

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

DESIGUALDADES HÍDRICO-CLIMÁTICAS NO BRASIL: UMA ANÁLISE DE AUTOCORRELAÇÃO ESPACIAL DOS ODS 6 E 13

Tereza Margarida Xavier de Melo Lopes¹; Samiria Maria Oliveira da Silva²; Francisco de Assis de Sousa Filho³ & Brenda Camila Ferreira⁴

Abstract: The achievement of the Sustainable Development Goals (SDGs) presents significant disparities among Brazilian municipalities. This study investigates the spatial patterns of the percentage performance of SDG 6 (clean water and sanitation) and SDG 13 (climate action) in Brazil for the year 2024, based on data from the Sustainable Development Index for Brazilian Cities (IDSC-BR). The methodology applies spatial autocorrelation analysis using Global and Local Moran's I (LISA), with a first-order Rook contiguity spatial weights matrix. The results reveal significant spatial autocorrelation for both variables, with Moran's I values of 0.541 for SDG 6 and 0.692 for SDG 13, indicating strong spatial patterns. High-High clusters of SDG 6 are mainly concentrated in the Southeast, while Low-Low clusters are predominant in the North and Northeast, reflecting historical disparities in sanitation infrastructure. In the case of SDG 13, High-High clusters are found in the North (areas with low emissions and greater forest cover) and the Southeast (with stronger institutional capacity), while Low-Low clusters are concentrated in the Center-West. The analysis highlights territorial inequalities and reinforces the need for regionally coordinated public policies. By providing technical input on the climate and water-related performance of Brazilian municipalities, the proposed approach contributes to territorial planning and the prioritization of investments in vulnerable contexts, in alignment with Brazil's commitments under COP 30 and the principles of the 2030 Agenda.

Resumo: O alcance dos Objetivos de Desenvolvimento Sustentável (ODS) apresenta grandes disparidades entre os municípios brasileiros. Este estudo investiga os padrões espaciais dos alcances percentuais dos ODS 6 (água potável e saneamento) e ODS 13 (ação climática) no Brasil, no ano de 2024, com base nos dados do Índice de Desenvolvimento Sustentável das Cidades – Brasil (IDSC-BR). A metodologia emprega análise de autocorrelação espacial por meio dos Índices de Moran Global e Local (LISA), utilizando matriz de vizinhança do tipo Rook de primeira ordem. Os resultados revelam autocorrelação espacial significativa para ambas as variáveis, com Moran's I de 0,541 para a ODS 6 e 0,692 para a ODS 13, indicando padrões espaciais marcantes. Os clusters Alto-Alto do ODS 6 concentram-se, majoritariamente, no Sudeste, enquanto os clusters Baixo-Baixo predominam no Norte e Nordeste, refletindo disparidades históricas em saneamento. Já para o ODS 13, os clusters Alto-Alto localizam-se na região Norte (em áreas de baixa emissão e maior cobertura florestal) e no Sudeste (com maior estrutura institucional), enquanto os Baixo-Baixo concentram-se no Centro-Oeste. A análise evidencia desigualdades territoriais e reforça a necessidade de políticas públicas articuladas regionalmente. Ao fornecer subsídios técnicos sobre o desempenho climático e hídrico dos municípios brasileiros, a abordagem proposta contribui para o planejamento territorial e a priorização de investimentos em contextos de vulnerabilidade, em consonância com os compromissos assumidos pelo Brasil no âmbito da COP 30 e com os princípios da Agenda 2030.

1) Doutorado em Engenharia Civil (Recursos Hídricos), Universidade Federal do Ceará – Campus do Pici, terezamelo@alu.ufc.br.

2) Professora do Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará – Campus do Pici, samiriamaria@gmail.com.

3) Professor do Departamento de Engenharia Hidráulica e Ambiental, Universidade Federal do Ceará – Campus do Pici, assis@ufc.br.

4) Mestranda em Engenharia de Recursos Hídricos e Ambiental, Universidade Federal do Paraná, brendacamila@ufpr.br

Palavras-Chave – ODS 6; ODS 13; Índice de Moran.

1. INTRODUÇÃO

Os Objetivos de Desenvolvimento Sustentável (ODSs), estabelecidos em 2015 pela Organização das Nações Unidas (ONU), configuram-se como uma agenda global voltada para a promoção do desenvolvimento sustentável em suas dimensões econômica, social e ambiental até 2030 (ONU, 2015). De acordo com o Sustainable Development Solutions Network (SDSN), o progresso no alcance dos ODSs requer uma abordagem integrada que considere as inter-relações entre os objetivos (SDSN, 2023). Entre os 17 objetivos, o ODS 6 busca assegurar o acesso universal e equitativo à água potável e ao saneamento básico, enquanto o ODS 13 visa promover ações urgentes para combater as mudanças climáticas e seus impactos. A relação entre esses dois objetivos é evidente, uma vez que a gestão sustentável dos recursos hídricos está intrinsecamente ligada à resiliência climática, dado que eventos extremos, como secas e enchentes, impactam diretamente o acesso à água e o saneamento.

