,40	8.355,55
2020	295	801,34	3.722,07	5.547,29	9.009,34	9.375,72	160.614,18	13.692,50
2021	295	821,75	3.675,73	5.690,36	8.045,94	8.743,00	128.475,02	10.210,62

Fonte: Elaborado pela autora (2025)

A Figura 33 apresenta boxplots do valor adicionado de comércio *per capita* anual para os municípios de Santa Catarina. Em todos os anos analisados, o maior valor *per capita* observado foi em Itajaí, com destaque para a atividade de comércio atacadista de produtos.

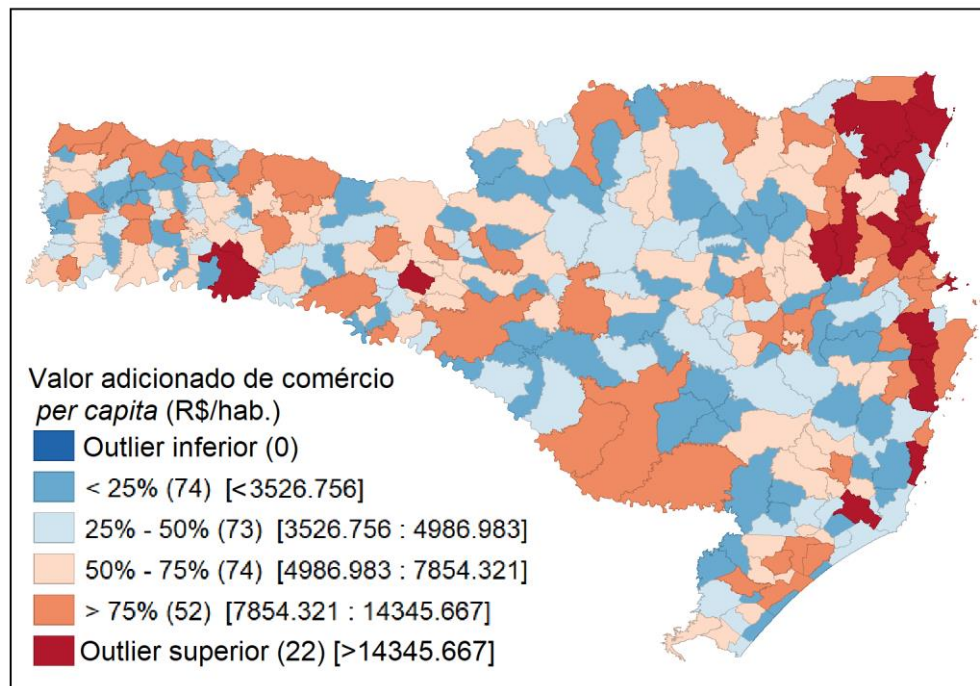
Figura 33 – Gráfico boxplot do valor adicionado de comércio *per capita* (R\$/hab.) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 34 apresenta a distribuição do valor adicionado de comércio *per capita* em Santa Catarina, por meio de mapa boxplot. Destaca-se a região do Vale do Itajaí com o maior média de valor adicionado de comércio *per capita*, seguida pelas regiões Norte e Grande Florianópolis.

Figura 34 – Mapa boxplot do valor adicionado de comércio *per capita* (R\$/hab.) em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.4.4 PIB *per capita*

A Tabela 20 apresenta sumário estatístico do PIB *per capita* para os municípios de Santa Catarina.

Tabela 20 - Sumário estatístico do PIB *per capita*

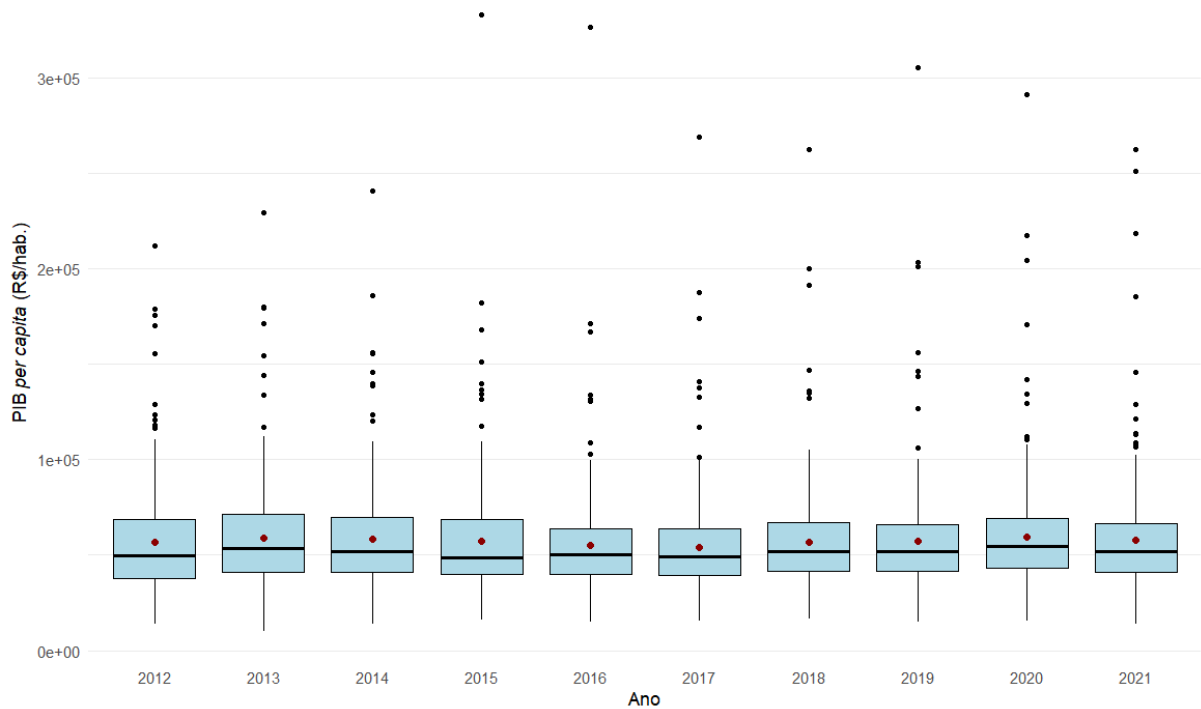
Ano	Observações	Mínimo (R\$)	1º Q (R\$)	Mediana (R\$)	Média (R\$)	3º Q (R\$)	Máximo (R\$)	Desvio Padrão (R\$)
2012 (m=1)	295	14.438,42	37.921,02	49.923,56	56.666,35	68.958,43	211.959,84	26.899,96
2012 (m=2)	295	11.541,03	37.921,02	49.923,56	56.649,56	68.959,43	211.959,84	26.921,84
2012 (m=3)	295	15.241,34	37.921,02	49.923,56	56.640,68	68.959,43	211.959,84	26.923,06
2013	295	10.168,76	41.087,32	53.271,26	59.136,59	71.316,29	229.262,71	27.335,79
2014	295	13.990,61	41.220,57	51.725,82	58.271,84	69.833,82	240.502,92	26.728,58
2015	295	16.271,72	40.179,56	48.644,71	57.265,91	68.512,09	332.835,81	28.698,85
2016	295	15.068,11	40.208,85	50.113,45	55.361,91	64.046,16	326.677,68	26.457,19
2017	295	15.606,83	39.223,03	49.305,93	54.026,07	63.557,65	268.716,75	25.221,85
2018	295	16.465,56	41.472,97	51.628,93	56.383,35	67.266,37	262.587,91	25.826,12

Ano	Observações	Mínimo (R\$)	1º Q (R\$)	Mediana (R\$)	Média (R\$)	3º Q (R\$)	Máximo (R\$)	Desvio Padrão (R\$)
2019	295	15.160,78	41.749,86	51.753,44	57.261,12	66.079,08	305.207,49	27.688,20
2020	295	15.559,25	43.081,05	54.847,48	59.313,01	69.150,24	291.016,16	28.064,87
2021	295	13.930,16	41.282,22	52.037,56	57.922,18	66.685,32	262.702,44	29.029,84

Fonte: Elaborado pela autora (2025)

A Figura 35 apresenta boxplot do PIB *per capita* anual para os municípios de Santa Catarina. Observa-se que os municípios de Vargeão e Piratuba, localizados na região oeste, assim como Itajaí, no Vale do Itajaí, destacam-se com os maiores valores de PIB *per capita* ao longo da série histórica.

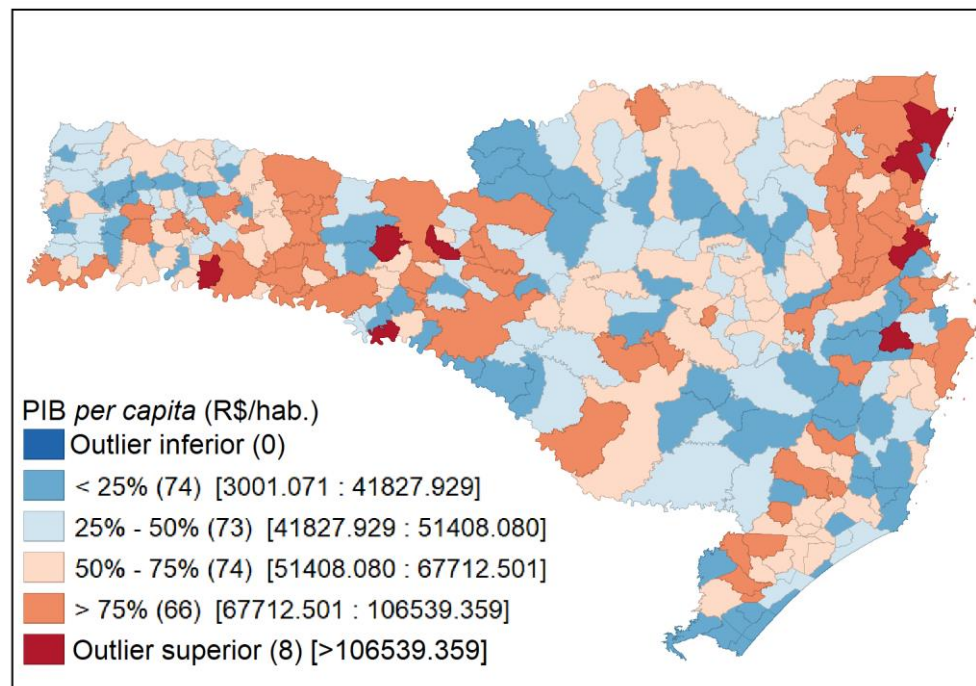
Figura 35 – Gráfico boxplot do PIB *per capita* (R\$/hab.) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 36 apresenta mapa boxplot com os valores de PIB *per capita* para os municípios de Santa Catarina. A região norte do estado apresenta a maior média de PIB *per capita*.

Figura 36 – Mapa boxplot do PIB *per capita* (R\$/hab.) anual médio em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.5 POPULAÇÃO

A Tabela 21 apresenta o sumário estatístico da população anual para os municípios de Santa Catarina.

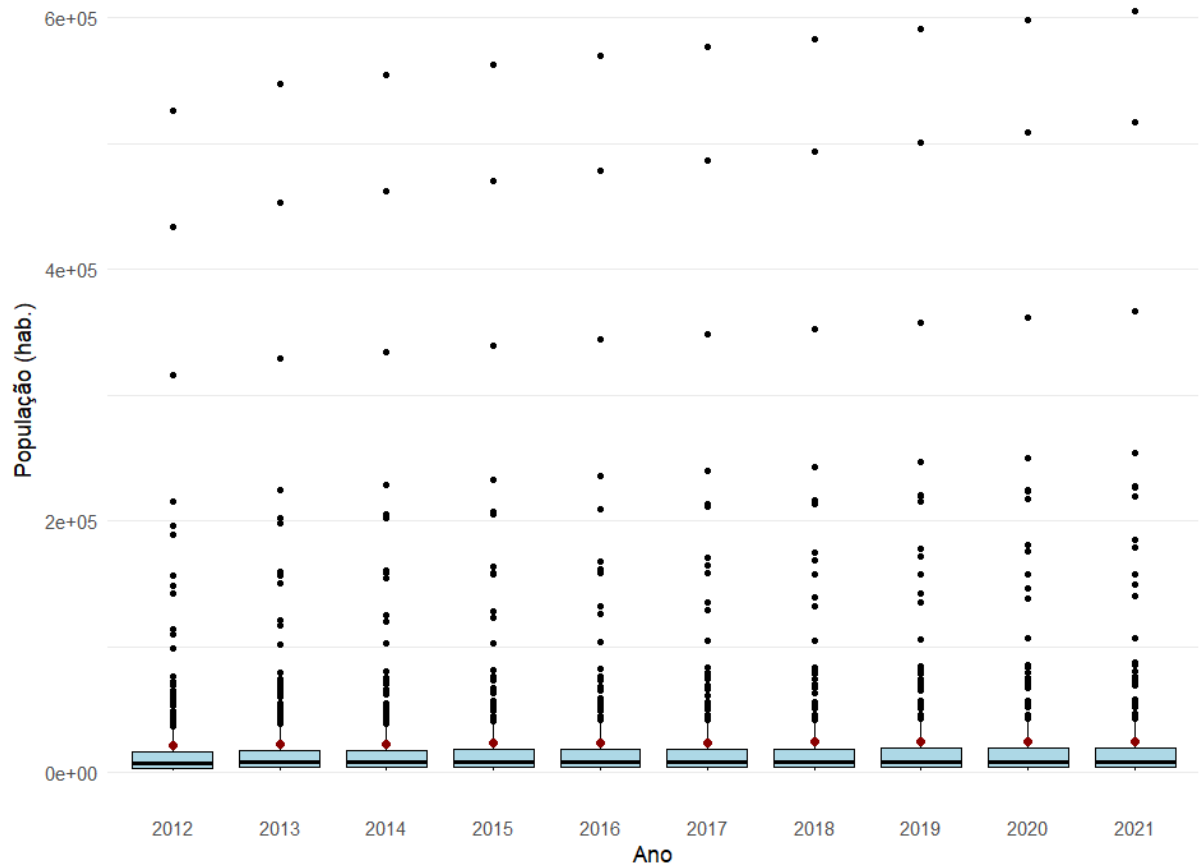
Tabela 21 - Sumário estatístico população municipal anual

Ano	Observações	Mínimo (R\$x10 ³)	1º Q (R\$x10 ³)	Mediana (R\$x10 ³)	Média (R\$x10 ³)	3º Q (R\$x10 ³)	Máximo (R\$x10 ³)	Desvio Padrão (R\$x10 ³)
2012	295	1.431,00	3.559,00	7.566,00	21.638,26	16.793,50	526.338,00	51.748,48
2013	295	1.414,00	3.652,50	7.747,00	22.489,00	17.444,50	546.981,00	53.981,71
2014	295	1.389,00	3.686,50	7.732,00	22.803,89	17.662,00	554.601,00	5.4861,36
2015	295	1.365,00	3.708,50	7.881,00	23.115,90	17.947,50	562.151,00	55.734,87
2016	295	1.341,00	3.685,00	7.829,00	23.425,60	18.118,00	569.645,00	56.603,75
2017	295	1.317,00	3.699,50	7.877,00	23.732,75	18.468,00	577.077,00	57.466,91
2018	295	1.286,00	3.712,50	7.889,00	23.984,73	18.656,00	583.144,00	58.212,67
2019	295	1.260,00	3.687,50	7.934,00	24.287,42	18.847,00	590.466,00	59.071,56
2020	295	1235,00	3.670,50	7.991,00	24.584,75	19.035,50	597.658,00	59.916,65
2021	295	1211,00	3636,00	8054,00	24.876,00	19.219,50	604.708,00	60.746,34

Fonte: Elaborado pela autora (2025)

A Figura 37 apresenta boxplots da população para os municípios de Santa Catarina. O município com maior população em toda a série histórica é Joinville, região norte, seguido por Florianópolis e Blumenau.

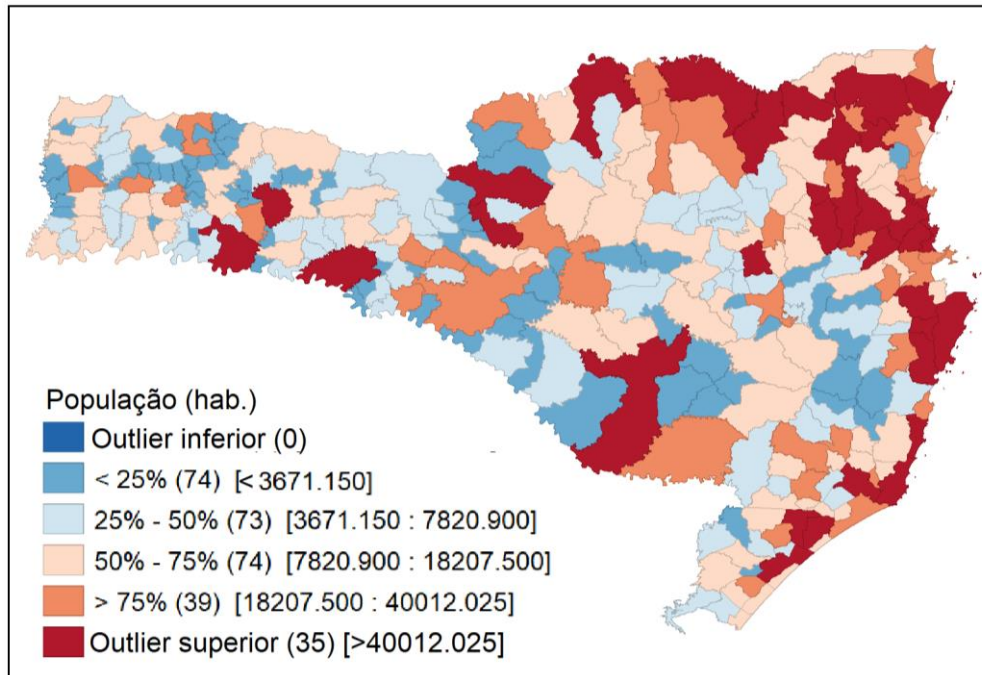
Figura 37 – Gráfico boxplot da População (hab.) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 38 apresenta mapa boxplot da população municipal em Santa Catarina. A região da Grande Florianópolis apresenta a maior população média do estado. Nota-se que os *outliers* superiores correspondem a municípios com população acima de 40.012 habitantes, valor que, embora não seja elevado em termos absolutos, destaca-se no contexto demográfico estadual.

Figura 38 – Mapa boxplot da população (hab.) em Santa Catarina (2012-2021)

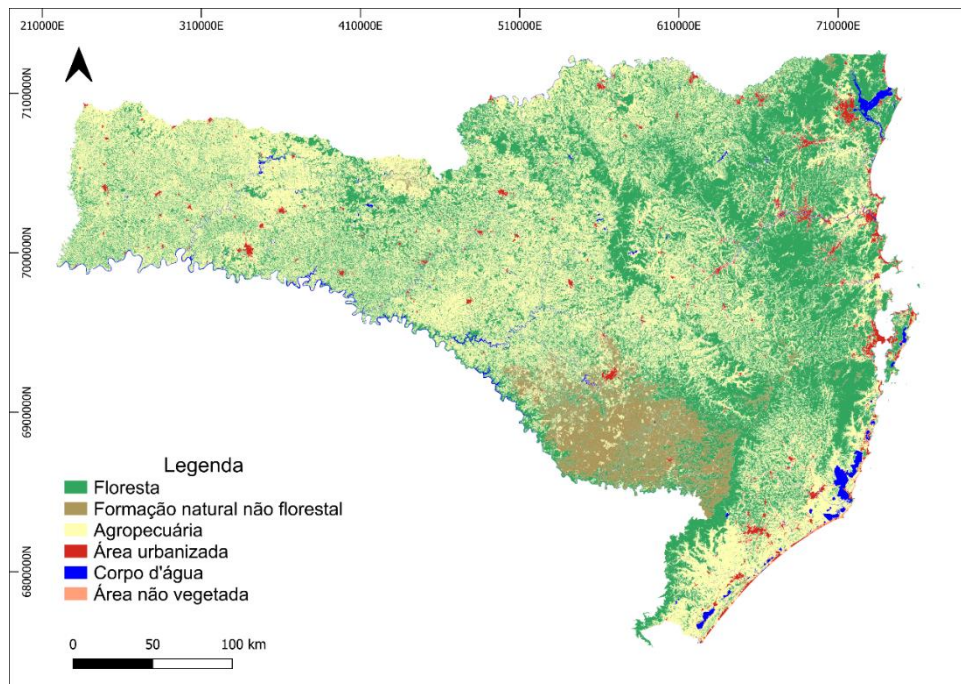


Fonte: Elaborado pela autora (2025)

4.6 DADOS CLASSIFICAÇÃO DE USO DO SOLO

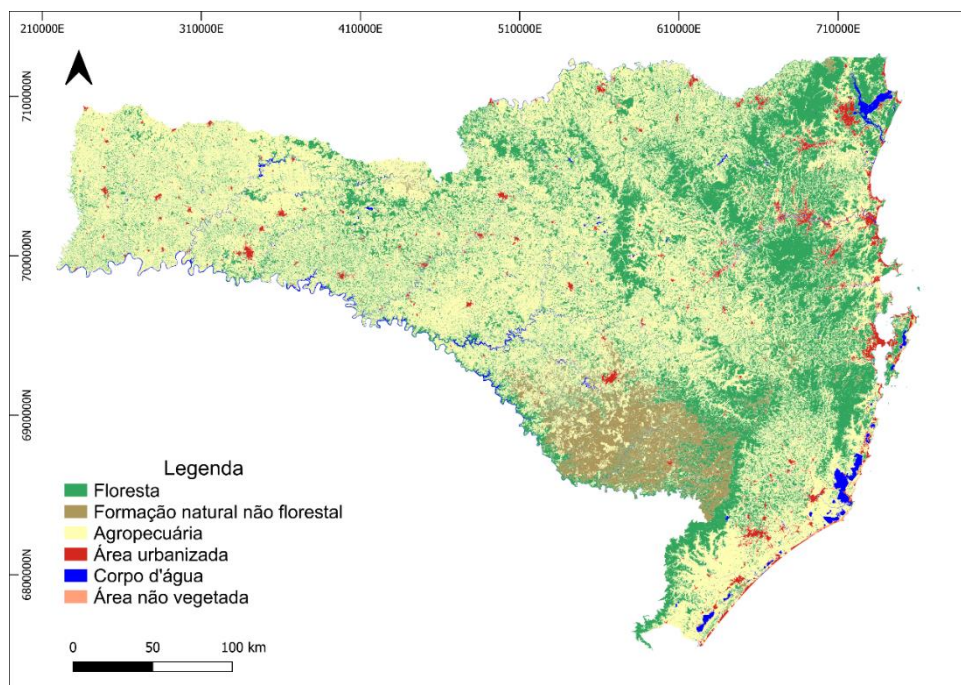
Esta seção apresenta a estatística descritiva dos dados obtidos de classificação obtidos a partir do MapBiomas. A Figura 39 e a Figura 40 apresentam o uso do solo em Santa Catarina para os anos de 2012 e 2021.