O Brasil, país marcado por expressivas disparidades hídricas e socioeconômicas (Lopes *et al.*, 2024), apresenta grandes desafios para o alcance do ODS 6 e ODS 13. De acordo com dados do Sistema Nacional de Informações sobre Saneamento (SNIS), o atendimento com rede de água alcançou 84,9% da população total em 2022, enquanto a cobertura de esgoto foi de apenas 56,0% (SNIS, 2022). Esse cenário se agrava nas regiões Norte e Nordeste, onde a cobertura de água permanece abaixo da média nacional, com índices de 64,2% e 76,9%, respectivamente (SNIS, 2022). Além disso, a concentração de focos de queimadas e a baixa implementação de estratégias de mitigação climática acentuam as desigualdades no alcance do ODS 13, particularmente na região amazônica (IDSC, 2024). Essas disparidades são ainda mais acentuadas quando se observam as regiões Norte e Nordeste, que historicamente apresentam os menores índices de cobertura de saneamento, refletindo desigualdades estruturais que afetam a implementação das metas do ODS 6 (SNIS, 2022).

Diante do exposto, este estudo propõe a Análise Exploratória de Dados Espaciais (AEDE) para avaliar a dependência espacial do alcance do ODS 6 e 13 por meio dos testes estatísticos de Autocorrelação Espacial: Índices de Moran Global (I) e Local (IL), conforme descrito por Almeida (2012). Tais índices têm sido amplamente utilizados em diversos campos do conhecimento, abordando temas relacionados à saúde (CHEONG *et al.*, 2022; ALPHONSO *et al.*, 2024), desenvolvimento socioeconômico (GIOVANINI *et al.*, 2022; HAN *et al.*, 2024), clima (CHEN *et al.*, 2023; XIANG *et al.*, 2024), bem como análises espaciais relacionadas aos recursos hídricos (MEDINA-RIVAS *et al.*, 2022; WANG *et al.*, 2023). No entanto, é notável a carência de estudos específicos voltados para a análise espacial integrada do alcance dos ODS 6 e 13, considerando simultaneamente as dimensões hídricas e climáticas no território brasileiro. Este trabalho visa preencher essa lacuna, empregando metodologias geoestatísticas para mapear áreas de vulnerabilidade e resiliência hídrica e climática, contribuindo para a formulação de políticas públicas regionais e nacionalmente articuladas. Além disso, as análises espaciais são fundamentais para a promoção da equidade no acesso à água, uma vez que identificar pontos de maior e menor consumo é essencial para garantir um acesso equitativo à água, especialmente em regiões onde a oferta é limitada (MEDINA-RIVAS *et al.*, 2022).

Assim, o presente trabalho visa identificar as áreas de maior e menor alcance das metas dos ODS 6 e 13 no Brasil, destacando as disparidades regionais e a persistência de desigualdades territoriais que comprometem a equidade e a justiça hídrica e climática no país, a partir Índice do Moran Global e Local (LISA). Ao evidenciar os clusters espaciais e os padrões de associação local,

espera-se fornecer subsídios técnicos para o planejamento territorial integrado e para a formulação de políticas públicas mais assertivas e regionalizadas.

2. METODOLOGIA

O processo metodológico consiste em três fases principais: i) coleta e estruturação dos dados; ii) cálculo das matrizes de ponderação espacial; iii) identificação dos padrões de autocorrelação espacial do alcance do ODS 6 e 13.

2.1. Base de dados

Os dados utilizados neste estudo foram coletados a partir da plataforma do Índice de Desenvolvimento Sustentável das Cidades – Brasil (IDSC-BR), desenvolvida pelo *Sustainable Development Solutions Network* (SDSN). O IDSC-BR é alimentado por indicadores nacionais provenientes de bases como o Sistema Nacional de Informações sobre Saneamento (SNIS), o Instituto Brasileiro de Geografia e Estatística (IBGE), o MapBiomas, o SEEG Municípios e o DATASUS.

O cálculo do ODS 6 é realizado por meio da normalização de cinco indicadores, enquanto o ODS 13 é composto por quatro indicadores (Quadro 1). Todos os dados referem-se ao ano de 2024, última atualização disponível na plataforma.

Quadro 1 - Indicadores que compõem as ODS 6 e 13 no IDSC-BR (2024)

ODS	Indicador	Unidade de Medida	Fonte
ODS 6	Perda de água tratada na distribuição	%	SNIS
	População atendida com abastecimento de água	%	
	População atendida com esgotamento sanitário	%	
	Índice de tratamento de esgoto	%	
ODS 13	Doenças relacionadas ao saneamento ambiental inadequado	Casos por 100 mil habitantes	DATASUS
	Emissões de CO2 per capita	Toneladas de CO2 por habitante	SEEG Municípios
	Concentração de focos de calor	Focos por mil km ²	MapBiomas / INPE
	Estratégias para gestão de riscos e prevenção a desastres naturais	%	IBGE
	Percentual do município desflorestado	%	MapBiomas

A metodologia para a construção do IDSC-BR é composta por três etapas principais: i) são corrigidos os valores atípicos (*outliers*); ii) os dados são normalizados entre 0 e 100, com base em valores-alvo de desempenho internacionalmente reconhecidos ou definidos a partir de boas práticas; e iii) os indicadores normalizados são agregados dentro de cada ODS por meio de média aritmética simples, e posteriormente utilizados para compor o índice geral.

A metodologia está alinhada às diretrizes internacionais de monitoramento dos ODS, sendo utilizada também no SDG Index global produzido pelo próprio SDSN (SDSN, 2023) e em publicações da UNESCO, para monitoramento dos ODSs (UNESCO-UIS, 2020). Tal alinhamento reforça a legitimidade do método adotado no presente trabalho.

A espacialização dos dados foi realizada por meio da linguagem R, utilizando o shapefile oficial dos municípios brasileiros disponibilizado pelo IBGE (2023). Os indicadores foram associados à malha municipal e submetidos às análises espaciais subsequentes.

2.1. Matrizes de Ponderação Espacial

A matriz de ponderação espacial, também conhecida como matriz de vizinhança, exerce um papel central nas análises geoestatísticas, por viabilizar a estruturação das relações espaciais entre as

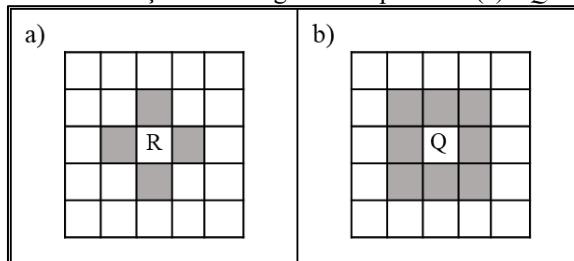
unidades observadas. De forma geral, essa matriz atribui pesos às interações entre os espaços geográficos, com base em critérios de proximidade ou contiguidade. Esses pesos espaciais traduzem o grau de conectividade ou proximidade geográfica, que conduzem as análises posteriores, permitindo quantificar a influência das relações espaciais (ALMEIDA, 2012).

Nesse contexto, a matriz de ponderação espacial (w) configura-se como uma matriz quadrada de dimensões $n \times n$, fornecendo uma representação matemática que viabiliza a estimativa de pesos espaciais w_{ij} . Geralmente, essa matriz é expressa de maneira binária, indicando se as unidades espaciais são vizinhas ou não. Assim, atribuiu-se o valor unitário para sinalizar a presença de vizinhança e valor nulo caso não exista vizinhança:

$$w_{i,j} = \begin{cases} 1 & \text{se } i \text{ e } j \text{ são vizinhas} \\ 0 & \text{se } i \text{ e } j \text{ não são vizinhas} \end{cases} \quad (1)$$

Para a definição da estrutura espacial de vizinhança, adotaram-se as convenções de contiguidade do tipo *Rook* (Torre) e *Queen* (Rainha), conforme ilustrado na Figura 1.

Figura 1 - Convenção de contiguidade tipo *Rook* (a) e *Queen* (b).



Fonte: ALMEIDA (2012).

Na matriz de ponderação espacial do tipo *Rook*, os pesos w_{ij} assumem valor igual a 1 quando duas unidades espaciais compartilham uma fronteira linear (aresta), e 0 caso contrário. Já na configuração do tipo *Queen*, a definição de vizinhança é mais abrangente, atribuindo o valor 1 não apenas às unidades que compartilham arestas, mas também às aquelas que compartilham vértices. Em síntese, a principal diferença entre as matrizes *Rook* e *Queen* está na inclusão dos vértices como critério de contiguidade (ALMEIDA, 2012).

2.3. Identificação dos padrões de autocorrelação espacial

A análise da autocorrelação espacial foi estruturada sob duas abordagens complementares: a global e a local. A abordagem global identifica padrões espaciais em toda a extensão do território nacional, partindo da premissa de homogeneidade espacial para detectar a presença de aglomerados de municípios com características semelhantes ou contrastantes em relação aos ODS 6 e 13. Por sua vez, a abordagem local direciona o foco da análise para a pontos específicos do território, permitindo a identificação de clusters espaciais que podem corroborar ou divergir do padrão global, evidenciando a existência de concentrações atípicas ou comportamentos heterogêneos no espaço geográfico (MATHUR, 2015).