Figura 39 - Uso do solo em Santa Catarina (2012)



Fonte: Elaborado pela autora (2025)

Figura 40 - Uso do solo em Santa Catarina (2021)



Fonte: Elaborado pela autora (2025)

A análise das mudanças do uso do solo entre os anos de 2012 e 2021 revela a dinâmica entre as classes analisadas: floresta, formação natural não florestal, agropecuária, área não vegetada, área urbana e corpo d'água. Com base no gráfico

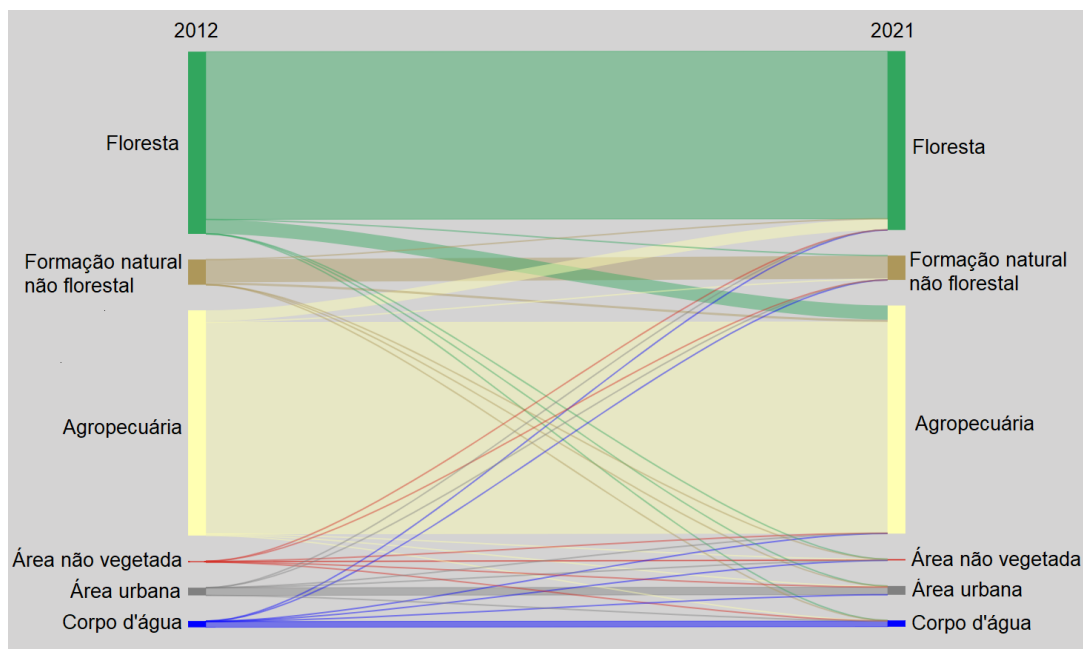
de Sankey (Figura 41), observa-se tanto a permanência quanto as conversões entre essas categorias.

A classe floresta apresentou taxa de permanência de 92% da área original, sendo o restante convertido para outras categorias, em destaque para agropecuária (3.409 km²), pequenas proporções também foram destinadas a áreas urbanas, corpos d'água, áreas não vegetadas e formações naturais não florestais.

A classe agropecuária apresentou taxa de permanência de 94%. É a classe que mais incorporou áreas, destacando-se a absorção de floresta, formação natural não florestal e corpo d'água. Por outro lado, aproximadamente 2.650 km² de área agropecuária foram revertidas para cobertura florestal.

Em relação à área de formação natural não florestal, a taxa de permanência foi de 87%, sendo observadas conversões tanto para agropecuária quanto para áreas urbanas e corpo d'água. A classe urbana apresentou alta taxa de permanência, de 99,6%. A classe apresentou crescimento, incorporando 270 km² proveniente de outras categorias. O acréscimo representa aumento de 14,6% em relação à área urbana de 2012.

Figura 41 - Transição do uso do solo (2012 - 2021)



Fonte: Elaborado pela autora (2025)

Para as variáveis relacionadas ao uso do solo, optou-se por utilizar a proporção de área (isto é, a razão entre a área de determinada classe de uso e a área total do

município), em vez de valores absolutos. Essa escolha se justifica pelo fato de que municípios com pequena extensão territorial naturalmente apresentariam áreas absolutas menores, o que poderia enviesar a análise. Como a variável dependente do modelo é o consumo de água *per capita*, é coerente que os determinantes espaciais também sejam expressos de forma relativa, permitindo comparabilidade entre municípios de diferentes tamanhos e evitando distorções associadas à escala territorial.

4.6.1 Área de floresta

A Tabela 22 apresenta o sumário estatístico referente à área de floresta dos municípios de Santa Catarina.

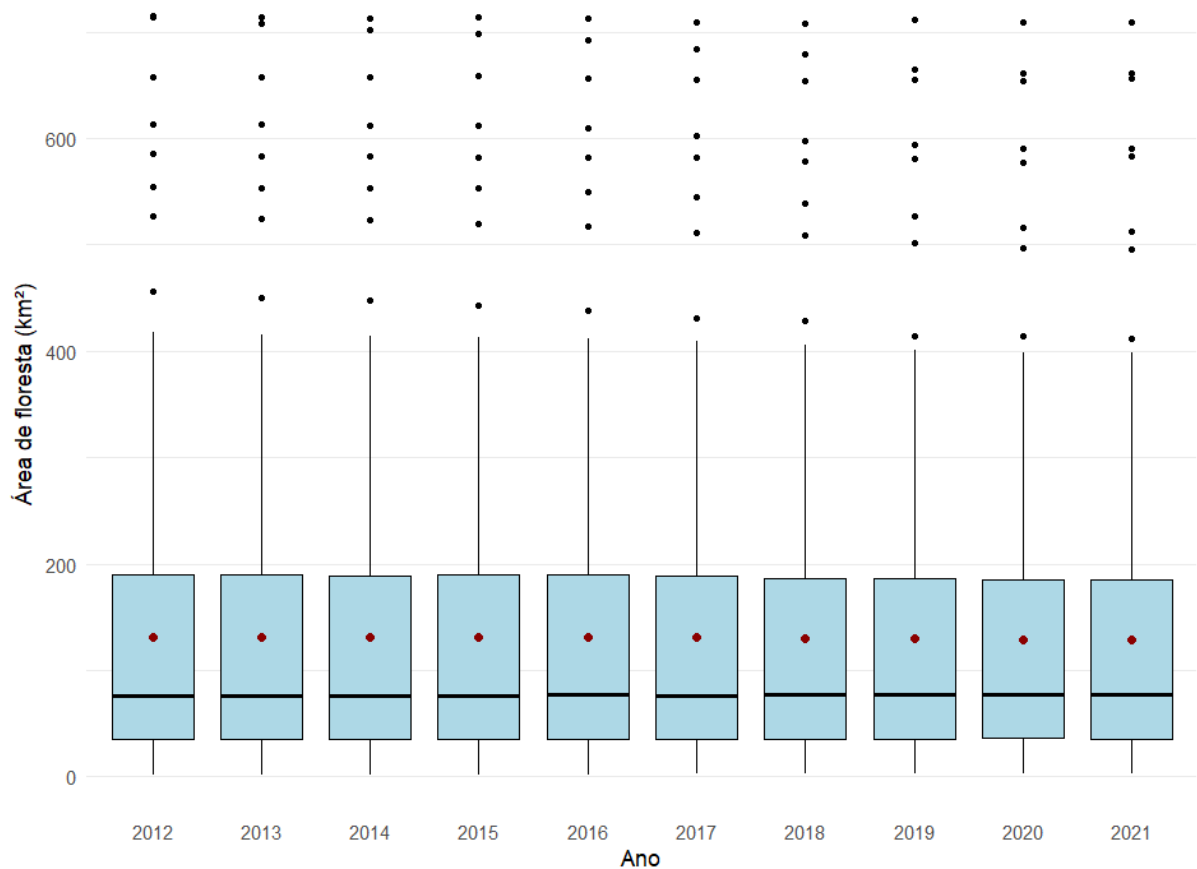
Tabela 22 – Sumário estatístico de área de floresta municipal anual

Ano	Observações	Mínimo (km²)	1º Q (km²)	Mediana (km²)	Média (km²)	3º Q (km²)	Máximo (km²)	Desvio Padrão (km²)
2012	295	1,94	35,14	76,12	131,57	190,49	714,60	133,35
2013	295	2,17	35,12	76,22	131,61	190,18	713,53	132,96
2014	295	2,27	34,90	75,91	131,35	189,29	713,16	132,53
2015	295	2,33	35,16	76,67	131,61	189,83	714,26	132,53
2016	295	2,28	35,12	76,97	131,28	190,25	712,88	132,22
2017	295	2,51	35,65	76,58	130,97	188,47	709,03	131,69
2018	295	2,53	35,85	77,36	130,63	186,52	707,30	131,18
2019	295	2,47	35,61	76,74	129,73	186,17	710,94	130,12
2020	295	2,56	35,95	76,86	129,18	185,39	708,95	129,41
2021	295	2,57	35,91	76,80	129,16	185,77	709,22	129,46

Fonte: Elaborado pela autora (2025)

A Figura 42 apresenta gráfico boxplot da área de floresta para os municípios. Os municípios com maiores áreas de floresta são Itaiópolis e Joinville, ambas na região norte do estado.

Figura 42 – Gráfico boxplot da área de floresta (km²) municipal anual (2012-2021)



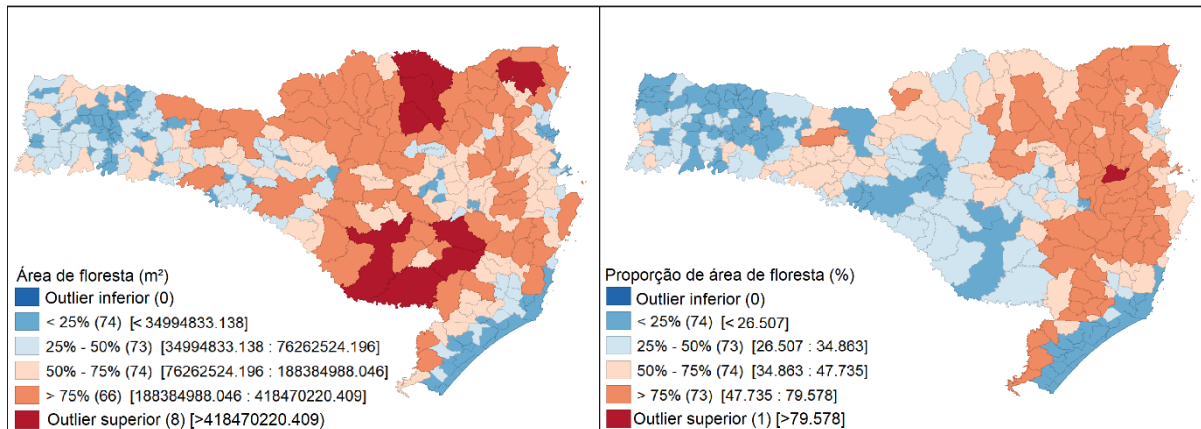
Fonte: Elaborado pela autora (2025)

A Figura 43 apresenta a distribuição espacial da área média total de floresta e da proporção média de área de floresta por município no estado de Santa Catarina. O mapa à esquerda representa os valores absolutos de cobertura florestal, enquanto o da direita mostra a proporção relativa em relação à área total de cada município.

No mapa de área absoluta, observa-se que os maiores valores de cobertura florestal se concentram em municípios com grande extensão territorial, especialmente na regiões Serrana e Norte do estado. Esses municípios apresentam extensas áreas de floresta, mas não necessariamente possuem alta densidade florestal.

O mapa de proporção de área de floresta mostra que apenas um município, Botuverá, localizado no Vale do Itajaí, se destaca como *outlier* superior, apresentando mais de 80% de sua área total coberta por floresta. Esse dado evidencia que municípios com alta proporção de cobertura florestal não coincidem, necessariamente, com aqueles de maior área florestal absoluta. Assim, nota-se que municípios com extensas áreas florestais podem apresentar baixa proporção florestal quando considerada a sua área territorial total.

Figura 43 – Mapas boxplot da área de floresta em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.6.2 Área de formação natural não florestal

A Tabela 23 apresenta o sumário estatístico referente a área de formação natural não florestal dos municípios de Santa Catarina.

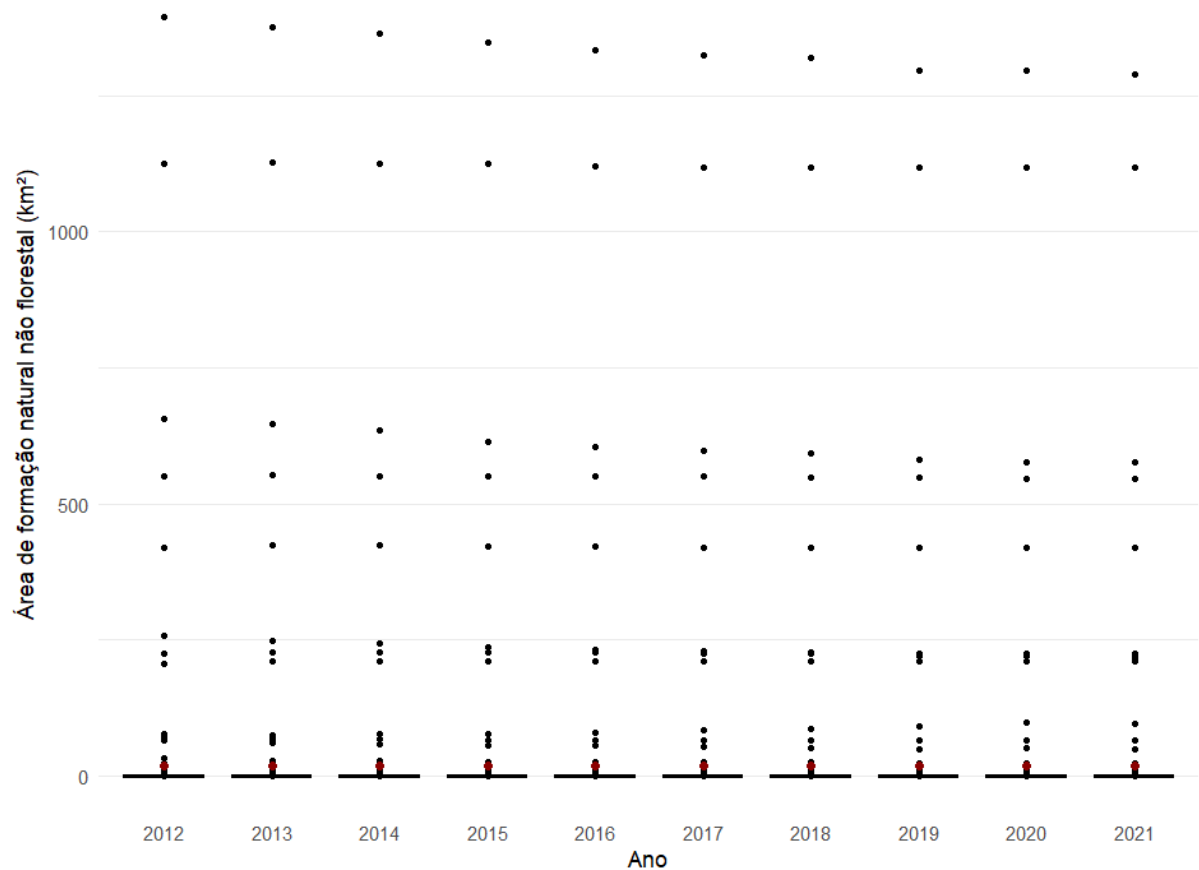
Tabela 23 - Sumário estatístico área de formação natural não florestal municipal anual

Ano	Observações	Mínimo (km²)	1º Q (km²)	Mediana (km²)	Média (km²)	3º Q (km²)	Máximo (km²)	Desvio Padrão (km²)
2012	295	0,00	0,00	0,00	18,04	0,17	1394,33	119,55
2013	295	0,00	0,00	0,00	17,92	0,18	1377,28	118,85
2014	295	0,00	0,00	0,00	17,83	0,19	1365,54	118,08
2015	295	0,00	0,00	0,00	17,68	0,22	1347,89	116,93
2016	295	0,00	0,00	0,00	17,59	0,24	1334,89	116,11
2017	295	0,00	0,00	0,00	17,54	0,24	1325,69	115,48
2018	295	0,00	0,00	0,00	17,53	0,26	1319,10	115,04
2019	295	0,00	0,00	0,00	17,40	0,27	1295,52	113,93
2020	295	0,00	0,00	0,00	17,45	0,29	1296,32	113,94
2021	295	0,00	0,00	0,00	17,40	0,31	1290,74	113,65

Fonte: Elaborado pela autora (2025)

A Figura 44 apresenta gráfico boxplot da área de formação não natural para os municípios. O município com maior área de formação natural não florestal é Lages, na região Serrana.

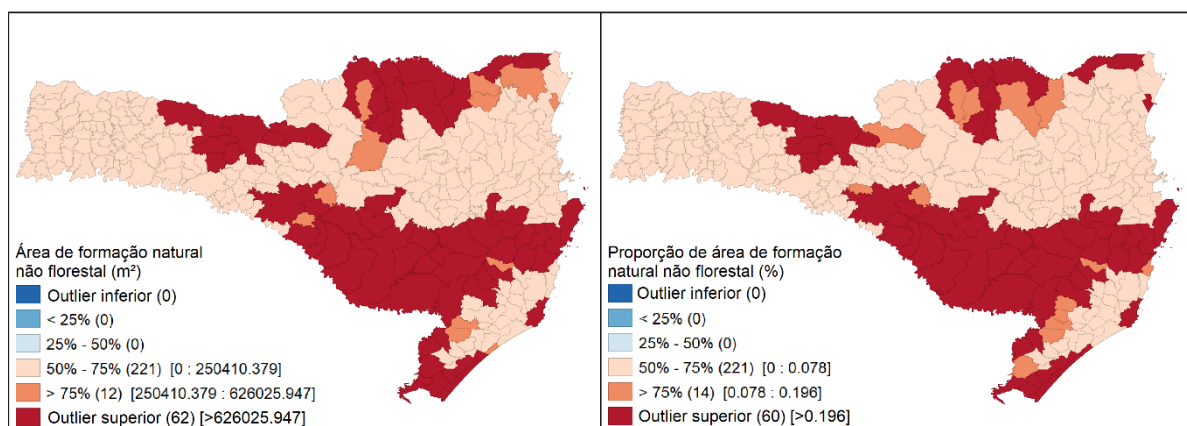
Figura 44 – Gráfico boxplot da área de formação natural não florestal (km²) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 45 apresenta a área média de formação natural não florestal e a proporção média da área de formação natural não florestal por município em mapas boxplot. Observa-se alta concentração espacial dessa cobertura, tanto em valores absolutos quanto proporcionais. O mapa da esquerda revela que a maior parte dos municípios possui valores médios baixos ou nulos de área de formação natural não florestal. De fato, a mediana da série histórica é igual a zero, indicando que mais da metade dos municípios não apresenta esse tipo de uso do solo.

Figura 45 – Mapas boxplot da área de formação natural não florestal em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.6.3 Área de agropecuária

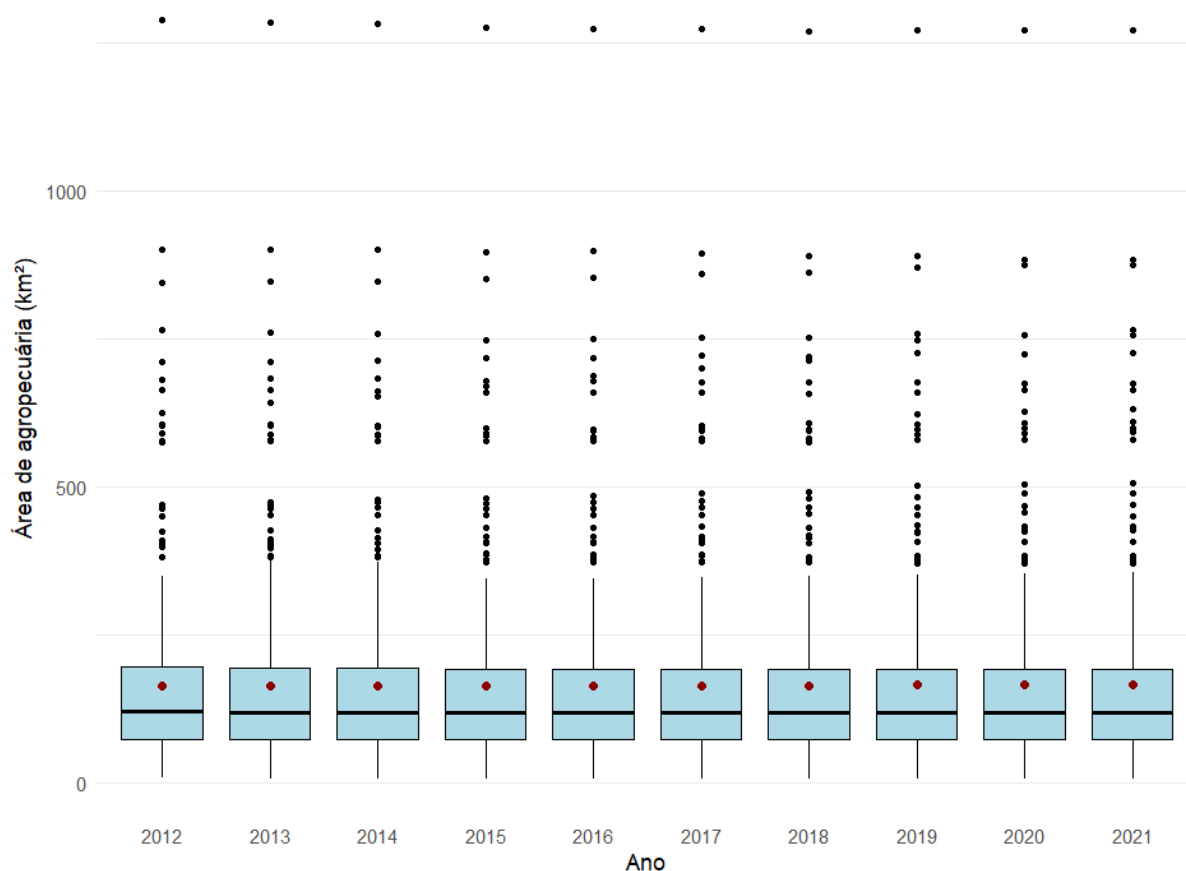
A Tabela 24 apresenta o sumário estatístico e a Figura 46 apresenta gráfico boxplot referentes à área de agropecuária dos municípios de Santa Catarina.

Tabela 24 - Sumário estatístico área de agropecuária municipal

Ano	Observações	Mínimo (km²)	1º Q (km²)	Mediana (km²)	Média (km²)	3º Q (km²)	Máximo (km²)	Desvio Padrão (km²)
2012	295	6,77	71,43	118,98	162,66	194,77	1287,70	156,96
2013	295	6,42	71,52	118,36	162,56	193,64	1284,83	157,33
2014	295	6,19	71,81	118,01	162,73	192,60	1281,00	157,37
2015	295	6,04	71,57	117,29	162,50	191,90	1276,48	157,33
2016	295	6,08	71,73	117,13	162,77	191,08	1273,16	157,53
2017	295	5,91	71,58	117,36	163,05	190,25	1272,98	157,88
2018	295	5,88	71,74	117,76	163,31	189,99	1269,12	157,98
2019	295	5,91	71,97	118,03	164,24	190,10	1272,23	159,41
2020	295	5,92	71,96	118,75	164,69	190,35	1270,78	159,66
2021	295	5,88	71,83	117,20	164,68	190,09	1270,70	159,94

Fonte: Elaborado pela autora (2025)

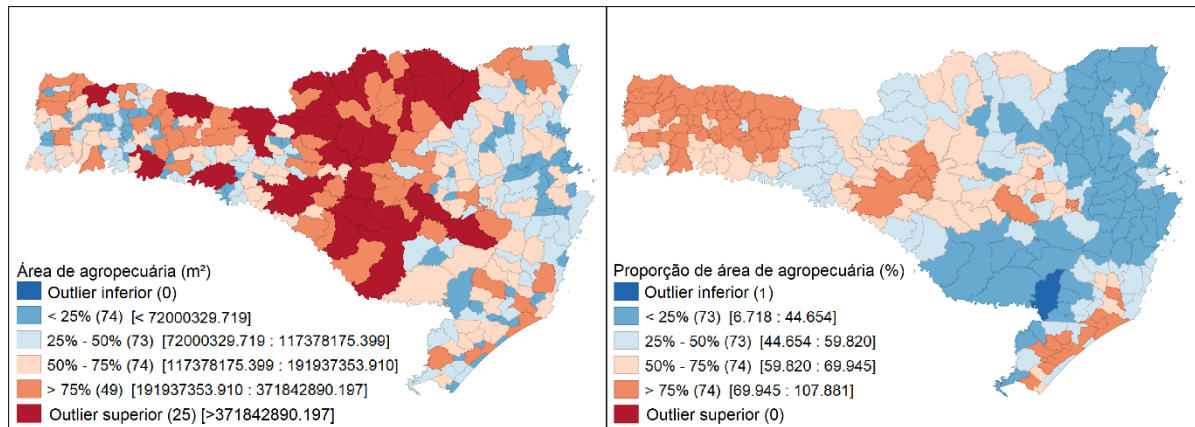
Figura 46 – Gráfico boxplot da área agropecuária (km²) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 47 apresenta a área média de agropecuária e a proporção média de área de agropecuária por município em mapas boxplot. Os dois mapas evidenciam dinâmicas distintas entre a extensão territorial ocupada e a proporção de uso do solo para fins agropecuários. No mapa de área, destacam-se principalmente os municípios das regiões Oeste, Norte e Serrana. Por outro lado, a distribuição proporcional revela padrão mais homogêneo, com a presença de apenas um *outlier* inferior. Observa-se que municípios das regiões Oeste, Sul e Serrana se destacam por apresentarem alta proporção de seu território ocupado por áreas agropecuárias.

Figura 47 – Mapas boxplot da área de agropecuária em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.6.4 Área urbana

A Tabela 25 apresenta o sumário estatístico da variável referente à área urbana municipal. Nota-se que a média da área urbana apresenta um aumento gradual ao longo dos anos, refletindo o crescimento urbano em Santa Catarina.

Tabela 25 - Sumário estatístico da área urbana municipal

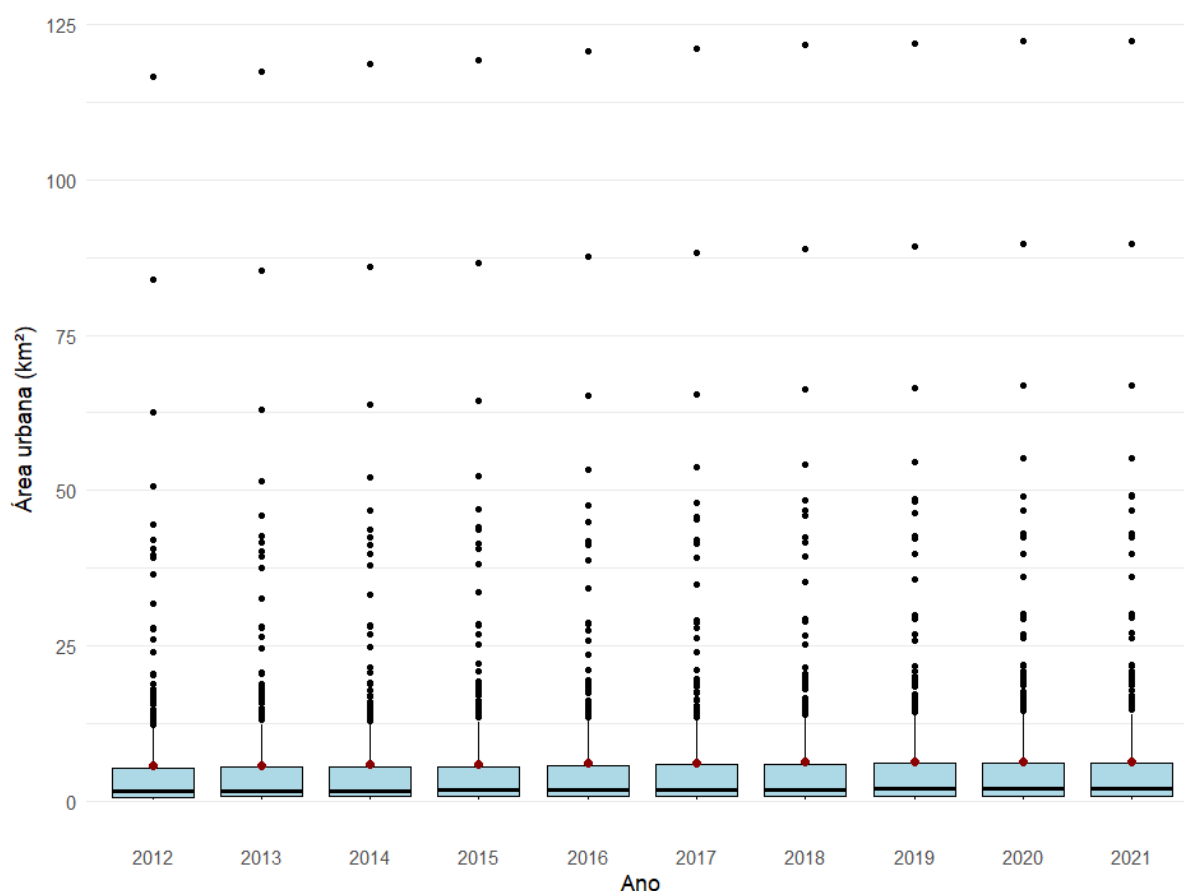
Ano	Observações	Mínimo (km²)	1º Q (km²)	Mediana (km²)	Média (km²)	3º Q (km²)	Máximo (km²)	Desvio Padrão (km²)
2012	295	0,15	0,62	1,59	5,56	5,19	116,53	11,68
2013	295	0,15	0,64	1,63	5,67	5,35	117,36	11,84
2014	295	0,15	0,65	1,65	5,78	5,44	118,67	12,00
2015	295	0,15	0,69	1,68	5,88	5,56	119,30	12,11
2016	295	0,16	0,72	1,76	6,00	5,70	120,61	12,28
2017	295	0,16	0,73	1,77	6,09	5,80	121,15	12,38
2018	295	0,17	0,75	1,81	6,19	5,93	121,64	12,50
2019	295	0,17	0,77	1,88	6,28	6,06	121,87	12,60
2020	295	0,17	0,78	1,91	6,35	6,10	122,26	12,68
2021	295	0,17	0,78	1,92	6,35	6,10	122,28	12,69

Fonte: Elaborado pela autora (2025)

O gráfico boxplot apresenta a distribuição da área urbana dos municípios de Santa Catarina para o período de 2012 a 2021 (Figura 48). Cada boxplot apresenta a dispersão da área urbana em cada ano. Grande parte dos municípios possui área

urbana concentrada em valores mais baixos. Esse padrão revela desigualdade na extensão urbana entre os municípios catarinenses, em que a maioria possui áreas urbanas pequenas, enquanto alguns se destacam com área urbana maior. O município com maior área urbana para toda a série histórica é Joinville, seguido por Florianópolis e Blumenau.

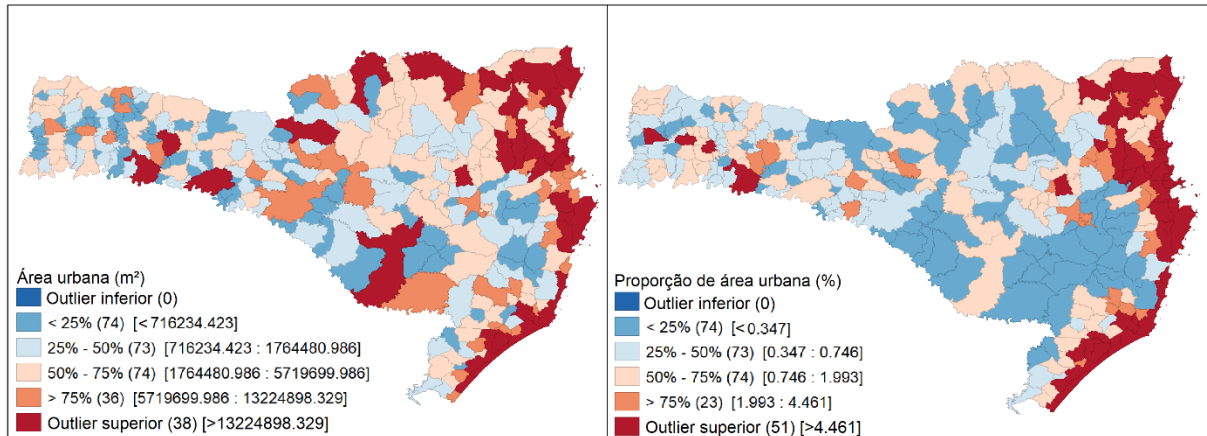
Figura 48 – Gráfico boxplot da área urbana (km²) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

O mapa boxplot apresenta a área média urbana e a proporção média de área urbana (Figura 49) dos municípios de Santa Catarina. Nota-se que municípios com alta densidade urbana proporcional estão majoritariamente localizados ao longo do litoral. A presença de 51 outliers superiores indica que diversos municípios possuem elevado grau de urbanização relativa, ainda que nem todos apresentem grandes extensões absolutas de área urbana.

Figura 49 –Mapas boxplot da área urbana em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.6.5 Área de corpo d'água

A Tabela 26 apresenta o sumário estatístico referente à área de corpo d'água dos municípios de Santa Catarina.

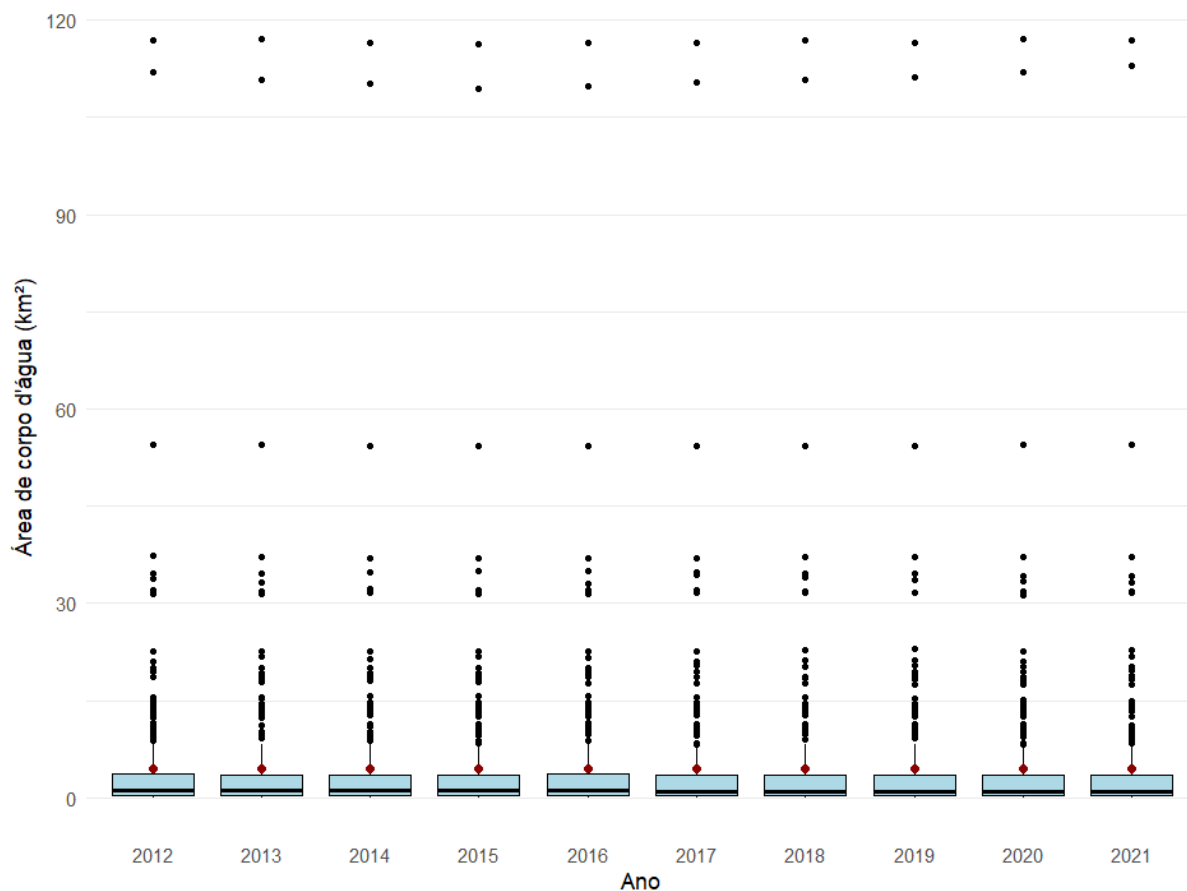
Tabela 26 - Sumário estatístico área de corpo d'água

Ano	Observações	Mínimo (km²)	1º Q (km²)	Mediana (km²)	Média (km²)	3º Q (km²)	Máximo (km²)	Desvio Padrão (km²)
2012	295	0,01	0,34	1,09	4,47	3,68	116,99	11,36
2013	295	0,01	0,30	1,08	4,51	3,62	117,03	11,36
2014	295	0,01	0,34	1,09	4,53	3,55	116,47	11,33
2015	295	0,01	0,35	1,10	4,52	3,54	116,35	11,30
2016	295	0,01	0,35	1,08	4,53	3,63	116,59	11,33
2017	295	0,01	0,37	1,03	4,50	3,45	116,61	11,35
2018	295	0,01	0,37	1,05	4,49	3,51	116,84	11,36
2019	295	0,01	0,37	1,03	4,48	3,59	116,60	11,36
2020	295	0,01	0,35	1,02	4,46	3,45	117,01	11,38
2021	295	0,01	0,37	1,02	4,50	3,50	116,89	11,43

Fonte: Elaborado pela autora (2025)

A Figura 50 apresenta gráfico boxplot da área de corpo d'água para os municípios de Santa Catarina. Destaca-se a presença de outliers superiores. Os municípios de São Francisco do Sul, Laguna, Imaruí e Pescaria Brava são os que apresentam os maiores valores ao longo do período analisado.

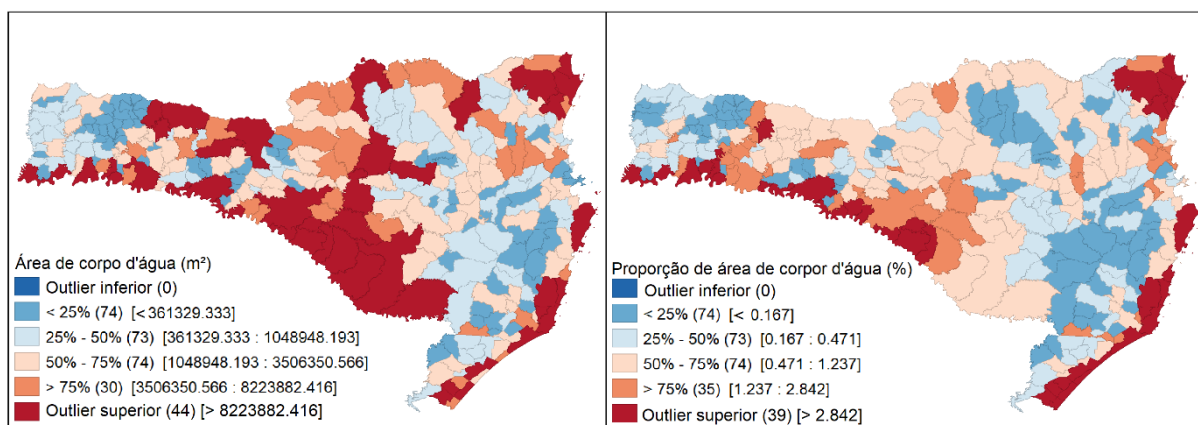
Figura 50 – Gráfico boxplot da área de corpo d'água (km²) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 51 apresenta a área de corpo d'água e a proporção da área de corpo d'água por município em mapas boxplot.

Figura 51 - Distribuição da área de corpo d'água em Santa Catarina (2012-2021)



Fonte: Elaborado pela autora (2025)

4.6.6 Área não vegetada

A Tabela 27 apresenta o sumário estatístico referente a área não vegetada dos municípios de Santa Catarina. Ao longo do período analisado, observa-se aumento gradual da mediana da área não vegetada, passando de 0,18 km² em 2012 para 0,35 km² em 2021.

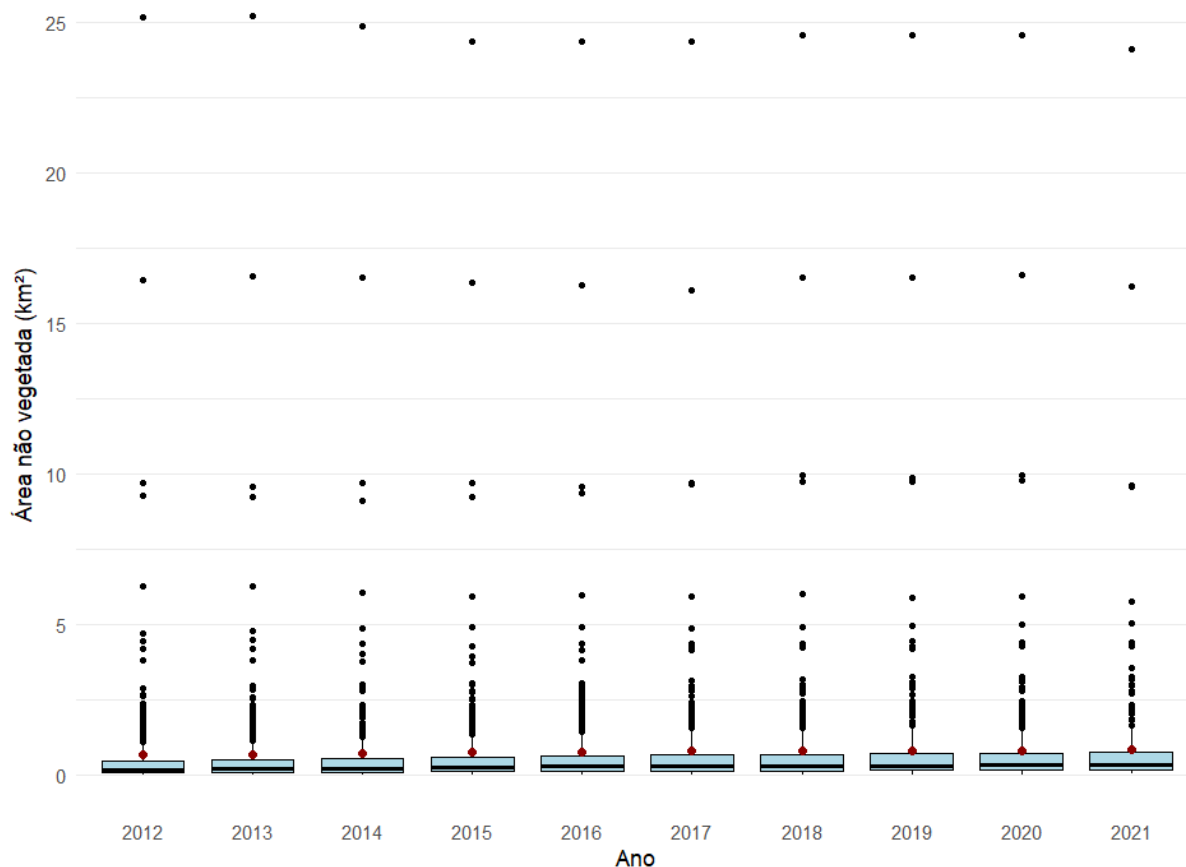
Tabela 27 - Sumário estatístico área não vegetada

Ano	Observações	Mínimo (km ²)	1º Q (km ²)	Mediana (km ²)	Média (km ²)	3º Q (km ²)	Máximo (km ²)	Desvio Padrão (km ²)
2012	295	0,00	0,07	0,18	0,66	0,47	25,19	2,02
2013	295	0,00	0,07	0,20	0,68	0,49	25,20	2,02
2014	295	0,00	0,09	0,22	0,72	0,54	24,89	2,01
2015	295	0,00	0,11	0,25	0,75	0,60	24,37	1,99
2016	295	0,00	0,12	0,28	0,77	0,63	24,37	1,99
2017	295	0,00	0,13	0,29	0,79	0,65	24,36	1,99
2018	295	0,01	0,14	0,29	0,81	0,68	24,58	2,02
2019	295	0,01	0,14	0,30	0,81	0,70	24,56	2,02
2020	295	0,01	0,14	0,32	0,82	0,70	24,58	2,02
2021	295	0,02	0,15	0,35	0,85	0,75	24,11	1,99

Fonte: Elaborado pela autora (2025)

A Figura 52 apresenta gráfico boxplot da área não vegetada para os municípios de Santa Catarina. Observa-se que, em todo o período analisado, a maior parte dos municípios apresenta áreas não vegetadas pequenas, concentradas próximas da mediana. Os municípios de Jaguaruna, Laguna, Imbituba e Florianópolis destacam-se como os com maiores valores de área não vegetada.

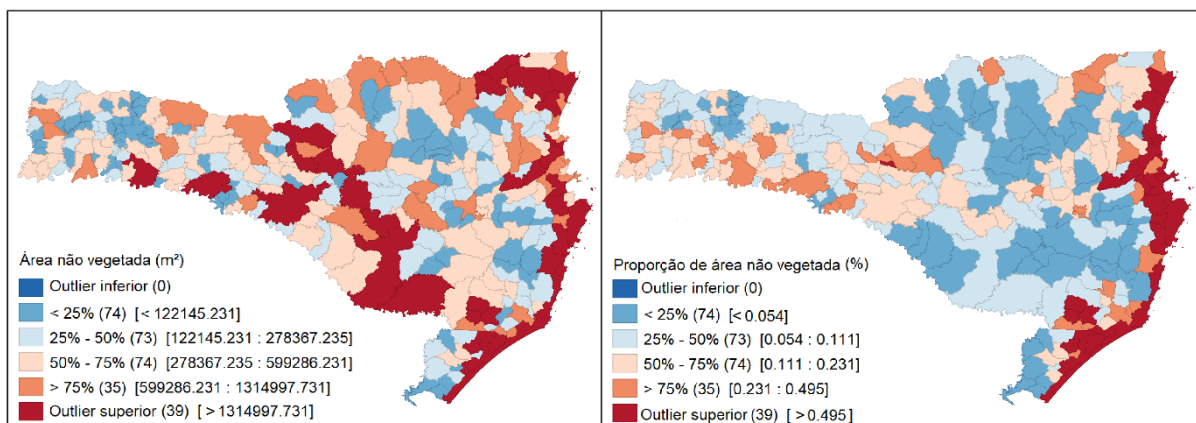
Figura 52 – Gráfico boxplot da área não vegetada (km²) municipal anual (2012-2021)



Fonte: Elaborado pela autora (2025)

A Figura 53 apresenta a área não vegetada e a proporção da área não vegetada por município em mapas boxplot. Observa-se maior concentração de áreas não vegetadas nos municípios localizados no litoral e no sul do estado, refletindo atividades de mineração e a presença de ambientes naturais como praias e dunas, caracterizados pela ausência de cobertura vegetal.

Figura 53 - Distribuição da área não vegetada em Santa Catarina (2012-2021)



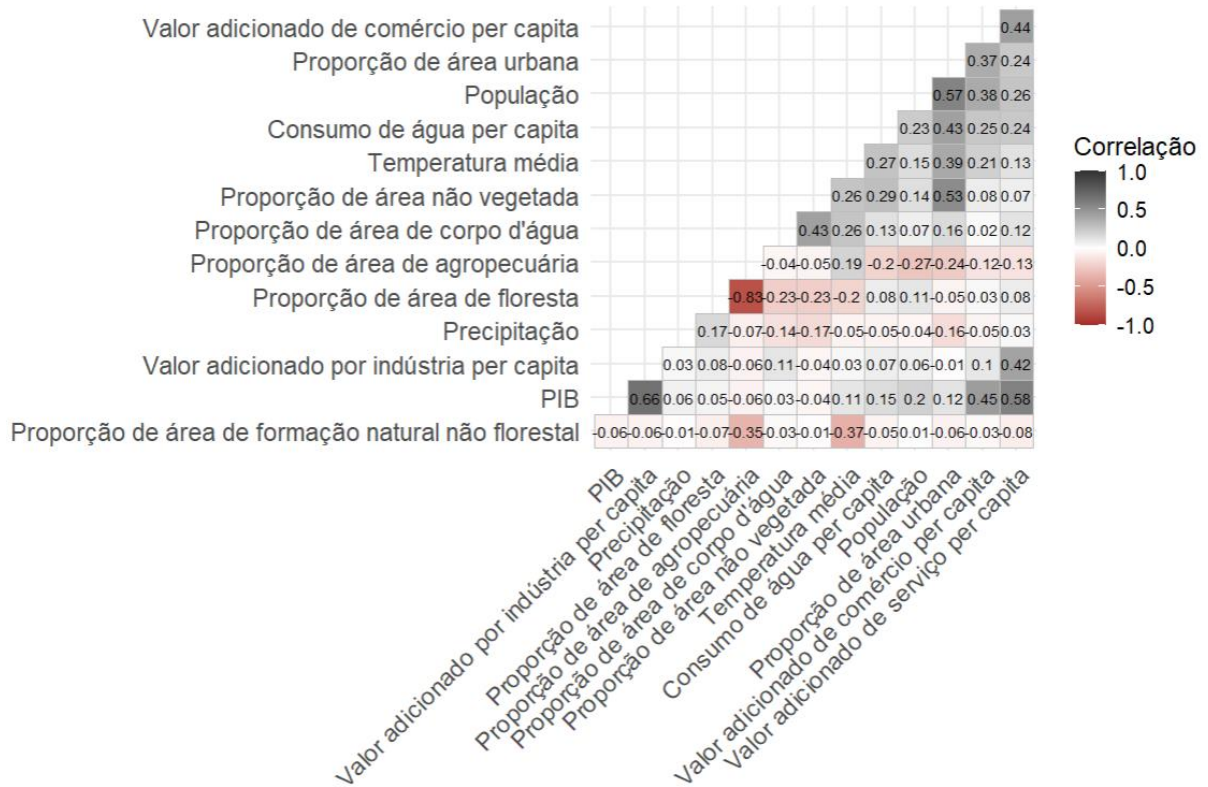
Fonte: Elaborado pela autora (2025)

4.7 REGRESSÃO EM PAINEL

Para a escolha das variáveis do modelo, foi realizada análise de correlação com objetivo de identificar possíveis casos de colinearidade entre as variáveis explicativas. Na matriz de correlação (Figura 54), é possível observar a força e a direção da associação entre as variáveis. A avaliação das correlações permitiu identificar pares de variáveis com alto grau de associação, o que pode comprometer a estabilidade dos coeficientes estimados e a interpretação dos resultados do modelo.

Observa-se correlação positiva e forte entre PIB *per capita* e o valor adicionado por indústria, de serviço e de comércio *per capita*. Essas relações sugerem que essas variáveis podem estar captando dimensões econômicas semelhantes, portanto, optou-se pela exclusão da variável PIB. A variável proporção de área de floresta apresenta correlação negativa e forte com a proporção de área de agropecuária, por essa razão, decidiu-se também pela exclusão da variável proporção de área de floresta.

Figura 54 - Matriz de correlação das variáveis



Fonte: Elaborado pela autora (2025)

As demais variáveis foram testadas quanto à presença de multicolinearidade em modelo OLS sem efeito, e seus resultados estão apresentados na Tabela 28. As variáveis apresentaram VIFs considerados aceitáveis ($VIF < 10$) (Song *et al.*, 2022).

Tabela 28 – Verificação de multicolinearidade

Variável	VIF
Precipitação	1,08
Temperatura média	1,55
População	1,69
Valor adicionado industrial	2,01
Valor adicionado comercial	1,68
Valor adicionado de serviço	1,71
Proporção de área urbana	2,67
Proporção de área não vegetada	1,84
Proporção de área de formação natural não florestal	1,31
Proporção de área de corpo d'água	1,38
Proporção de área de agropecuária	1,38

Fonte: Elaborado pela autora (2025)

Inicialmente, foram gerados quatro modelos com dados em painel sem efeitos de interação espacial (Tabela 29) utilizando o pacote plm (Croissant; Millo, 2008), os resultados para as outras duas imputações estão no Apêndice A. Os modelos foram submetidos a teste de heterocedasticidade, e os resultados indicaram a violação do pressuposto de homocedasticidade. Por conseguinte, foi realizada a correção dos erros-padrão com base na abordagem robusta de Arellano, a qual permite obter erros-padrão robustos à heterocedasticidade e autocorrelação dentro dos grupos, utilizando as unidades amostrais como *clusters* (Álvarez; Barbero; Zofío, 2017).

Tabela 29 - Modelos em painel sem efeitos espaciais

Variável	OLS	Efeitos Fixos (Individuais)	Efeitos Fixos (Tempo)	Efeitos Fixos (Indiv. + Tempo)
Intercepto	71,62 ***	-	-	-
Precipitação	-0,10	$-1,00 \times 10^{-1}$	$2,17 \times 10^{-1}$	$-4,31 \times 10^{-1}$
Temperatura média	3,35 **	$3,82 \times 10^{-1}$	3,78 **	-4,57
População	-3,15	$3,98 \times 10^{-5}$	$-3,08 \times 10^{-5}$	$1,95 \times 10^{-6}$
V.A. indústria <i>per capita</i>	$1,92 \times 10^{-5}$	$1,24 \times 10^{-4}$ **	$1,74 \times 10^{-5}$	$1,14 \times 10^{-4}$ *
V.A. comércio <i>per capita</i>	$2,68 \times 10^{-4}$ •	$1,05 \times 10^{-4}$	$2,55 \times 10^{-4}$ •	$8,27 \times 10^{-5}$
V.A. serviços <i>per capita</i>	$1,56 \times 10^{-3}$ *	$7,39 \times 10^{-4}$ •	$1,56 \times 10^{-3}$ *	$7,42 \times 10^{-4}$
Proporção de área urbana	1,70 **	$-2,96 \times 10^{-1}$	1,66 **	-2,25
Proporção de área de formação natural não florestal	$-1,08 \times 10^{-1}$	-1,60	$-8,46 \times 10^{-2}$	-1,99
Proporção de área de corpo d'água	$-1,99 \times 10^{-1}$	17,28 **	$-2,23 \times 10^{-1}$	16,18 **
Proporção de área de agropecuária	$-3,02 \times 10^{-1}$ **	$-4,14 \times 10^{-1}$	$-3,07 \times 10^{-1}$ **	$-6,52 \times 10^{-1}$
Proporção de área não vegetada	4,44 *	16,63	4,45 *	10,81
R ²	0,246	0,022	0,247	0,019
R ² ajustado	0,243	0,018	0,245	0,015
α^2	866,40	221,48	862,80	219,34
LogL	-14157	-12146	-14152	-12132
LM defasagem espacial	28,55 ***	1,34	25,65 ***	4,12 *
LM robusto defasagem espacial	23,51 ***	0,75	20,76 ***	0,19
LM erro espacial	15,64 ***	1,61	14,24 ***	4,35 *
LM robusto erro espacial	10,60	1,01	9,35 ***	0,43

*** p < 0,001 ** p < 0,01 * p < 0,05 • p < 0,1

Fonte: Elaborado pela autora (2025)

O teste de Hausman foi realizado para comparar os modelos de efeitos fixos e aleatórios com base nas unidades individuais. O resultado indicou valor qui-quadrado

de 36,65 com 11 graus de liberdade e $p\text{-valor} < 0,001$. Com esse resultado, rejeita-se a hipótese nula de que o modelo de efeitos aleatórios é consistente indicando a preferência pelo modelo de efeitos fixos.

Foi realizado o teste LR para verificar se os efeitos fixos individuais são significativos. O resultado do teste (4040,14, com 295 graus de liberdade e $p\text{-valor} < 0,001$) leva à rejeição da hipótese nula de que esses efeitos são conjuntamente não significativos. Da mesma forma, o teste referente aos efeitos fixos de tempo (28,53 com 10 graus de liberdade e $p\text{-valor} = 0,001$) também indica que esses efeitos são estatisticamente significativos. Esses resultados de teste indicam a extensão do modelo para incluir efeitos fixos individuais e de tempo (*two-way* de efeito fixo) (Elhorst, 2014).

No entanto, apesar da significância estatística dos efeitos fixos individuais indicada pelo teste LR, optou-se por manter apenas os efeitos fixos de tempo no modelo. Com base na revisão da literatura e em Elhorst (2014), avaliou-se a expectativa quanto ao comportamento dos coeficientes estimados sob diferentes especificações do modelo. Observa-se estabilidade dos coeficientes estimados e maior capacidade explicativa do modelo com efeitos fixos de tempo, conforme evidenciado pelos valores de R^2 ajustado (0,24) e pela significância estatística das variáveis explicativas. A inclusão dos efeitos fixos individuais, embora estatisticamente recomendável pelo teste LR, resultou em perda de significância de variáveis relevantes. Conforme coloca Elhorst (2014), as unidades espaciais tendem a diferir em variáveis de fundo, que geralmente são variáveis específicas do espaço e invariantes no tempo, mas que afetam a variável dependente, embora sejam difíceis de medir ou obter. No entanto, como todos os modelos já incorporam variáveis explicativas que capturam aspectos abrangentes das unidades, como características econômicas, populacionais, climáticas e de uso do solo, entende-se que parte da heterogeneidade entre os municípios está suficientemente representada. Além disso, a introdução de efeitos espaciais no modelo de efeito fixo de tempo subsequente permite tratar a heterogeneidade entre as unidades geográficas por meio da dependência espacial, ou seja, as diferenças entre os municípios passam a ser modeladas com base nas suas interações espaciais, e não por interceptos fixos. Por conseguinte, o próximo passo da análise consiste em avaliar a incorporação de efeitos espaciais ao modelo com efeitos fixos de tempo.

Os quatro testes LM são significativos para o modelo com efeito fixo de tempo, portanto é desenvolvido o modelo espacial SDM. Para o modelo espacial, a base de dados foi organizada conforme o procedimento descrito em LeSage (2021), com os valores ordenados por ano. Por conseguinte, foram dispostos os dados de todas as unidades para o ano de 2012, seguidos pelos dados de 2013, e assim sucessivamente até o último ano da série. Para o modelo SDM foi utilizada a função “*sdm_panel_FE_g*” com *novi_flag* = 0 para ser tratado como modelo heterocedástico. A propriedade *model* foi definida como 2 para modelo de efeito fixo de tempo.

O modelo SDM é estimado para testar se ele pode ser simplificado para o modelo SAR ou o modelo SEM (Elhorst, 2014). Foi realizado o teste LR para comparar o modelo SDM com os modelos SAR e SEM. O teste entre SDM e SAR (130, 10 graus de liberdade, p-valor <0,001), indica que o modelo SDM não deve ser simplificado no modelo SAR. O teste entre o modelo SDM e SEM (140, 11 graus de liberdade, p-valor < 0,001) também indica que o modelo SDM não deve ser simplificado em modelo SEM.

A Tabela 30 apresenta os coeficientes das variáveis explicativas e das suas defasagens espaciais obtidos para o modelo SDM de efeitos fixos de tempo para $m = 1$, os resultados para as outras duas imputações estão no Apêndice B.

O coeficiente ρ representa o parâmetro de autocorrelação espacial na variável dependente, ou seja, ele mede o quanto o consumo de água *per capita* em um município é influenciado pelo consumo de água nos municípios vizinhos. O valor de $\rho = 0,12$, positivo e estatisticamente significativo, indica que existe uma relação espacial positiva entre os municípios estudados. Isso quer dizer que, quando o consumo de água em um município aumenta, há uma tendência de que os municípios vizinhos também apresentem aumento no consumo de água *per capita*. O coeficiente de estimação do modelo econométrico espacial difere daquele obtido no modelo não espacial, pois o último não consegue representar a influência de uma unidade de mudança na variável independente sobre a variável dependente (Song *et al.*, 2022). Para o modelo econométrico espacial, a mudança na variável independente de uma área levará não apenas a uma mudança nas variáveis dependente local (ou seja, efeito direto), mas também à mudança na variável dependente das áreas vizinhas (ou seja, efeito indireto) (Song *et al.*, 2022). Portanto, a decomposição do efeito é necessária antes da análise (Song *et al.*, 2022). Os coeficientes da Tabela 30 não

refletem diretamente o impacto total das variáveis explicativas sobre o consumo de água *per capita*, pois é necessária a decomposição dos efeitos em diretos, indiretos e totais para uma interpretação adequada. Dessa forma, é possível compreender como as variações nas características de um município influenciam não apenas seu próprio consumo, mas também o consumo dos municípios vizinhos.

Tabela 30 - Coeficientes do SDM com efeitos fixos de tempo

Variável	Coeficiente	Coeficiente defasado espacialmente
Precipitação	-2,26	1,68
Temperatura média	3,44 **	-2,10
População	$-1,8 \times 10^{-5}$ *	$-2,03 \times 10^{-4}$ ***
V.A. indústria <i>per capita</i>	$7,5 \times 10^{-5}$ ***	$1,29 \times 10^{-4}$ **
V.A. comércio <i>per capita</i>	$3,57 \times 10^{-4}$ ***	$-1,3 \times 10^{-4}$
V.A. serviços <i>per capita</i>	$8,55 \times 10^{-4}$ **	$3,6 \times 10^{-3}$ ***
Proporção de área urbana	1,37 ***	2,25 ***
Proporção de área de formação natural não florestal	$-2,5 \times 10^{-1}$ *	$3,7 \times 10^{-1}$ **
Proporção de área de corpo d'água	$-5,9 \times 10^{-1}$ ***	$6,4 \times 10^{-1}$ *
Proporção de área de agropecuária	$-2,7 \times 10^{-1}$ ***	$-2,79 \times 10^{-2}$
Proporção de área não vegetada	6,96 ***	-3,44
ρ	0,12 ***	
R ²	0,27	
R ² ajustado	0,27	

*** p < 0,001 ** p < 0,01 * p < 0,05 • p < 0,1

Fonte: Elaborado pela autora (2025)

Os resultados obtidos por meio do modelo SDM revelam distintas contribuições das variáveis explicativas sobre o consumo de água *per capita*. A Tabela 31 apresenta os efeitos direto, indireto e total do modelo SDM com efeito fixo de tempo. Os resultados para as demais imputações encontram-se no Apêndice C.

Tabela 31 - Efeitos direto, indireto e total do modelo SDM com efeito fixo de tempo

Variável	Efeito direto	Efeito indireto	Efeito total
Precipitação	-2,23	1,57	$-6,6 \times 10^{-1}$
Temperatura média	3,40 **	-1,87	1,53 **
População	$-2,30 \times 10^{-5}$ *	$-2,30 \times 10^{-4}$ ***	$-2,52 \times 10^{-4}$ ***
V.A. indústria <i>per capita</i>	$7,80 \times 10^{-5}$ ***	$1,54 \times 10^{-4}$ **	$2,32 \times 10^{-4}$ ***
V.A. comércio <i>per capita</i>	$3,55 \times 10^{-4}$ ***	$-9,60 \times 10^{-5}$	$2,59 \times 10^{-4}$ ***
V.A. serviços <i>per capita</i>	$9,45 \times 10^{-4}$ ***	$4,24 \times 10^{-3}$ ***	$5,19 \times 10^{-3}$ ***
Proporção de área urbana	1,43 ***	2,70 ***	4,13 ***
Proporção de área de formação natural não florestal	$-2,39 \times 10^{-1}$ *	$3,84 \times 10^{-1}$ **	$1,46 \times 10^{-1}$
Proporção de área de corpo d'água	$-5,76 \times 10^{-1}$ ***	$6,38 \times 10^{-1}$ •	$6,28 \times 10^{-2}$
Proporção de área de agropecuária	$-2,71 \times 10^{-1}$ ***	$-6,83 \times 10^{-2}$	$-3,39 \times 10^{-1}$ ***
Proporção de área não vegetada	6,90 ***	-2,88	4,02 *

*** $p < 0,001$ ** $p < 0,01$ * $p < 0,05$ • $p < 0,1$

Fonte: Elaborado pela autora (2025)

Li *et al.* (2023) afirmam que mudanças nas condições meteorológicas afetam o uso da água, uma vez que essas variações influenciam a percepção e o comportamento dos indivíduos em relação ao consumo. A variável temperatura média apresentou um efeito direto positivo e estatisticamente significativo sobre o consumo de água *per capita*. Esse resultado indica que o aumento da temperatura em uma localidade está associado ao aumento do consumo de água *per capita* nessa mesma localidade. Embora o efeito indireto tenha sido negativo, ele não foi estatisticamente significativo. Como consequência, o efeito total da temperatura sobre o consumo de água permanece positivo e estatisticamente significativo. Este achado também é condizente com os resultados de Fan *et al.* (2017), Makpiboon (2020) e Veiga, Kalbusch e Henning (2023). No estudo de Li *et al.* (2023), o aumento da temperatura ao nível do solo está fortemente associado ao aumento do consumo de água diário urbano e a variável foi a que apresentou maior impacto dentre todas as variáveis climáticas analisadas pelos autores. Acuña *et al.* (2020) afirmam que temperaturas mais elevadas afetam as atividades externas, como regar jardins, encher piscinas e lavar carros, e também intensificam o uso interno da água, como a maior frequência de banhos. A variável precipitação, por sua vez, não apresentou efeitos

estatisticamente significativos, seja na dimensão direta, indireta ou total. Isso indica que, de acordo com os resultados do modelo, as variações na precipitação nos municípios analisados não exercem influência sobre o consumo de água *per capita* urbano, nem localmente, nem regionalmente.

A variável população revelou efeitos negativos e estatisticamente significativos em todas as dimensões (direta, indireta e total). O efeito direto indica que o aumento da população em um município está associado à redução do consumo de água *per capita* local. O efeito indireto sugere que municípios vizinhos com maior população também levam à diminuição do consumo *per capita* no município local. O efeito total, portanto, confirma a tendência geral de que a variável população está relacionado à redução do consumo *per capita* de água. Veiga, Kalbusch e Henning (2023) colocam que, com o aumento do número de residentes em um domicílio, o consumo de água *per capita* diminui, uma vez que diversos usos da água como lavar roupas, limpar a casa, cuidar do jardim e até cozinhar são atividades compartilhadas.

O valor adicionado da indústria *per capita* apresentou um efeito total positivo e estatisticamente significativo sobre o consumo de água *per capita*, resultado da combinação de efeitos diretos e indiretos positivos e significativos. Isso sugere que a intensificação da atividade industrial tanto no município quanto nas regiões vizinhas está associada ao aumento da demanda por água, refletindo o caráter intensivo do uso de recursos hídricos desse setor. Long *et al.* (2019) destacam que a produção de bens industriais requer água para resfriamento, transporte, acionamento e limpeza, entre outras finalidades, o que leva ao aumento do consumo hídrico.

A variável valor adicionado de comércio *per capita* apresentou efeito total positivo e significativo sobre o consumo de água *per capita*, resultado impulsionado pelo efeito direto. O efeito indireto não foi estatisticamente significativo e o efeito direto positivo e significativo indica que a atividade comercial local contribui para o aumento do consumo de água *per capita* local.

O valor adicionado de serviço *per capita* teve efeito direto e indireto positivos e estatisticamente significativos. Isso implica que tanto o aumento do valor adicionado de serviço em um município quanto em seus vizinhos está associado ao aumento do consumo de água *per capita*. O efeito total reforça essa influência positiva do setor de serviços sobre a demanda hídrica.

Esses achados são consistentes com Lyu *et al.* (2021), que analisaram a dinâmica do uso da água nos setores secundário (indústria e construção) e terciário

(serviços e comércio) em Tianjin e Hebei, na China. Os autores destacam que o crescimento econômico foi o principal determinante no aumento do uso da água para a produção. Isso confirma a tendência de que, à medida que as economias locais se expandem, a demanda hídrica cresce em paralelo. Shang *et al.* (2017) analisaram o consumo de água na indústria e constataram que, embora os ganhos de eficiência tenham inicialmente reduzido o uso de água mesmo com o crescimento industrial, em um segundo momento, o aumento da produção superou esses ganhos, resultando em uma elevação do consumo hídrico. Nesse sentido, Lyu *et al.* (2021) destacam a importância de analisar separadamente os efeitos de escala e de intensidade. Embora o modelo SDM aplicado neste estudo capte os efeitos espaciais e econômicos agregados, uma análise mais aprofundada que considere a eficiência hídrica dos setores (intensidade do uso da água) seria necessária para diferenciar se o aumento no consumo está sendo impulsionado por expansão da atividade econômica ou por baixa eficiência no uso dos recursos. Essa distinção é importante para subsidiar políticas públicas mais eficazes de gestão da demanda hídrica.

A proporção de área urbana apresentou efeitos diretos e indiretos positivos e significativos, indicando que tanto a urbanização local quanto a de municípios vizinhos estão associadas a um maior consumo de água *per capita*. O efeito total, portanto, também é positivo e significativo. Esses achados estão em consonância com o exposto por Deng *et al.* (2021), que identificaram que áreas com maior nível de urbanização apresentam maior consumo de água, e que o crescimento populacional e da área construída, impulsionado pela expansão urbana, é uma das principais causas da heterogeneidade espaço-temporal da demanda hídrica. Yuan *et al.* (2024) afirmam que o uso do solo para áreas urbanizadas influencia o consumo de água. Ao simular diferentes cenários de uso do solo para o futuro em uma província na China, constatou-se que o cenário com maior expansão de áreas urbanas resultou em aumento no consumo de água doméstico e industrial (Yuan *et al.*, 2024).

A variável proporção de área de formação natural não florestal apresentou efeito direto negativo e significativo, indicando que municípios com maior cobertura desse tipo tendem a apresentar menor consumo de água *per capita*. Por outro lado, o efeito indireto foi positivo e significativo, sugerindo que a presença dessa cobertura em municípios vizinhos está associada a um aumento do consumo local. Esses efeitos opostos se anulam, de forma que o efeito total da variável não é estatisticamente significativo.

A proporção de corpos d'água apresentou efeito direto negativo e significativo, apontando que a presença de maiores áreas cobertas por água em um município está associada à redução do consumo de água *per capita* local, possivelmente pelo uso direto dos corpos hídricos em detrimento do consumo registrado via redes formais. O efeito indireto foi marginalmente significativo e positivo, o que sugere que a existência de corpos d'água em municípios vizinhos pode estar associada a um aumento no consumo *per capita* local. No entanto, o efeito total da variável não foi estatisticamente significativo, sugerindo equilíbrio entre as forças locais e regionais.

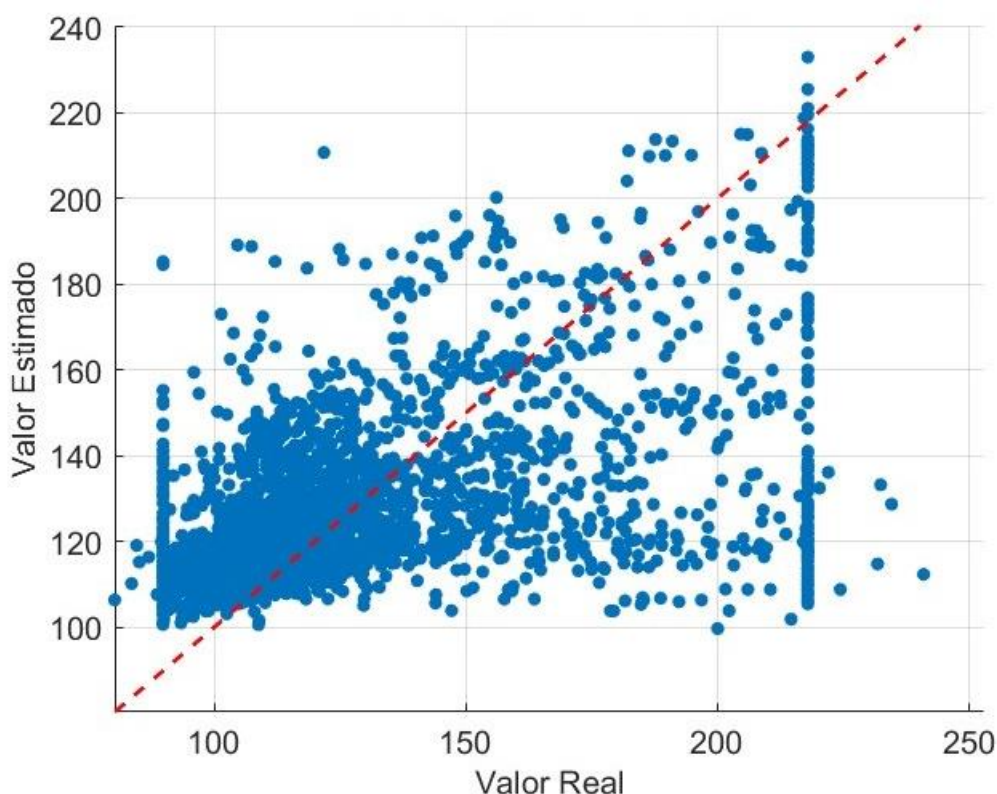
A variável proporção de área de agropecuária apresentou um efeito direto negativo e estatisticamente significativo, indicando que municípios com maior uso do solo para agropecuária apresentam menores níveis de consumo de água *per capita* urbana. É importante destacar que o indicador de consumo de água *per capita* utilizado neste estudo não inclui a água utilizada nas atividades agropecuárias, o que reforça a interpretação de que áreas predominantemente agrícolas, ao apresentarem menor urbanização registram consumo *per capita* inferior.

Por fim, a variável proporção de área não vegetada, que inclui dunas, areais, regiões de mineração e também áreas litorâneas como praias, apresentou um efeito direto positivo e estatisticamente significativo sobre o consumo de água *per capita*. Esse resultado pode refletir diferentes dinâmicas, dependendo da configuração territorial do município. Em áreas costeiras, a presença de praias e dunas está frequentemente associada ao turismo, à existência de residências de veraneio e a uma maior pressão sobre os sistemas de abastecimento, fatores que podem elevar o consumo de água *per capita*. O consumo turístico tende a ser mais intensivo do que o residencial, devido ao uso mais liberal por parte dos visitantes, à frequência maior de trocas de roupas de cama e banho em hospedagens, ao uso de piscinas, parques aquáticos e à irrigação de jardins e paisagismo urbano, comuns em destinos turísticos (Toth; Bragalli; Neri, 2018). O efeito total também foi positivo e significativo, enquanto o efeito indireto não foi estatisticamente significativo, o que indica que a influência dessa variável se concentra no próprio município, sem repercussões espaciais relevantes nas áreas vizinhas.

A Figura 55 apresenta a relação entre os valores reais e os valores estimados pelo modelo SDM com efeito fixo de tempo. A linha tracejada vermelha representa a linha de referência, na qual os valores estimados seriam iguais aos valores observados. Observa-se que há maior dispersão para valores mais altos de consumo

de água *per capita*, o que pode indicar alguma limitação na capacidade explicativa do modelo para esses casos. Nota-se também acúmulos verticais de pontos nos valores 89,84 e 217,91. Essas concentrações são resultado do procedimento de aplicação da função *winsorize*, no qual os 5% dos valores mais baixos e os 5% dos valores mais altos foram substituídos pelos respectivos percentis limites. Os valores inferiores a 89,84 e superiores a 217,91 são referentes ao procedimento de imputação.

Figura 55 - Gráfico real x estimado

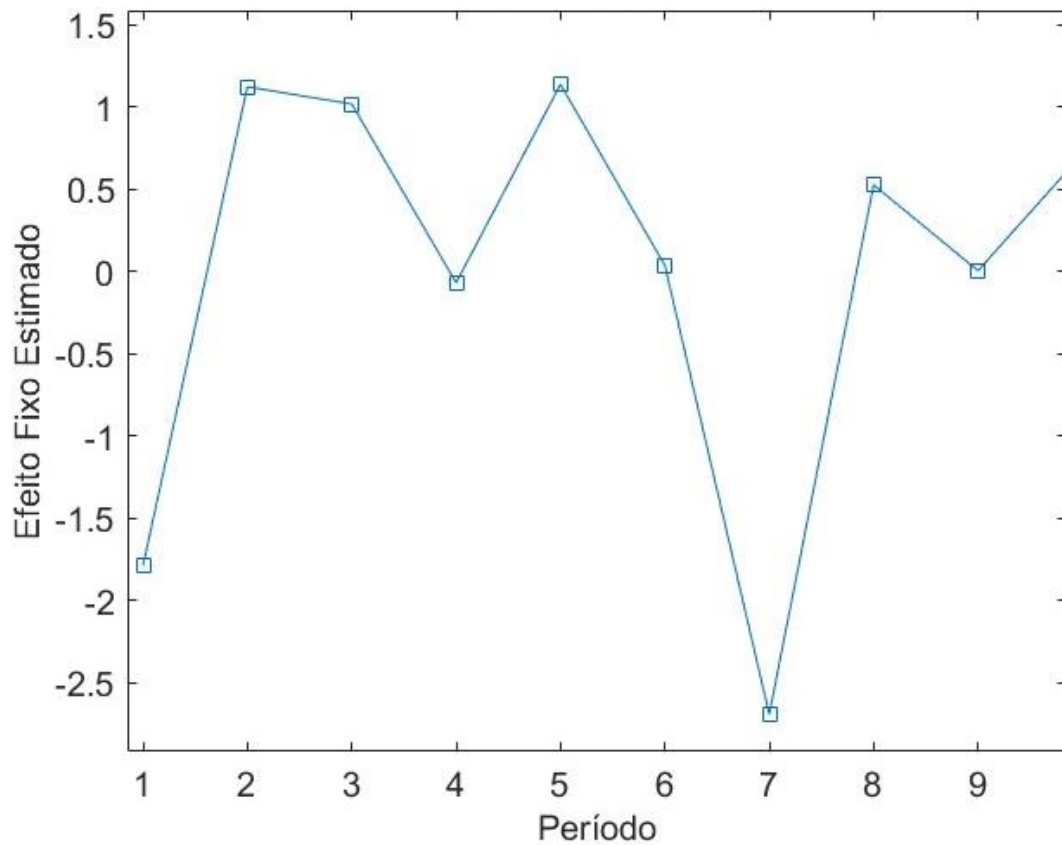


Fonte: Elaborado pela autora (2025)

A Figura 56 apresenta os efeitos fixos estimados para cada período no modelo de painel com efeitos fixos de tempo, sendo o período 1 correspondente ao ano de 2012 e o período 10, ao ano de 2021. Observa-se que, embora haja variação entre os anos, a magnitude dos efeitos fixos por tempo é relativamente pequena, com valores oscilando de -2,69 a 1,13. Essa pequena amplitude observada sugere que as variações não observadas específicas de cada ano possuem impacto relativamente pequeno sobre o consumo de água *per capita*. Essa interpretação é reforçada ao analisar o R^2 e o R^2 ajustado do modelo que são próximos, indicando que a inclusão

dos efeitos fixos de tempo não altera substancialmente o grau de explicação do modelo (Elhorst, 2014).

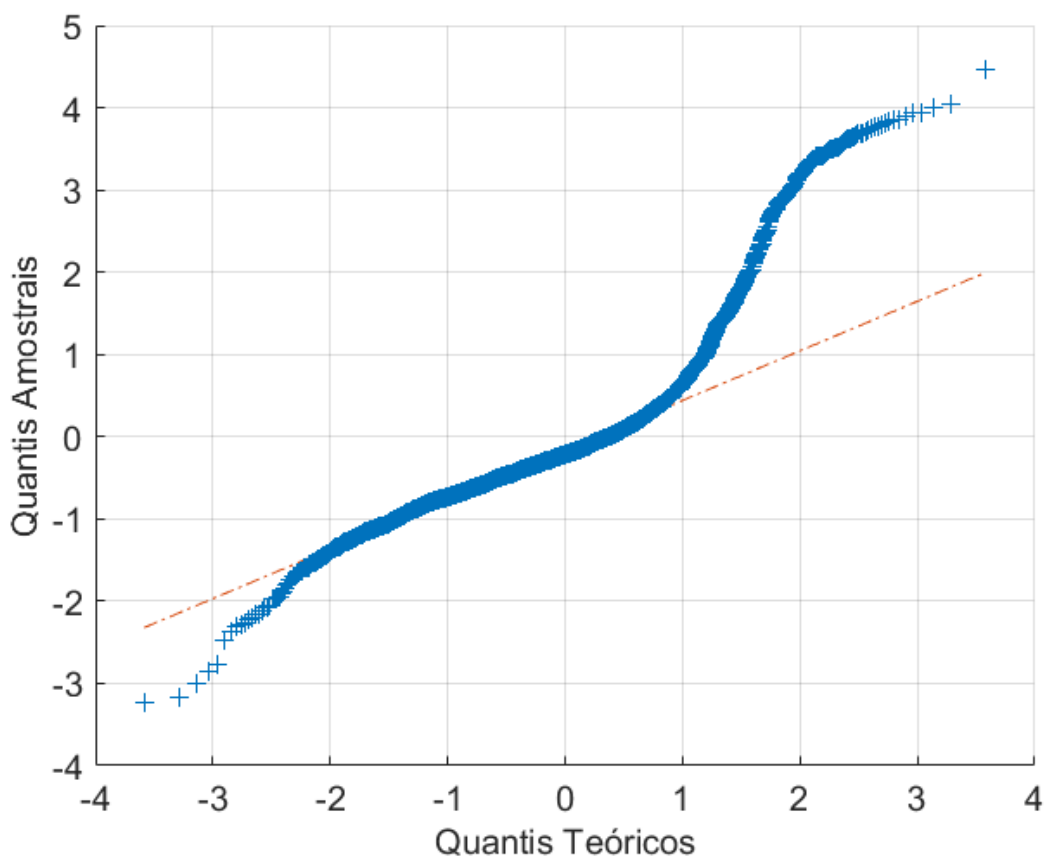
Figura 56 - Efeito fixo de tempo



Fonte: Elaborado pela autora (2025)

O gráfico QQ (Figura 57) apresenta comparação entre os quantis amostrais dos resíduos do modelo e os quantis teóricos de uma distribuição normal. Observa-se que, em parte da distribuição os pontos estão próximos à linha de referência, mas há desvios nas extremidades.

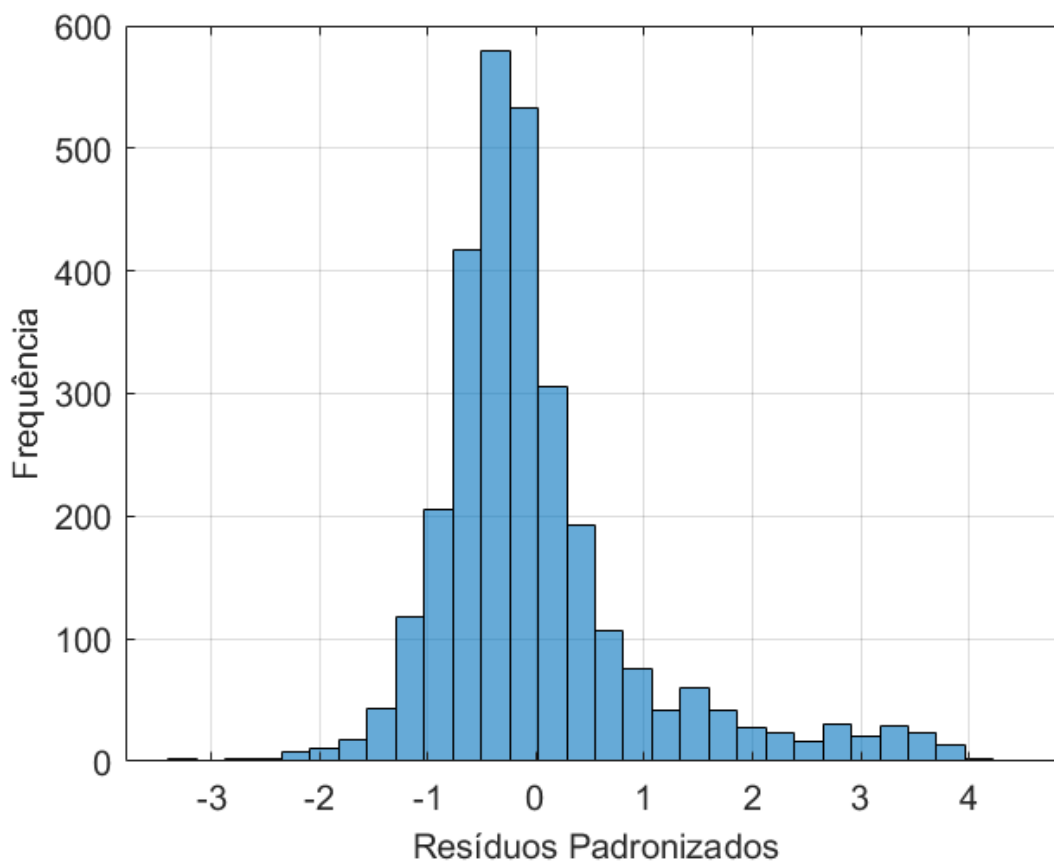
Figura 57 - Gráfico QQ dos resíduos



Fonte: Elaborado pela autora (2025)

O teste de Jarque-Bera aplicado aos resíduos do modelo resultou em p-valor de 0,001, indicando a rejeição da hipótese nula de normalidade dos resíduos. Esse resultado sugere que os resíduos não seguem uma distribuição normal. O histograma dos resíduos, Figura 58, apresenta distribuição assimétrica à direita.

Figura 58 - Histograma dos resíduos do modelo SDM com efeito fixo de tempo



Fonte: Elaborado pela autora (2025)

Os resultados do teste de Moran aplicados aos resíduos do modelo para cada ano, apresentados na Tabela 32, indicam que não há evidência significativa de autocorrelação espacial residual. Os valores do Índice de Moran oscilam próximo de zero e os p-valores associados estão acima do nível de significância de 5% em todos os anos.

Tabela 32 - Índice de Moran nos resíduos do modelo por ano

Ano	Índice de Moran	<i>p</i> -valor
2012	-0,041	0,152
2013	-0,052	0,105
2014	-0,011	0,409
2015	-0,043	0,104
2016	0,008	0,386
2017	-0,006	0,454
2018	-0,058	0,068
2019	-0,026	0,277
2020	0,008	0,378
2021	-0,018	0,343

Fonte: Elaborado pela autora (2025)

Os resultados obtidos a partir do modelo SDM com efeito fixo de tempo e estrutura heterocedástica permitiram identificar efeitos diretos e indiretos estatisticamente significativos entre as variáveis analisadas no modelo. Os resultados dos diferentes conjuntos imputados ($m = 1, 2$ e 3) apresentaram consistência tanto em termos de sinais dos coeficientes quanto da significância estatística. O modelo apresentou ausência de normalidade nos resíduos e não foi encontrada autocorrelação residual. O modelo mostrou-se capaz de captar relações entre as variáveis econômicas, de uso do solo, de temperatura e de população, e apresentou R^2 ajustado de 0,27. Ressalta-se que a aplicação da técnica de *winsorize* a 5%, para controlar a influência de *outliers* extremos, pode ter contribuído para a redução da variabilidade dos dados. Ainda assim, os achados fornecem informações sobre determinantes do consumo de água em escala municipal, colaborando para análises futuras com aprimoramentos metodológicos.

5 CONSIDERAÇÕES FINAIS

O consumo de água em contextos urbanos resulta da interação dinâmica entre múltiplas variáveis físicas, climáticas, econômicas, sociodemográficas e de uso do solo. Essas variáveis não atuam isoladamente e podem apresentar padrões de interdependência espacial, nos quais mudanças em um município podem influenciar o comportamento de municípios vizinhos quanto ao consumo de água. A incorporação da dimensão espacial pode ser fundamental para compreender a heterogeneidade do consumo de água e suas variações no espaço. Com base nessa perspectiva, este estudo investigou os fatores associados ao consumo de água *per capita* nos municípios de Santa Catarina entre 2012 e 2021, por meio de um modelo em painel espacial.

Inicialmente, foi conduzida revisão sistemática da literatura nas bases *Web of Science* e *Scopus*, que permitiu identificar os principais determinantes do consumo de água e orientar a seleção das variáveis e do método analítico. A revisão demonstrou a relevância de fatores físicos, climáticos, econômicos e sociodemográficos. Além disso, possibilitou melhor compreensão do papel de cada uma dessas variáveis na dinâmica do consumo de água.

Após a finalização de coleta e o tratamento de dados, a análise foi realizada por meio de um modelo em painel espacial, SDM, com efeitos fixos no tempo, capaz de capturar dependências espaciais entre os municípios e controlar os efeitos específicos de cada ano. Os resultados do modelo indicaram efeitos significativos das variáveis climáticas, econômicas, sociodemográficas e de uso do solo. O parâmetro *rho* estimado no modelo SDM foi significativo e positivo, indicando que o aumento do consumo de água *per capita* em um município está associado ao aumento do consumo de água *per capita* nos municípios vizinhos, refletindo um padrão de dependência espacial positiva. Os coeficientes do modelo foram decompostos em efeitos diretos, indiretos e total.

Apresentaram efeito direto positivo as variáveis temperatura média, valor adicionado da indústria, valor adicionado do comércio, valor adicionado de serviço e proporção de área urbana indicando que o aumento dessas variáveis está associado ao aumento do consumo de água *per capita* no município analisado. Por outro lado, as variáveis proporção de área de agropecuária e população apresentaram efeito direto negativo. A variável população também apresentou efeito indireto negativo

significativo, enquanto as variáveis valor adicionado da indústria, valor adicionado de serviço e proporção de área urbana apresentaram efeitos indiretos positivos significativos. As variáveis proporção de corpos d'água e formação de área não florestal não apresentaram efeitos totais estatisticamente significativos.

O modelo SDM com efeitos fixos no tempo obteve um R^2 ajustado de 0,27, não apresentou normalidade nos resíduos e não apresentou autocorrelação residual. Espera-se que este trabalho sirva como base para futuras pesquisas, que poderão explorar outras formas de modelagem espacial, incorporar variáveis adicionais ou analisar recortes regionais distintos, ampliando o entendimento sobre o uso da água em contextos urbanos.

5.1 SUGESTÕES PARA TRABALHOS FUTUROS

Os resultados obtidos abrem espaço para diversos aprimoramentos e aprofundamentos metodológicos. Entre as principais sugestões para trabalhos futuros, destacam-se:

- a) aplicação de modelos de painel dinâmico a fim de capturar a defasagem no tempo;
- b) exploração de outras áreas de estudo, de modo a verificar os resultados em diferentes contextos;
- c) estudo de diferentes métodos de tratamento de *outliers*, como, por exemplo, a aplicação do método *winsorize* nos percentis 2,5% inferior e superior, ou, alternativamente a exclusão dos *outliers* seguida da aplicação de técnicas de imputação.

REFERÊNCIAS

- ACUÑA, Guillermo Ignacio *et al.* The role of climate variability in convergence of residential water consumption across Chilean localities. **Environmental Economics and Policy Studies**, [s. l.], v. 22, n. 1, p. 89–108, 2020.
- AGGARWAL, Rimjhim M. *et al.* How do variations in Urban Heat Islands in space and time influence household water use? The case of Phoenix, Arizona. **Water Resources Research**, [s. l.], v. 48, n. 6, p. 2011WR010924, 2012.
- AHMAD, Muhammad Tajuri; HAIE, Naim. Assessing the Impacts of Population Growth and Climate Change on Performance of Water Use Systems and Water Allocation in Kano River Basin, Nigeria. **Water**, [s. l.], v. 10, n. 12, p. 1766, 2018.
- ALAMANOS, Angelos. Water resources planning under climate and economic changes in Skiathos island, Aegean. **Journal of Water Supply: Research and Technology-Aqua**, [s. l.], v. 70, n. 7, p. 1085–1093, 2021.
- ALMUTAZ, Ibrahim *et al.* A long-term forecast of water demand for a desalinated dependent city: case of Riyadh City in Saudi Arabia. **Desalination and Water Treatment**, [s. l.], v. 51, n. 31–33, p. 5934–5941, 2013.
- ALMUTAZ, Ibrahim *et al.* A probabilistic forecast of water demand for a tourist and desalination dependent city: Case of Mecca, Saudi Arabia. **Desalination**, [s. l.], v. 294, p. 53–59, 2012.
- ALNSOUR, Moawiah A.; IJAM, Abbas Z. Specifying a cascade water demand forecasting model using time-series analysis: a case of Jordan. **Sustainable Water Resources Management**, [s. l.], v. 9, n. 1, p. 37, 2023.
- ALSULAILI, Abdalrahman; ALKANDARI, Marwah; BUQAMMAZ, Amani. Assessing the impacts of meteorological factors on freshwater consumption in arid regions and forecasting the freshwater demand. **Environmental Technology & Innovation**, [s. l.], v. 25, p. 102099, 2022.
- ÁLVAREZ, Inmaculada C.; BARBERO, Javier; ZOFÍO, José L. A **Panel Data Toolbox for MATLAB**. **Journal of Statistical Software**, [s. l.], v. 76, n. 6, 2017. Disponível em: <http://www.jstatsoft.org/v76/i06/>. Acesso em: 15 jun. 2025.
- AL-ZAHRANI, Muhammad A.; ABO-MONASAR, Amin. Urban Residential Water Demand Prediction Based on Artificial Neural Networks and Time Series Models. **Water Resources Management**, [s. l.], v. 29, n. 10, p. 3651–3662, 2015.
- ANIL KUMAR, Arjun; RAMACHANDRAN, Parthasarathy. Cross-sectional study of factors influencing the residential water demand in Bangalore. **Urban Water Journal**, [s. l.], v. 16, n. 3, p. 171–182, 2019.
- ANSELIN, Luc. **An Introduction to Spatial Data Science with GeoDa**. Boca Raton, FL: CRC/Chapman&Hall, 2023. v. 1: Exploring Spatial Data
- ANSELIN, Luc *et al.* Simple diagnostic tests for spatial dependence. **Regional Science and Urban Economics**, [s. l.], v. 26, n. 1, p. 77–104, 1996.

ANSELIN, Luc. **Spatial Econometrics: Methods and Models**. [S. l.]: Springer-Science+Business Media Dordrecht, 1988.

ANSELIN, Luc; FLORAX, Raymond J. G. M.; REY, Sergio J. (org.). **Advances in Spatial Econometrics: Methodology, Tools and Applications**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004. (Advances in Spatial Science). Disponível em: <http://link.springer.com/10.1007/978-3-662-05617-2>. Acesso em: 30 jun. 2025.

ANSELIN, Luc; SYABRI, Ibnu; KHO, Youngihn. GeoDa: An Introduction to Spatial Data Analysis. **Geographical Analysis**, [s. l.], v. 38, n. 1, p. 5–22, 2006.

ARAMPATZIS, G. *et al.* Using accurate demand forecasting to improve the efficiency of water supply-distribution chains. **Desalination and Water Treatment**, [s. l.], v. 57, n. 25, p. 11494–11505, 2016.

ARIA, Massimo; CUCCURULLO, Corrado. bibliometrix : An R-tool for comprehensive science mapping analysis. **Journal of Informetrics**, [s. l.], v. 11, n. 4, p. 959–975, 2017.

ASHOORI, Negin; DZOMBAK, David A.; SMALL, Mitchell J. Identifying water price and population criteria for meeting future urban water demand targets. **Journal of Hydrology**, [s. l.], v. 555, p. 547–556, 2017.

ASHOORI, Negin; DZOMBAK, David A.; SMALL, Mitchell J. Modeling the Effects of Conservation, Demographics, Price, and Climate on Urban Water Demand in Los Angeles, California. **Water Resources Management**, [s. l.], v. 30, n. 14, p. 5247–5262, 2016.

BAIGORRI, Bárbara; MONTAÑÉS, Antonio; SIMÓN-FERNÁNDEZ, María Blanca. Household Water Consumption in Spain: Disparities between Region. **Water**, [s. l.], v. 14, n. 7, p. 1121, 2022.

BALACCO, Gabriella *et al.* At-Site Assessment of a Regional Design Criterium for Water-Demand Peak Factor Evaluation. **Water**, [s. l.], v. 11, n. 1, p. 24, 2018.

BALACCO, Gabriella *et al.* Influence of COVID-19 Spread on Water Drinking Demand: The Case of Puglia Region (Southern Italy). **Sustainability**, [s. l.], v. 12, n. 15, p. 5919, 2020.

BALATA, Edson Elídio; PINTO, Hugo; MOREIRA DA SILVA, Manuela. Latent dimensions between water use and socio-economic development: A global exploratory statistical analysis. **Regional Sustainability**, [s. l.], v. 3, n. 3, p. 269–280, 2022.

BALTAGI, Badi H. **Econometric Analysis of Panel Data**. 3^oed. England: John Wiley & Sons, 2005.

BAO, Chao; XU, Minyu. Spatiotemporal characteristics of water use change and its driving factors in China's urban agglomerations. **Ecological Indicators**, [s. l.], v. 151, p. 110279, 2023.

BARKER, Adrian *et al.* Drivers of future water demand in Sydney, Australia: examining the contribution from population and climate change. **Journal of Water and Climate Change**, [s. l.], v. 12, n. 4, p. 1168–1183, 2021.

BLANC, Elodie *et al.* Modeling U.S. water resources under climate change. **Earth's Future**, [s. l.], v. 2, n. 4, p. 197–224, 2014.

BOUZIOTAS, Dimitrios; ROZOS, Evangelos; MAKROPOULOS, Christos. Water and the city: exploring links between urban growth and water demand management. **Journal of Hydroinformatics**, [s. l.], v. 17, n. 2, p. 176–192, 2015.

BRAGA, Hugo José; GHELLRE, Reginaldo. Proposta de Diferenciação Climática para o Estado de Santa Catarina. [s. l.], 1999.

BRASIL. Congresso Nacional. **Lei Complementar nº 63, de 11 de janeiro de 1990**. 11 jan. 1990. Disponível em: https://www.planalto.gov.br/ccivil_03/LEIS//LCP/Lcp63.htm#:~:text=LEI%20COMPLEMENTAR%20N%C2%BA%2063%2C%20DE,Munic%C3%ADpios%2C%20e%20d%C3%A1%20outras%20provid%C3%AAs. Acesso em: 4 set. 2024.

BRASIL; MINISTÉRIO DO DESENVOLVIMENTO REGIONAL; SECRETARIA NACIONAL DE SANEAMENTO – SNS. **Sistema Nacional de Informações sobre Saneamento: 25º Diagnóstico dos Serviços de Água e Esgotos – 2019**. Brasília: [s. n.], 2020.

BRELSFORD, Christa; ABBOTT, Joshua K. Growing into Water Conservation? Decomposing the Drivers of Reduced Water Consumption in Las Vegas, NV. **Ecological Economics**, [s. l.], v. 133, p. 99–110, 2017.

BREYER, Betsy; CHANG, Heejun. Urban water consumption and weather variation in the Portland, Oregon metropolitan area. **Urban Climate**, [s. l.], v. 9, p. 1–18, 2014.

CAPT, Tallen *et al.* Urban Water Demand: Statistical Optimization Approach to Modeling Daily Demand. **Journal of Water Resources Planning and Management**, [s. l.], v. 147, n. 2, p. 04020105, 2021.

CHANG, Heejun *et al.* Determinants of single family residential water use across scales in four western US cities. **Science of The Total Environment**, [s. l.], v. 596–597, p. 451–464, 2017.

CHEN, I-Chun *et al.* Identifying Spatial Driving Factors of Energy and Water Consumption in the Context of Urban Transformation. **Sustainability**, [s. l.], v. 13, n. 19, p. 10503, 2021.

CHHABRA, Geeta; VASHISHT, Vasudha; RANJAN, Jayanthi. A Comparison of Multiple Imputation Methods for Data with Missing Values. **Indian Journal of Science and Technology**, [s. l.], v. 10, n. 19, p. 1–7, 2017.

CHHETRI, Netra B. Water-demand management: assessing impacts of climate and other changes on water usage in Central Arizona. **Journal of Water and Climate Change**, [s. l.], v. 2, n. 4, p. 288–312, 2011.

CONNOLLY, Matthew H.; HAGELMAN, Ronald R. Management implications of spatiotemporal non-stationarity in municipal water consumption patterns and drivers. **Applied Geography**, [s. l.], v. 65, p. 70–81, 2015.

CROISSANT, Yves; MILLO, Giovanni. Panel Data Econometrics in R: The plm Package. **Journal of Statistical Software**, [s. l.], 2008. 2. Disponível em: <https://www.jstatsoft.org/v27/i02/>.

DA VEIGA, Fabiano; KALBUSCH, Andreza; HENNING, Elisa. Drivers of urban water consumption in Brazil: a countrywide, cross-sectional study. **Urban Water Journal**, [s. l.], v. 20, n. 10, p. 1462–1470, 2023.

DANG, Xiaohu; LI, Lin; FAN, Liangxin. Spatiotemporal variation of household water consumption and coping strategies in water-stressed city of arid and semiarid Northwest China. **Frontiers in Environmental Science**, [s. l.], v. 10, p. 922144, 2022.

DAS, Keya Rani; IMON, A. H. M. Rahmatullah. A Brief Review of Tests for Normality. **American Journal of Theoretical and Applied Statistics**, [s. l.], v. 5, n. 1, p. 5, 2016.

DAW, Mabroka Mohamed; ALI, Elhadi Ramadan; TORIMAN, Mohd Ekhwan. Determinants of Urban Residential Water Demand in Libya. **International Journal of Engineering and Advanced Technology**, [s. l.], v. 8, n. 5c, p. 847–856, 2019.

DENG, Chuxiong *et al.* Precipitation and urban expansion caused jointly the spatiotemporal dislocation between supply and demand of water provision service. **Journal of Environmental Management**, [s. l.], v. 299, p. 113660, 2021.

DING, Xuhui *et al.* Study on the Evolution of Water Resource Utilization Efficiency in Tibet Autonomous Region and Four Provinces in Tibetan Areas under Double Control Action. **Sustainability**, [s. l.], v. 11, n. 12, p. 3396, 2019.

DING, Xuhui; FU, Zhu; JIA, Hongwen. Study on Urbanization Level, Urban Primacy and Industrial Water Utilization Efficiency in the Yangtze River Economic Belt. **Sustainability**, [s. l.], v. 11, n. 23, p. 6571, 2019.

DROOGERS, P. *et al.* Water resources trends in Middle East and North Africa towards 2050. **Hydrology and Earth System Sciences**, [s. l.], v. 16, n. 9, p. 3101–3114, 2012.

DU, Yueyue *et al.* Local and non-local drivers of consumption-based water use in China during 2007–2015: Perspective of metacoupling. **Journal of Environmental Management**, [s. l.], v. 312, p. 114940, 2022.

ELHORST, J. Paul. **Spatial Econometrics: From Cross-Sectional Data to Spatial Panels**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014. (SpringerBriefs in Regional Science). Disponível em: <https://link.springer.com/10.1007/978-3-642-40340-8>. Acesso em: 10 out. 2024.

EXPÓSITO, Alfonso; PABLO-ROMERO, María; SÁNCHEZ-BRAZA, Antonio. Testing EKC for Urban Water Use: Empirical Evidence at River Basin Scale from the Guadalquivir River, Spain. **Journal of Water Resources Planning and Management**, [s. l.], v. 145, n. 4, p. 04019005, 2019.

FABRE, Julie *et al.* Reducing the gap between water demand and availability under climate and water use changes: assessing the effectiveness and robustness of adaptation. **La Houille Blanche**, [s. l.], v. 102, n. 6, p. 21–29, 2016.

FABRE, J. *et al.* Simulating past changes in the balance between water demand and availability and assessing their main drivers at the river basin scale. **Hydrology and Earth System Sciences**, [s. l.], v. 19, n. 3, p. 1263–1285, 2015.

FAN, Liangxin *et al.* Urban water consumption and its influencing factors in China: Evidence from 286 cities. **Journal of Cleaner Production**, [s. l.], v. 166, p. 124–133, 2017.

FERCOVIC, Juan; FOSTER, William; MELO, Oscar. Economic development and residential water consumption in Chile. **Environment and Development Economics**, [s. l.], v. 24, n. 1, p. 23–46, 2019.

FONTDECABA, Sara *et al.* A Methodology to Model Water Demand based on the Identification of Homogenous Client Segments. Application to the City of Barcelona. **Water Resources Management**, [s. l.], v. 26, n. 2, p. 499–516, 2012.

FROYEN, Richard T. **Macroeconomia**. 5^oed. [S. l.]: Saraiva, 2015.

FUNDAÇÃO GETÚLIO VARGAS, IBRE. IGP. *In*: PORTAL IBRE. 2020. Disponível em: <https://portalibre.fgv.br/igp>. Acesso em: 3 mar. 2024.

GARCIA, Margaret; ISLAM, Shafiqul. The role of external and emergent drivers of water use change in Las Vegas. **Urban Water Journal**, [s. l.], v. 15, n. 9, p. 888–898, 2018.

GARCÍA-LÓPEZ, Marcos; MONTANO, Borja. Water Price Effects on Consumption and Territorial Imbalances in Spain in the Context of the Water Framework Directive. **Water**, [s. l.], v. 12, n. 6, p. 1604, 2020.

GEBREYOHANNES HIBEN, Mehari; GEBEYEHU AWOKE, Admasu; ADUGNA ASHENAFI, Abraha. Future potable water supply demand projection under climate change and socioeconomic scenarios: A case of Gshba subbasin, Northern Ethiopia. **International Research Journal of Multidisciplinary Technovation**, [s. l.], p. 51–64, 2024.

GHARABAGHI, Shahrzad; STAHL, Emily; BONAKDARI, Hossein. Integrated nonlinear daily water demand forecast model (case study: City of Guelph, Canada). **Journal of Hydrology**, [s. l.], v. 579, p. 124182, 2019.

GHAVIDELFAR, Saeed; SHAMSELDIN, Asaad Y.; MELVILLE, Bruce W. A Multi-Scale Analysis of Low-Rise Apartment Water Demand through Integration of Water Consumption, Land Use, and Demographic Data. **JAWRA Journal of the American Water Resources Association**, [s. l.], v. 52, n. 5, p. 1056–1067, 2016.

GHAVIDELFAR, Saeed; SHAMSELDIN, Asaad Y.; MELVILLE, Bruce W. A Multi-Scale Analysis of Single-Unit Housing Water Demand Through Integration of Water Consumption, Land Use and Demographic Data. **Water Resources Management**, [s. l.], v. 31, n. 7, p. 2173–2186, 2017.

GHAVIDELFAR, Saeed; SHAMSELDIN, Asaad Y.; MELVILLE, Bruce W. Evaluating spatial and seasonal determinants of residential water demand across different housing types through data integration. **Water International**, [s. l.], v. 43, n. 7, p. 926–942, 2018.

GRAHAM, Neal T. *et al.* Water Sector Assumptions for the Shared Socioeconomic Pathways in an Integrated Modeling Framework. **Water Resources Research**, [s. l.], v. 54, n. 9, p. 6423–6440, 2018.

GUJARATI, Damodar N.; PORTER, Dawn C. **Econometria básica**. 5. ed. [S. l.]: AMGH, 2011.

GUO, Bin *et al.* Spatially explicit estimation of domestic water use in the arid region of northwestern China: 1985–2009. **Hydrological Sciences Journal**, [s. l.], v. 58, n. 1, p. 162–176, 2013.

GUO, Jun; SUN, Hui; DU, Baigang. Multivariable Time Series Forecasting for Urban Water Demand Based on Temporal Convolutional Network Combining Random Forest Feature Selection and Discrete Wavelet Transform. **Water Resources Management**, [s. l.], v. 36, n. 9, p. 3385–3400, 2022.

GUO, Lishuo; WANG, Lifang. Peak water: future long-term changes driven by socio-economic development in China. **Environmental Science and Pollution Research**, [s. l.], v. 30, n. 1, p. 1306–1317, 2023.

HAMLAT, Abdelkader *et al.* Water supply and demand balancing and forecasting in a semi-arid region of Algeria using the WEAP model: a case study of El Bayadh province. **Sustainable Water Resources Management**, [s. l.], v. 10, n. 1, p. 34, 2024.

HAN, Shaohong *et al.* Influence of Community Factors on Water Saving in a Mega City after Implementing the Progressive Price Schemes. **Water**, [s. l.], v. 13, n. 8, p. 1097, 2021.

HAO, Yu; HU, Xinlei; CHEN, Heyin. On the relationship between water use and economic growth in China: New evidence from simultaneous equation model analysis. **Journal of Cleaner Production**, [s. l.], v. 235, p. 953–965, 2019.

HAQUE, Md *et al.* A Comparative Assessment of Variable Selection Methods in Urban Water Demand Forecasting. **Water**, [s. l.], v. 10, n. 4, p. 419, 2018.

HAQUE, Md Mahmudul *et al.* Assessing the significance of climate and community factors on urban water demand. **International Journal of Sustainable Built Environment**, [s. l.], v. 4, n. 2, p. 222–230, 2015.

HARMA, Kirsten J.; JOHNSON, Mark S.; COHEN, Stewart J. Future Water Supply and Demand in the Okanagan Basin, British Columbia: A Scenario-Based Analysis of Multiple, Interacting Stressors. **Water Resources Management**, [s. l.], v. 26, n. 3, p. 667–689, 2012.

HE, Fang; TAO, Tao. An Improved Coupling Model of Grey-System and Multivariate Linear Regression for Water Consumption Forecasting. [s. l.], 2014.

HE, Jia; ZHAO, Yiqiu; WEN, Chuanhao. Spatiotemporal Variation and Driving Factors of Water Supply Services in the Three Gorges Reservoir Area of China Based on Supply-Demand Balance. **Water**, [s. l.], v. 14, n. 14, p. 2271, 2022.

HEMATI, Azadeh *et al.* Deconstructing Demand: The Anthropogenic and Climatic Drivers of Urban Water Consumption. **Environmental Science & Technology**, [s. l.], v. 50, n. 23, p. 12557–12566, 2016.

HONAKER, James; KING, Gary; BLACKWELL, Matthew. Amelia II: A Program for Missing Data. **Journal of Statistical Software**, [s. l.], 2011. 45, p. 47.

HOUSE-PETERS, Lily A.; CHANG, Heejun. Urban water demand modeling: Review of concepts, methods, and organizing principles. **Water Resources Research**, [s. l.], v. 47, n. 5, p. 2010WR009624, 2011.

HOUSE-PETERS, Lily; PRATT, Bethany; CHANG, Heejun. Effects of Urban Spatial Structure, Sociodemographics, and Climate on Residential Water Consumption in Hillsboro, Oregon ¹. **JAWRA Journal of the American Water Resources Association**, [s. l.], v. 46, n. 3, p. 461–472, 2010.

HUANG, Lili *et al.* Application of a Combination Model Based on Wavelet Transform and KPLS-ARMA for Urban Annual Water Demand Forecasting. **Journal of Water Resources Planning and Management**, [s. l.], v. 140, n. 8, p. 04014013, 2014.

IBGE. Clima | 2002 Clima - 1:5000000. *In*: INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. 2002. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-ambientais/climatologia/15817-clima.html?=&t=acesso-ao-produto>. Acesso em: 10 jul. 2024.

IBGE. Malha Municipal. *In*: IBGE. 2022a. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/15774-malhas.html>. Acesso em: 5 jul. 2024.

IBGE. Produto Interno Bruto dos Municípios. *In*: 2022b. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/contas-nacionais/9088-produto-interno-bruto-dos-municipios.html?=&t=downloads>. Acesso em: 4 set. 2024.

IBGE. Santa Catarina. *In*: CIDADES E ESTADOS. 2022c. Disponível em: <https://www.ibge.gov.br/cidades-e-estados/sc.html>. Acesso em: 10 jul. 2024.

JENSEN, John R. **Introductory Digital Image Processing A Remote Sensing Perspective**. 3ªed. University of South Carolina: Pearson, 2005.

JOHNSON, Ryan C. *et al.* Preparing municipal water system planning for a changing climate: Integrating climate-sensitive demand estimates. **JAWRA Journal of the American Water Resources Association**, [s. l.], p. 1752–1688.13165, 2023.

KAHLERRAS, Malika *et al.* Modeling water supply and demand for effective water management allocation in Mazafran basin (north of Algeria). **Arabian Journal of Geosciences**, [s. l.], v. 11, n. 18, p. 547, 2018.

KARAHAN, S. M.; ELÇİ, S. Assessment of future water demand in a semiarid region of Turkey: a case study of Tahtali–Seferihisar Basin. **Sustainable Water Resources Management**, [s. l.], v. 9, n. 2, p. 44, 2023.

KING, Gary *et al.* Analyzing Incomplete Political Science Data: An Alternative Algorithm for Multiple Imputation. **American Political Science Review**, [s. l.], v. 95, n. 1, p. 49–69, 2001.

KLAIBER, H Allen *et al.* Measuring Price Elasticities for Residential Water Demand with Limited Information. **Land Economics**, [s. l.], 2014.

KOO, Kang-Min *et al.* Performance Assessment for Short-Term Water Demand Forecasting Models on Distinctive Water Uses in Korea. **Sustainability**, [s. l.], v. 13, n. 11, p. 6056, 2021.

LAWENS, M.; MUTSVANGWA, C. Application of multiple regression analysis in projecting the water demand for the City of Cape Town. **Water Practice and Technology**, [s. l.], v. 13, n. 3, p. 705–711, 2018.

LE, Nguyen Truc *et al.* Measuring water resource use efficiency of the Dong Nai River Basin (Vietnam): an application of the two-stage data envelopment analysis (DEA). **Environment, Development and Sustainability**, [s. l.], v. 24, n. 10, p. 12427–12445, 2022.

LEE, Seung-Jae; WENTZ, Elizabeth A.; GOBER, Patricia. Space–time forecasting using soft geostatistics: a case study in forecasting municipal water demand for Phoenix, Arizona. **Stochastic Environmental Research and Risk Assessment**, [s. l.], v. 24, n. 2, p. 283–295, 2010.

LESAGE, James P. A panel data toolbox for MATLAB. [s. l.], 2021.

LI, Zhengxuan *et al.* Prediction of Daily Water Consumption in Residential Areas Based on Meteorologic Conditions—Applying Gradient Boosting Regression Tree Algorithm. **Water**, [s. l.], v. 15, n. 19, p. 3455, 2023.

LI, Wu; HUICHENG, Zhou. Urban water demand forecasting based on HP filter and fuzzy neural network. **Journal of Hydroinformatics**, [s. l.], v. 12, n. 2, p. 172–184, 2010.

LI, Jun; SONG, Songbai. Urban Water Consumption Prediction Based on CPMBNIP. **Water Resources Management**, [s. l.], v. 37, n. 13, p. 5189–5213, 2023.

LI, Tianhong; YANG, Songnan; TAN, Mingxin. Simulation and optimization of water supply and demand balance in Shenzhen: A system dynamics approach. **Journal of Cleaner Production**, [s. l.], v. 207, p. 882–893, 2019.

LINS, Gledsneli *et al.* Determining indicators of urban household water consumption through multivariate statistical techniques. **Journal of Urban and Environmental Engineering**, [s. l.], v. 4, n. 2, p. 74–80, 2010.

LIU, Chunjing *et al.* Urban Water Demand Prediction Based on Attention Mechanism Graph Convolutional Network-Long Short-Term Memory. **Water**, [s. l.], v. 16, n. 6, p. 831, 2024.

LIU, Jing-qing; CHENG, Wei-ping; ZHANG, Tu-qiao. Principal Factor Analysis for Forecasting Diurnal Water-Demand Pattern Using Combined Rough-Set and Fuzzy-Clustering Technique. **Journal of Water Resources Planning and Management**, [s. l.], v. 139, n. 1, p. 23–33, 2013.

LIU, Yueyi; ZHAO, Jianshi; WANG, Zhongjing. Identifying determinants of urban water use using data mining approach. **Urban Water Journal**, [s. l.], v. 12, n. 8, p. 618–630, 2015.

LONG, Haiyu *et al.* Analysis of China's regional differences in water consumption based on spatial structural decomposition analysis model. **Science of The Total Environment**, [s. l.], v. 848, p. 157629, 2022.

LONG, Houyin *et al.* Spatio-temporal analysis of driving factors of water resources consumption in China. **Science of The Total Environment**, [s. l.], v. 690, p. 1321–1330, 2019.

LÜ, Subing *et al.* Analysis of dynamic evolution and driving factors behind water consumption in China. **Water Supply**, [s. l.], v. 18, n. 3, p. 1093–1102, 2018.

LU, Hongfang; MATTHEWS, John; HAN, Shuai. A hybrid model for monthly water demand prediction: A case study of Austin, Texas. **AWWA Water Science**, [s. l.], v. 2, n. 2, p. e1175, 2020.

LYU, Wenfei *et al.* Decomposing drivers of changes in productive and domestic water use based on the logarithmic mean Divisia index method: a regional comparison in Northern China. **Water Policy**, [s. l.], v. 23, n. 2, p. 310–326, 2021.

MAKPIBOON, Chinnapan. IMPACTS OF WEATHER VARIABLES ON URBAN WATER DEMAND AT MULTIPLE TEMPORAL SCALES. **International Journal of GEOMATE**, [s. l.], v. 18, n. 67, 2020. Disponível em: <https://geomatejournal.com/geomate/article/view/486/1469>. Acesso em: 10 jun. 2024.

MALDONADO-DEVIS, Mónica *et al.* Assessment of domestic water consumption in Valencia city through fuzzy-set qualitative comparative analysis. **Urban Water Journal**, [s. l.], v. 18, n. 8, p. 640–647, 2021.

MALDONADO-DEVIS, Mónica; ALMENAR-LLONGO, Vicent. Heterogeneity in Domestic Water Demand: An Application of Multilevel Analysis to the City of Valencia (Spain). **Water**, [s. l.], v. 13, n. 23, p. 3400, 2021.

MAPBIOMAS. Coleção 8 da série anual de Mapas de Cobertura e Uso da Terra do Brasil. *In*: 2024a. Disponível em: <https://brasil.mapbiomas.org/colecoes-mapbiomas/>. Acesso em: 15 ago. 2024.

MAPBIOMAS. Descrição detalhada. *In*: MAPBIOMAS BRASIL. 2024b. Disponível em: <https://brasil.mapbiomas.org/wp-content/uploads/sites/4/2023/09/Legenda-Colecao-8-Descricao-Detalhada-PDF-PT-3-1.pdf>. Acesso em: 15 ago. 2024.

MAPBIOMAS. Método cobertura e uso. *In*: MAPBIOMAS BRASIL. 2024c. Disponível em: https://brasil.mapbiomas.org/metodo_cobertura_e_uso/. Acesso em: 15 ago. 2024.

MAPBIOMAS. Quem somos. *In*: MAPBIOMAS BRASIL. 2024d. Disponível em: <https://brasil.mapbiomas.org/quem-somos/>. Acesso em: 15 ago. 2024.

MARCH, Hug; PERARNAU, Judit; SAURÍ, David. Exploring the Links between Immigration, Ageing and Domestic Water Consumption: The Case of the Metropolitan Area of Barcelona. **Regional Studies**, [s. l.], v. 46, n. 2, p. 229–244, 2012.

MARCH, Hug; SAURÍ, David. The Suburbanization of Water Scarcity in the Barcelona Metropolitan Region: Sociodemographic and Urban Changes Influencing Domestic Water Consumption. **The Professional Geographer**, [s. l.], v. 62, n. 1, p. 32–45, 2010.

MATHUR, Manish. Spatial autocorrelation analysis in plant population: An overview. **Journal of Applied and Natural Science**, [s. l.], v. 7, n. 1, p. 501–513, 2015.

MATHWORKS. **MATLAB**. versão R2024. [S. l.: s. n.], 2025. Disponível em: <https://www.mathworks.com/products/matlab.html>.

MAZZONI, Filippo *et al.* Exploring the impacts of tourism and weather on water consumption at different spatiotemporal scales: evidence from a coastal area on the Adriatic Sea (northern Italy). **Environmental Research: Infrastructure and Sustainability**, [s. l.], v. 2, n. 2, p. 025005, 2022.

MEDINA-RIVAS, Carolina Massiel *et al.* Spatial inequality of domestic water consumption in Mexico city. **Water Resources and Economics**, [s. l.], v. 40, p. 100210, 2022.

MILLO, Giovanni; PIRAS, Gianfranco; BIVAND, Roger. **Econometric Models for Spatial Panel Data**. versão 1.6-5. [S. l.]: CRAN, 2023.

MO, Li *et al.* Studying the evolutions, differences, and water security impacts of water demands under shared socioeconomic pathways: A SEMs-bootstrap-ANN approach applied to Sichuan Province. **Journal of Environmental Management**, [s. l.], v. 349, p. 119455, 2024.

MOGLIA, Magnus; NYGAARD, Christian Andi. The Responsiveness of Urban Water Demand to Working from Home Intensity. **Sustainability**, [s. l.], v. 16, n. 5, p. 1867, 2024.

MORAIN, Almando; ANANDHI, Aavudai. Fresh Water Use in Florida: Trends and Drivers. **Water**, [s. l.], v. 14, n. 22, p. 3726, 2022.

MOROTE, Álvaro-Francisco; HERNÁNDEZ, María. Urban sprawl and its effects on water demand: A case study of Alicante, Spain. **Land Use Policy**, [s. l.], v. 50, p. 352–362, 2016.

MSONGALELI, Barnabas *et al.* Characterizing the relationship between urban sprawl and water demand in Dodoma Urban District, Tanzania: 1992–2029. **Urban Water Journal**, [s. l.], v. 20, n. 10, p. 1579–1591, 2023.

MUÑOZ SABATER, J. ERA5-Land monthly averaged data from 1950 to present. [s. l.], Copernicus Climate Change Service (C3S) Climate Data Store (CDS)., 2019. Disponível em: <https://doi.org/10.24381/cds.68d2bb30>. Acesso em: 1 set. 2024.

NAMDARI, Hossein; ASHRAFI, Seyed Mohammad; HAGHIGHI, Ali. Deep learning-based short-term water demand forecasting in urban areas: A hybrid multichannel model. **AQUA — Water Infrastructure, Ecosystems and Society**, [s. l.], v. 73, n. 3, p. 380–395, 2024.

NAMDARI, Hossein; HAGHIGHI, Ali; ASHRAFI, Seyed Mohammad. Short-term urban water demand forecasting; application of 1D convolutional neural network (1D CNN) in comparison with different deep learning schemes. **Stochastic Environmental Research and Risk Assessment**, [s. l.], 2023. Disponível em: <https://link.springer.com/10.1007/s00477-023-02565-3>. Acesso em: 10 jun. 2024.

NIVESH, Shreya *et al.* Assessment of future water demand and supply using WEAP model in Dhasan River Basin, Madhya Pradesh, India. **Environmental Science and Pollution Research**, [s. l.], v. 30, n. 10, p. 27289–27302, 2022.

NUNES CARVALHO, Taís Maria; DE SOUZA FILHO, Francisco De Assis; PORTO, Victor Costa. Urban Water Demand Modeling Using Machine Learning Techniques: Case Study of Fortaleza, Brazil. **Journal of Water Resources Planning and Management**, [s. l.], v. 147, n. 1, p. 05020026, 2021.

O'DONNELL, Michael; BERRENS, Robert P. Understanding Falling Municipal Water Demand in a Small City Dependent on the Declining Ogallala Aquifer: Case Study of Clovis, New Mexico. **Water Economics and Policy**, [s. l.], v. 04, n. 04, p. 1850015, 2018.

OPALINSKI, Nicole F.; BHASKAR, Aditi S.; MANNING, Dale T. Spatial and Seasonal Response of Municipal Water Use to Weather across the Contiguous U.S. **JAWRA Journal of the American Water Resources Association**, [s. l.], v. 56, n. 1, p. 68–81, 2020.

OU, Zhigang *et al.* Analysis of driving factors of water demand based on explainable artificial intelligence. **Journal of Hydrology: Regional Studies**, [s. l.], v. 47, p. 101396, 2023.

OUYANG, Yun *et al.* A MULTI-SCALE ANALYSIS OF SINGLE-FAMILY RESIDENTIAL WATER USE IN THE PHOENIX METROPOLITAN AREA. [s. l.], v. 50, n. 2, 2014.

PANAGOPOULOS, George P. Assessing the impacts of socio-economic and hydrological factors on urban water demand: A multivariate statistical approach. **Journal of Hydrology**, [s. l.], v. 518, p. 42–48, 2014.

PANAGOPOULOS, George P. *et al.* Mapping Urban Water Demands Using Multi-Criteria Analysis and GIS. **Water Resources Management**, [s. l.], v. 26, n. 5, p. 1347–1363, 2012.

PARKINSON, Simon C. *et al.* Climate and human development impacts on municipal water demand: A spatially-explicit global modeling framework. **Environmental Modelling & Software**, [s. l.], v. 85, p. 266–278, 2016.

POLEBITSKI, Austin S.; PALMER, Richard N.; WADDELL, Paul. Evaluating Water Demands under Climate Change and Transitions in the Urban Environment. **Journal of Water Resources Planning and Management**, [s. l.], v. 137, n. 3, p. 249–257, 2011.

POLIDORI, James A.; PAULSON, Hannah L.; GRONEWOLD, Andrew D. Assessing trends in urban municipal water use across the Great Lakes Basin. **Journal of Great Lakes Research**, [s. l.], v. 50, n. 1, p. 102243, 2024.

PRASOOD, S.P. *et al.* Urbanization and its effects on water resources: Scenario of a tropical river basin in South India. **Remote Sensing Applications: Society and Environment**, [s. l.], v. 23, p. 100556, 2021.

QI, Cheng; CHANG, Ni-Bin. System dynamics modeling for municipal water demand estimation in an urban region under uncertain economic impacts. **Journal of Environmental Management**, [s. l.], v. 92, n. 6, p. 1628–1641, 2011.

R CORE TEAM. **R**. versão 4.4.1. [S. l.]: R Foundation for Statistical Computing, 2024. Disponível em: <https://www.r-project.org/>. Acesso em: 30 set. 2024.

RAMOS FILHO, Rivaildo Da Silva *et al.* Urban water insecurity drivers in the Brazilian semi-arid region. **Water Supply**, [s. l.], v. 23, n. 2, p. 447–458, 2023.

RAMOS-BUENO, Arturo; GALEANA-PIZAÑA, José Mauricio; PEREVOCHTCHIKOVA, María. Urban water consumption analysis through a spatial panel modeling approach: a case study of Mexico City, 2004–2022. **Water Supply**, [s. l.], p. ws2024191, 2024.

RAMOS-BUENO, Arturo; PEREVOCHTCHIKOVA, María; CHANG, Heejun. Socio-spatial analysis of residential water demand in Mexico City. **Tecnología y ciencias del agua**, [s. l.], v. 12, n. 2, p. 59–110, 2021.

RATOLOJANAHARY, Romy *et al.* Model selection to improve multiple imputation for handling high rate missingness in a water quality dataset. **Expert Systems with Applications**, [s. l.], v. 131, p. 299–307, 2019.

RENZETTI, Steven *et al.* Using demand elasticity as an alternative approach to modelling future community water demand under a conservation-oriented pricing system: An exploratory investigation. **Canadian Water Resources Journal / Revue canadienne des ressources hydriques**, [s. l.], v. 40, n. 1, p. 62–70, 2015.

REYNAUD, Arnaud; PONS, Marc; PESADO, Cristina. Household Water Demand in Andorra: Impact of Individual Metering and Seasonality. **Water**, [s. l.], v. 10, n. 3, p. 321, 2018.

ROMANO, Giulia; SALVATI, Nicola; GUERRINI, Andrea. An empirical analysis of the determinants of water demand in Italy. **Journal of Cleaner Production**, [s. l.], v. 130, p. 74–81, 2016.

ROMANO, Giulia; SALVATI, Nicola; GUERRINI, Andrea. Estimating the Determinants of Residential Water Demand in Italy. **Water**, [s. l.], v. 6, n. 10, p. 2929–2945, 2014.

ROUSHANGAR, Kiyoumars; ALIZADEH, Farhad. Investigating effect of socio-economic and climatic variables in urban water consumption prediction via Gaussian process regression approach. **Water Supply**, [s. l.], v. 18, n. 1, p. 84–93, 2018.

RUBIN, Donald B. **Multiple Imputation for Nonresponse in Surveys**. 1. ed. [S. l.]: Wiley, 1987. (Wiley Series in Probability and Statistics). Disponível em: <https://onlinelibrary.wiley.com/doi/book/10.1002/9780470316696>. Acesso em: 14 maio 2025.

RUNFOLA, Daniel Miller *et al.* A growing concern? Examining the influence of lawn size on residential water use in suburban Boston, MA, USA. **Landscape and Urban Planning**, [s. l.], v. 119, p. 113–123, 2013.

SANKARASUBRAMANIAN, A. *et al.* Synthesis of public water supply use in the United States: Spatio-temporal patterns and socio-economic controls. **Earth's Future**, [s. l.], v. 5, n. 7, p. 771–788, 2017.

SANTA CATARINA. SEF/SC. **Portaria nº 233, de 09 de agosto de 2012**. 9 ago. 2012. Disponível em: https://legislacao.sef.sc.gov.br/html/portarias/2012/port_12_233.htm. Acesso em: 4 set. 2024.

SCHAFER, J. L. **Analysis of Incomplete Multivariate Data**. [S. l.]: Chapman & Hall/CRC, 1997.

SEBRI, Maamar. A meta-analysis of residential water demand studies. **Environment, Development and Sustainability**, [s. l.], v. 16, n. 3, p. 499–520, 2014.

SEF/SC, Secretaria da Fazenda do Estado de Santa Catarina. Valor Adicionado por Município e Atividade. *In*: SECRETARIA DA FAZENDA DO ESTADO DE SANTA CATARINA. 2016. Disponível em: <https://www.sef.sc.gov.br/transparencias/valor-adicionado-por-municipio-e-atividade>. Acesso em: 10 set. 2024.

SHABANI, Maryam; GHARNEH, Naser Shams; NIAKI, Seyed Taghi Akhavan. Planning for urban water supply–demand portfolio using a hybrid robust stochastic optimization approach. **Water Supply**, [s. l.], v. 20, n. 8, p. 3433–3448, 2020.

SHANDAS, Vivek; PARANDVASH, G Hossein. Integrating Urban Form and Demographics in Water-Demand Management: An Empirical Case Study of Portland, Oregon. **Environment and Planning B: Planning and Design**, [s. l.], v. 37, n. 1, p. 112–128, 2010.

SHANG, Yizi *et al.* Drivers of industrial water use during 2003–2012 in Tianjin, China: A structural decomposition analysis. **Journal of Cleaner Production**, [s. l.], v. 140, p. 1136–1147, 2017.

SHI, Changfeng *et al.* Decoupling analysis of water consumption and economic development of arid and semiarid regions in Northwest China. **Natural Resources Forum**, [s. l.], v. 47, n. 2, p. 192–213, 2023.

SHIKLOMANOV, I. A.; BABKIN, V. I.; BALONISHNIKOV, Zh. A. Water resources, their use, and water availability in Russia: Current estimates and forecasts. **Water Resources**, [s. l.], v. 38, n. 2, p. 139–148, 2011.

SIGNORELL, Andri. **DescTools: Tools for Descriptive Statistics**. versão 0.99.59. [S. l.: s. n.], 2025. Disponível em: <https://CRAN.R-project.org/package=DescTools>.

SNIS. SNIS - Série Histórica. In: 2024. Disponível em: <http://app4.mdr.gov.br/serieHistorica/#>. Acesso em: 2 fev. 2024.

SOHN, Jungyul. Watering cities: spatial analysis of urban water use in the Southeastern United States. **Journal of Environmental Planning and Management**, [s. l.], v. 54, n. 10, p. 1351–1371, 2011.

SONG, Malin *et al.* Spatiotemporal characteristics and influencing factors of China's urban water resource utilization efficiency from the perspective of sustainable development. **Journal of Cleaner Production**, [s. l.], v. 338, p. 130649, 2022.

SOUSA, Cláudia O. M.; TEIXEIRA, Lucas V.; FOUTO, Nuno M. M. D. Midterm impacts of a water drought experience: evaluation of consumption changes in São Paulo, Brazil. **Water Policy**, [s. l.], v. 24, n. 1, p. 179–191, 2022.

SOUZA, Carlos M. *et al.* Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, [s. l.], v. 12, n. 17, p. 2735, 2020.

STOCK, James H.; WATSON, Mark W. **Introduction to Econometrics**. 3ª ed. [S. l.]: Pearson, 2011.

STOKER, Philip *et al.* Building Water-Efficient Cities: A Comparative Analysis of How the Built Environment Influences Water Use in Four Western U.S. Cities. **Journal of the American Planning Association**, [s. l.], v. 85, n. 4, p. 511–524, 2019a.

STOKER, Philip *et al.* Neighborhood effects on parcel-level water use. **Sustainable Water Resources Management**, [s. l.], v. 5, n. 3, p. 1303–1313, 2019b.

SUN, Dongying *et al.* Convergence and influencing factors of urban domestic water consumption in the Yangtze River Delta under urbanization. **Urban Water Journal**, [s. l.], v. 20, n. 8, p. 1038–1051, 2023.

TAŞTAN, Hüseyin. Estimation of dynamic water demand function: the case of Istanbul. **Urban Water Journal**, [s. l.], v. 15, n. 1, p. 75–82, 2018.

TAYEBI, Safiyeh *et al.* A Neighborhood-Based Urban Water Carrying Capacity Assessment: Analysis of the Relationship between Spatial-Demographic Factors and Water Consumption Patterns in Tehran, Iran. **Land**, [s. l.], v. 11, n. 12, p. 2203, 2022.

TELFARH, Dua'a B.; JARADAT, Aiman Q.; ISMAIL, Rabah. Examining the Long-Run and Short-Run Relationship between Water Demand and Socio-Economic Explanatory Variables: Evidence from Amman. **Sustainability**, [s. l.], v. 16, n. 6, p. 2315, 2024.

TIMOTEWOS, Mosisa Teferi; BARJENBRUCH, Matthias; BEHAILU, Beshah M. The Assessment of Climate Variables and Geographical Distribution on Residential Drinking Water Demand in Ethiopia. **Water**, [s. l.], v. 14, n. 11, p. 1722, 2022.

TOTH, Elena; BRAGALLI, Cristiana; NERI, Mattia. Assessing the significance of tourism and climate on residential water demand: Panel-data analysis and non-linear modelling of monthly water consumptions. **Environmental Modelling & Software**, [s. l.], v. 103, p. 52–61, 2018a.

TOTH, Elena; BRAGALLI, Cristiana; NERI, Mattia. Assessing the significance of tourism and climate on residential water demand: Panel-data analysis and non-linear modelling of monthly water consumptions. **Environmental Modelling & Software**, [s. l.], v. 103, p. 52–61, 2018b.

VANHAM, Davy *et al.* Rasterised Water Demands: Methodology for Their Assessment and Possible Applications. **Water Resources Management**, [s. l.], v. 25, n. 13, p. 3301–3320, 2011.

VILLARÍN, María C. Methodology based on fine spatial scale and preliminary clustering to improve multivariate linear regression analysis of domestic water consumption. **Applied Geography**, [s. l.], v. 103, p. 22–39, 2019.

VONK; CIRKEL; BLOKKER. Estimating Peak Daily Water Demand Under Different Climate Change and Vacation Scenarios. **Water**, [s. l.], v. 11, n. 9, p. 1874, 2019.

WANG, Dong *et al.* Prediction of water consumption in Beijing based on the multi-variable grey model with adjacent accumulation. **Water Supply**, [s. l.], v. 24, n. 5, p. 1924–1937, 2024.

WANG, Xiaowei; LI, Rongrong. Is Urban Economic Output Decoupling from Water Use in Developing Countries?—Empirical Analysis of Beijing and Shanghai, China. **Water**, [s. l.], v. 11, n. 7, p. 1335, 2019.

WANG, Qiang; WANG, Xiaowei. Moving to economic growth without water demand growth -- a decomposition analysis of decoupling from economic growth and water use in 31 provinces of China. **Science of The Total Environment**, [s. l.], v. 726, p. 138362, 2020.

WARZINIACK, Travis *et al.* Projections of Freshwater Use in the United States Under Climate Change. **Earth's Future**, [s. l.], v. 10, n. 2, p. e2021EF002222, 2022.

WILLUWEIT, Lars; O'SULLIVAN, John J. A decision support tool for sustainable planning of urban water systems: Presenting the Dynamic Urban Water Simulation Model. **Water Research**, [s. l.], v. 47, n. 20, p. 7206–7220, 2013.

WONG, Jefferson See; ZHANG, Qiang; CHEN, Yongqin David. Statistical modeling of daily urban water consumption in Hong Kong: Trend, changing patterns, and forecast. **Water Resources Research**, [s. l.], v. 46, n. 3, p. 2009WR008147, 2010.

WOOLDRIDGE, Jeffrey M. **Introdução à econometria: uma abordagem moderna**. 4ªed. [S. l.]: Cengage Learning Edições Ltda, 2023.

WORLAND, Scott C.; STEINSCHNEIDER, Scott; HORNBERGER, George M. Drivers of Variability in Public-Supply Water Use Across the Contiguous United States. **Water Resources Research**, [s. l.], v. 54, n. 3, p. 1868–1889, 2018.

WU, Hao *et al.* Changing Characteristics of the Water Consumption Structure in Nanjing City, Southern China. **Water**, [s. l.], v. 8, n. 8, p. 314, 2016.

WU, Caimin; LIU, Wei; DENG, Hongbing. Urbanization and the Emerging Water Crisis: Identifying Water Scarcity and Environmental Risk with Multiple Applications in Urban Agglomerations in Western China. **Sustainability**, [s. l.], v. 15, n. 17, p. 12977, 2023.

WU, Lifeng; MENG, Yuan. Water Requirement in North China from Grey Point Prediction and Grey Interval Prediction. **Water**, [s. l.], v. 15, n. 8, p. 1453, 2023.

WU, Junhao; WANG, Zhaocai; DONG, Leyiping. Prediction and analysis of water resources demand in Taiyuan City based on principal component analysis and BP neural network. **Journal of Water Supply: Research and Technology-Aqua**, [s. l.], v. 70, n. 8, p. 1272–1286, 2021.

XIANGMEI, Meng *et al.* Forecast of annual water consumption in 31 regions of China considering GDP and population. **Sustainable Production and Consumption**, [s. l.], v. 27, p. 713–736, 2021.

XIAO-JUN, Wang *et al.* Potential impact of climate change on future water demand in Yulin city, Northwest China. **Mitigation and Adaptation Strategies for Global Change**, [s. l.], v. 20, n. 1, p. 1–19, 2015.

XU, Zhihao *et al.* A Novel Approach for Predicting Water Demand with Complex Patterns Based on Ensemble Learning. **Water Resources Management**, [s. l.], v. 36, n. 11, p. 4293–4312, 2022.

YAN, Ziqi *et al.* Water use characteristics and impact factors in the Yellow River basin, China. **Water International**, [s. l.], v. 45, n. 3, p. 148–168, 2020.

YANG, Tao *et al.* Probabilistic modeling and uncertainty estimation of urban water consumption under an incompletely informational circumstance. **Stochastic Environmental Research and Risk Assessment**, [s. l.], v. 30, n. 2, p. 725–736, 2016.

YANG, Zhicheng *et al.* Water consumption prediction and influencing factor analysis based on PCA-BP neural network in karst regions: a case study of Guizhou Province. **Environmental Science and Pollution Research**, [s. l.], v. 30, n. 12, p. 33504–33515, 2022.

YANG, Jie; CHEN, Xiaohong. Quantification of the Driving Factors of Water Use in the Productive Sector Change Using Various Decomposition Methods. **Water Resources Management**, [s. l.], v. 33, n. 12, p. 4105–4121, 2019.

YILMAZ, Volkan; ALPARS, Mehmet. An Investigation of the Temporal Interaction of Urban Water Consumption in the Framework of Settlement Characteristics. **Water Resources Management**, [s. l.], v. 37, n. 4, p. 1619–1639, 2023.

YILMAZ, V. The use of band similarity in urban water demand forecasting as a new method. **Water Supply**, [s. l.], v. 22, n. 1, p. 1004–1019, 2022.

YOUNIS, Hebah Ibrahim; KIZHISSERI, Mohamed Ibrahim; MOHAMED, Mohamed Mostafa. Forecasting Future Water Demands for Sustainable Development in Al-Ain City, United Arab Emirates. **Water**, [s. l.], v. 15, n. 21, p. 3800, 2023.

YUAN, Chengjun *et al.* Projections of Land Use Change and Water Supply–Demand Assessment Based on Climate Change and Socioeconomic Scenarios: A Case Study of Guizhou Province, China. **Land**, [s. l.], v. 13, n. 2, p. 194, 2024.

ZHANG, Wanjuan *et al.* Evaluating Water Consumption Based on Water Hierarchy Structure for Sustainable Development Using Grey Relational Analysis: Case Study in Chongqing, China. **Sustainability**, [s. l.], v. 10, n. 5, p. 1538, 2018.

ZHANG, Peilin *et al.* Socioeconomic drivers of water use in China during 2002–2017. **Resources, Conservation and Recycling**, [s. l.], v. 154, p. 104636, 2020.

ZHANG, J. Z. *et al.* Using a fuzzy approach to assess adaptive capacity for urban water resources. **International Journal of Environmental Science and Technology**, [s. l.], v. 16, n. 3, p. 1571–1580, 2019.

ZHAO, Xuelian; FAN, Xinghua; LIANG, Jiaochen. Kuznets type relationship between water use and economic growth in China. **Journal of Cleaner Production**, [s. l.], v. 168, p. 1091–1100, 2017.

ZHOU, Shengwen *et al.* A Hybrid Framework for Multivariate Time Series Forecasting of Daily Urban Water Demand Using Attention-Based Convolutional Neural Network and Long Short-Term Memory Network. **Sustainability**, [s. l.], v. 14, n. 17, p. 11086, 2022.

ZHOU, Feng; SU, Weici; ZHANG, Fengtai. Influencing Indicators and Quantitative Assessment of Water Resources Security in Karst Region Based on PSER Model—The Case of Guizhou. **Sustainability**, [s. l.], v. 11, n. 20, p. 5671, 2019.

ZOU, Weiyong; XIONG, Yunjun. Does artificial intelligence promote industrial upgrading? Evidence from China. **Economic Research-Ekonomska Istraživanja**, [s. l.], v. 36, n. 1, p. 1666–1687, 2023.

ZUBAIDI, Salah L. *et al.* A Method for Predicting Long-Term Municipal Water Demands Under Climate Change. **Water Resources Management**, [s. l.], v. 34, n. 3, p. 1265–1279, 2020a.

ZUBAIDI, Salah L. *et al.* A Novel approach for predicting monthly water demand by combining singular spectrum analysis with neural networks. **Journal of Hydrology**, [s. l.], v. 561, p. 136–145, 2018a.

ZUBAIDI, Salah L. *et al.* Assessing the Benefits of Nature-Inspired Algorithms for the Parameterization of ANN in the Prediction of Water Demand. **Journal of Water Resources Planning and Management**, [s. l.], v. 149, n. 1, p. 04022075, 2023.

ZUBAIDI, Salah L. *et al.* Hybridised Artificial Neural Network Model with Slime Mould Algorithm: A Novel Methodology for Prediction of Urban Stochastic Water Demand. **Water**, [s. l.], v. 12, n. 10, p. 2692, 2020b.

ZUBAIDI, Salah L. *et al.* Short-Term Urban Water Demand Prediction Considering Weather Factors. **Water Resources Management**, [s. l.], v. 32, n. 14, p. 4527–4542, 2018b.

APÊNDICE A

Modelos de dados em painel sem efeitos de interação espacial (m=2)

Variável	OLS	Efeitos Fixos (Individuais)	Efeitos Fixos (Tempo)	Efeitos Fixos (Indiv. + Tempo)
Intercepto	73,27 ***	-	-	-
Precipitação	$-9,31 \times 10^{-2}$	$-7,68 \times 10^{-2}$	$1,38 \times 10^{-1}$	$-1,02 \times 10^{-1}$
Temperatura média	3,29 **	$4,19 \times 10^{-1}$	3,72 **	-2,93
População	$-3,21 \times 10^{-5}$	$8,24 \times 10^{-6}$	$-3,14 \times 10^{-6}$	$-3,27 \times 10^{-5}$
V.A. indústria <i>per capita</i>	$1,22 \times 10^{-5}$	$1,01 \times 10^{-4}$ *	$1,03 \times 10^{-5}$	$9,02 \times 10^{-5}$ *
V.A. comércio <i>per capita</i>	$2,65 \times 10^{-4}$ •	$1,33 \times 10^{-4}$	$2,52 \times 10^{-4}$ •	$1,05 \times 10^{-4}$
V.A. serviços <i>per capita</i>	$1,57 \times 10^{-3}$ *	$5,42 \times 10^{-4}$	$1,59 \times 10^{-3}$ *	$5,49 \times 10^{-4}$
Proporção de área urbana	1,68 **	$-4,96 \times 10^{-1}$	1,64 **	-2,40
Proporção de área de formação natural não florestal	$-1,20 \times 10^{-1}$	-1,86	$-9,70 \times 10^{-2}$	-2,25
Proporção de área de corpo d'água	$-1,36 \times 10^{-1}$	$1,72 \times 10^1$ **	$-1,63 \times 10^{-1}$	$1,68 \times 10^1$ **
Proporção de área de agricultura	$-3,02 \times 10^{-1}$ **	$-4,92 \times 10^{-1}$	$-3,08 \times 10^{-1}$ **	$-7,46 \times 10^{-1}$
Proporção de área não vegetada	4,37 •	$1,66 \times 10^1$	4,37 *	$1,13 \times 10^1$
R ²	0,24	0,019	0,24	0,016
R ² ajustado	0,24	0,016	0,24	0,013
α^2	874,82	218,32	870,92	216,28
LogL	-14173	-12126	-14166	-12112
LM defasagem espacial	32,79 ***	1,48	29,52 ***	4,18 *
LM robusto defasagem espacial	27,31 ***	1,36	23,53 ***	0,62
LM erro espacial	18,02 ***	1,82	16,63 ***	4,54 *
LM robusto erro espacial	12,54 ***	1,70	10,63 ***	0,97

*** p < 0,001 ** p < 0,01 * p < 0,05 • p < 0,1

Modelos de dados em painel sem efeitos de interação espacial (m=3)

Variável	OLS	Efeitos Fixos (Individuais)	Efeitos Fixos (Tempo)	Efeitos Fixos (Indiv. + Tempo)
Intercepto	73,92 ***	-	-	-
Precipitação	$-7,00 \times 10^{-2}$	$-5,58 \times 10^{-2}$	$2,17 \times 10^{-1}$	$-6,46 \times 10^{-2}$
Temperatura média	3,21 **	$4,12 \times 10^{-1}$	3,78 **	-3,63
População	$-3,07 \times 10^{-5}$	$2,19 \times 10^{-5}$	$-3,09 \times 10^{-5}$	$2,52 \times 10^{-5}$
V.A. indústria <i>per capita</i>	$1,31 \times 10^{-5}$	$1,23 \times 10^{-4}$ ***	$1,74 \times 10^{-5}$	$1,10 \times 10^{-4}$ **
V.A. comércio <i>per capita</i>	$2,67 \times 10^{-4}$ •	$1,17 \times 10^{-4}$	$2,55 \times 10^{-4}$ •	$8,48 \times 10^{-5}$
V.A. serviços <i>per capita</i>	$1,60 \times 10^{-3}$ *	$7,30 \times 10^{-4}$ •	$1,56 \times 10^{-3}$ *	$7,49 \times 10^{-4}$ •
Proporção de área urbana	1,69 **	$-6,48 \times 10^{-2}$	1,66 **	-2,30
Proporção de área de formação natural não florestal	$-1,01 \times 10^{-1}$	-2,40	$-8,46 \times 10^{-2}$	-2,90
Proporção de área de corpo d'água	$-2,04 \times 10^{-1}$	$1,64 \times 10^1$ **	$-2,23 \times 10^{-1}$	$1,58 \times 10^1$ *
Proporção de área de agricultura	$-2,92 \times 10^{-1}$ **	$-5,70 \times 10^{-1}$	$-3,07 \times 10^{-1}$ **	$-8,80 \times 10^{-1}$
Proporção de área não vegetada	4,49 **	$1,53 \times 10^1$	4,45 *	9,19
R ²	0,24	0,020	0,24	0,017
R ² ajustado	0,24	0,018	0,24	0,014
α^2	870,63	219,88	866,49	217,30
LogL	-14165	-12136	-14519	-12119
LM defasagem espacial	34,30 ***	1,02	30,60 ***	4,15 *
LM robusto defasagem espacial	27,11 ***	2,36	23,44 ***	1,01
LM erro espacial	19,13 ***	1,42	17,45 ***	4,61 *
LM robusto erro espacial	12,03 ***	2,76	10,30 ***	1,48

*** p < 0,001 ** p < 0,01 * p < 0,05 • p < 0,1

APÊNDICE B

Coeficientes do modelos SDM com efeito fixo de tempo (m=2)

Variável	SDM Efeito fixo de tempo
Precipitação	-2,21
Temperatura média	3,75 **
População	-1,70 x 10 ⁻⁵ •
V.A. indústria <i>per capita</i>	7,3 x 10 ⁻⁵ ***
V.A. comércio <i>per capita</i>	3,6 x 10 ⁻⁴ ***
V.A. serviços <i>per capita</i>	9,17 x 10 ⁻⁴ ***
Proporção de área urbana	1,33 ***
Proporção de área de formação natural não florestal	-2,75 x 10 ⁻¹ **
Proporção de área de corpo d'água	-5,5 x 10 ⁻¹ **
Proporção de área de agricultura	-2,93 x 10 ⁻¹
Proporção de área não vegetada	6,79 ***
W-Precipitação	1,51
W-Temperatura média	-2,54 •
W-População	-2,01 x 10 ⁻⁴
W-V.A. indústria <i>per capita</i>	1,13 x 10 ⁻⁴ *
W-V.A. comércio <i>per capita</i>	-9,7 x 10 ⁻⁵
W-V.A. serviços <i>per capita</i>	3,83 x 10 ⁻³ ***
W-Proporção de área urbana	2,14 ***
W-Proporção de área de formação natural não florestal	4,07 x 10 ⁻¹ **
W-Proporção de área de corpo d'água	5,51 x 10 ⁻¹ •
W-Proporção de área de agricultura	1,14 x 10 ⁻²
W-Proporção de área não vegetada	-2,83
ρ	0,13 ***
R ²	0,27
R ² ajustado	0,27

*** p < 0,001 ** p < 0,01 * p < 0,05 • p < 0,1

Coeficientes do modelo SDM com efeito fixo de tempo (m=3)

Variável	SDM Efeito fixo de tempo
Precipitação	-2,33
Temperatura média	3,59 **
População	-1,70 x 10 ⁻⁵ •
V.A. indústria <i>per capita</i>	7,00 x 10 ⁻⁵ ***
V.A. comércio <i>per capita</i>	3,54 x 10 ⁻⁴ ***
V.A. serviços <i>per capita</i>	9,39 x 10 ⁻⁴ ***
Proporção de área urbana	1,35 ***
Proporção de área de formação natural não florestal	-2,40 x 10 ⁻¹ •
Proporção de área de corpo d'água	-5,71 x 10 ⁻¹ **
Proporção de área de agricultura	-2,85 x 10 ⁻¹ ***
Proporção de área não vegetada	6,80 ***
W-Precipitação	1,76
W-Temperatura média	-2,48 •
W-População	-1,99 x 10 ⁻⁴ ***
W-V.A. indústria <i>per capita</i>	1,33 x 10 ⁻⁴ **
W-V.A. comércio <i>per capita</i>	-9,50 x 10 ⁻⁵
W-V.A. serviços <i>per capita</i>	3,67 x 10 ⁻³ ***
W-Proporção de área urbana	2,19 ***
W-Proporção de área de formação natural não florestal	3,66 x 10 ⁻¹ **
W-Proporção de área de corpo d'água	5,82 x 10 ⁻¹ •
W-Proporção de área de agricultura	1,63 x 10 ⁻²
W-Proporção de área não vegetada	-3,25 •
ρ	0,13 ***
R ²	0,27
R ² ajustado	0,27

*** p < 0,001 ** p < 0,01 * p < 0,05 • p < 0,1

APÊNDICE C

Efeito direto indireto e total (m=2)

Variável	Efeito direto	Efeito indireto	Efeito total
Precipitação	-2,18	1,38	-0,80
Temperatura média	3,70 **	-2,31	1,39 *
População	$-2,20 \times 10^{-5} *$	$-2,28 \times 10^{-4} ***$	$-2,51 \times 10^{-4} ***$
V.A. indústria <i>per capita</i>	$7,6 \times 10^{-5} ***$	$1,37 \times 10^{-4} *$	$2,14 \times 10^{-4} ***$
V.A. comércio <i>per capita</i>	$3,59 \times 10^{-4} ***$	$-5,7 \times 10^{-5}$	$3,02 \times 10^{-4} \bullet$
V.A. serviços <i>per capita</i>	$1,01 \times 10^{-3} ***$	$4,43 \times 10^{-3} ***$	$5,44 \times 10^{-3} ***$
Proporção de área urbana	1,39 ***	2,60 ***	3,99 ***
Proporção de área de formação natural não florestal	$-2,66 \times 10^{-1} *$	$4,18 \times 10^{-1} **$	$1,52 \times 10^{-1}$
Proporção de área de corpo d'água	$-5,39 \times 10^{-1} **$	$5,39 \times 10^{-1} \bullet$	$1,05 \times 10^{-4}$
Proporção de área de agricultura	$-2,94 \times 10^{-1} ***$	$-2,94 \times 10^{-2}$	$-3,24 \times 10^{-1} ***$
Proporção de área não vegetada	6,74 ***	-2,20	4,54 *

*** p < 0,001 ** p < 0,01 * p < 0,05 • p < 0,1

Efeito direto indireto e total (m=3)

Variável	Efeito direto	Efeito indireto	Efeito total
Precipitação	-2,29	1,63	$-6,62 \times 10^{-1}$
Temperatura média	3,54 **	-2,25	1,29 *
População	$-2,2 \times 10^{-5} *$	$-2,27 \times 10^{-4} ***$	$-2,49 \times 10^{-4} ***$
V.A. indústria <i>per capita</i>	$7,4 \times 10^{-5} ***$	$1,61 \times 10^{-4} **$	$2,36 \times 10^{-4} ***$
V.A. comércio <i>per capita</i>	$3,53 \times 10^{-4} ***$	$-5,3 \times 10^{-5}$	$3,00 \times 10^{-4} \bullet$
V.A. serviços <i>per capita</i>	$1,04 \times 10^{-3} ***$	$4,30 \times 10^{-3} ***$	$5,43 \times 10^{-3} ***$
Proporção de área urbana	1,41 ***	2,69 ***	4,10 ***
Proporção de área de formação natural não florestal	$-2,32 \times 10^{-1} *$	$3,77 \times 10^{-1} **$	$1,45 \times 10^{-1}$
Proporção de área de corpo d'água	$-5,58 \times 10^{-1} **$	$5,70 \times 10^{-1} \bullet$	$1,20 \times 10^{-2}$
Proporção de área de agricultura	$-2,87 \times 10^{-1} ***$	$-2,57 \times 10^{-2}$	$-3,12 \times 10^{-1} ***$
Proporção de área não vegetada	6,74 ***	-2,63	4,11 *

*** p < 0,001 ** p < 0,01 * p < 0,05 • p < 0,1

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
BIBLIOTECA UNIVERSITÁRIA
REPOSITÓRIO INSTITUCIONAL

CENTRO DE CIÊNCIAS TECNOLÓGICAS – CCT

ATESTADO DE VERSÃO FINAL

Eu, Andreza Kalbusch, professora do curso de Engenharia Civil, declaro que esta é a versão final aprovada pela comissão julgadora da dissertação/tese intitulada: **“Análise das relações espaciais e temporais entre o consumo de água em Santa Catarina e variáveis climáticas, econômicas e sociodemográficas”** de autoria do(a) acadêmico Fabiana Weimann Araujo.

Joinville, 01 de setembro de 2025.

Assinatura digital do(a) orientador(a):

Andreza Kalbusch