No contexto dos Sistemas de Informação Geográfica (SIG), a autocorrelação espacial constitui um recurso metodológico relevante para avaliar o grau de similaridade ou dissimilaridade entre municípios vizinhos, possibilitando a identificação de padrões de concentração, dispersão ou aleatoriedade na distribuição espacial das variáveis observadas (LONGLEY et al., 2011).

Para a análise da dependência espacial entre os municípios brasileiros, foram empregados o Índice de Moran Global (I), que fornece uma métrica geral da autocorrelação espacial ao longo do território, e o Índice de Moran Local (LISA), que possibilita a identificação de clusters espaciais específicos, revelando áreas onde a associação espacial é mais intensa, seja positiva ou negativa.

2.3.1. Índice de Moran Global (I)

O Índice de Moran Global é utilizado para quantificar a presença de dependência espacial ao avaliar o grau de similaridade entre os valores observados em unidades geográficas vizinhas. A autocorrelação espacial é identificada quando existe uma correspondência significativa entre os valores das variáveis em áreas próximas, sugerindo a existência de padrões não aleatórios na distribuição espacial dos dados (ANSELIN, 1995).

O Índice de Moran Global é calculado a partir da equação 2:

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

Em que: n é o número de unidades espaciais; x_i e x_j correspondem aos valores do indicador percentual de alcance das ODS 6 e 13 nas unidades espaciais, e w_{ij} representa os elementos da matriz de pesos espaciais, responsável por capturar a estrutura de contiguidade geográfica entre os municípios brasileiros.

O valor do índice varia entre -1 e 1. Valores positivos indicam autocorrelação espacial positiva, ou seja, municípios com valores semelhantes tendem a estar próximos. Valores negativos apontam para autocorrelação negativa, sugerindo padrões espaciais de dissimilaridade entre vizinhos. Um valor próximo de zero indica ausência de dependência espacial.

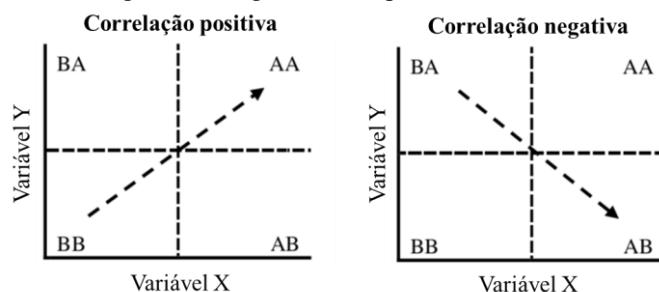
Para este estudo, o Índice de Moran Global foi calculado com base nas matrizes de contiguidade do tipo *Rook* e *Queen*, ambas de primeira ordem. Após a estimativa em cada configuração, adotou-se aquela que apresentou o maior valor de autocorrelação espacial para prosseguimento das análises subsequentes. A significância estatística do índice foi verificada por meio de um teste de permutação aleatória, utilizando 999 permutações e adotando um nível de significância de $p < 0,05$, conforme estipulado por Medeiros et al. (2015).

2.3.2. Índice de Moran Local (IL)

Após analisar a autocorrelação espacial em uma abordagem global, prosseguiu-se com a avaliação local com o objetivo de identificar padrões diferenciados de alcance dos ODS 6 e 13. Para tanto, aplicou-se o Indicador Local de Associação Espacial (LISA), fundamentado no Índice de Moran Local.

A estatística LISA permite decompor a autocorrelação global em componentes locais, classificando as observações em quatro categorias distintas (Figura 2), de acordo com a distribuição dos municípios nos quadrantes do gráfico de dispersão de Moran (ANSELIN, 2005).

Figura 2 - Diagrama de dispersão de Moran.



Fonte: Adaptado de Marconato et al. (2013)

Os quadrantes AA (alto-alto) e BB (baixo-baixo) indicam a presença de autocorrelação espacial positiva, sugerindo a existência de áreas onde o padrão observado é semelhante entre unidades vizinhas. Por outro lado, os quadrantes AB (alto-baixo) e BA (baixo-alto) refletem situações de

autocorrelação espacial negativa, evidenciando contrastes entre os valores observados em unidades vizinhas.

Dessa forma, os quatro quadrantes permitem identificar diferentes configurações de associação espacial, as quais são visualizadas no diagrama de dispersão. Caso os pontos se distribuam de forma homogênea entre os quadrantes, a autocorrelação espacial é pouco evidente. Em contrapartida, se os valores se concentram na diagonal que conecta os quadrantes AA e BB, há indicação de autocorrelação positiva. Já a concentração na diagonal que atravessa os quadrantes AB e BA sugere autocorrelação negativa (MEDEIROS et al., 2015).

Em síntese, o Índice de Moran Local (LISA) permite identificar clusters espaciais e outliers com base na seguinte equação:

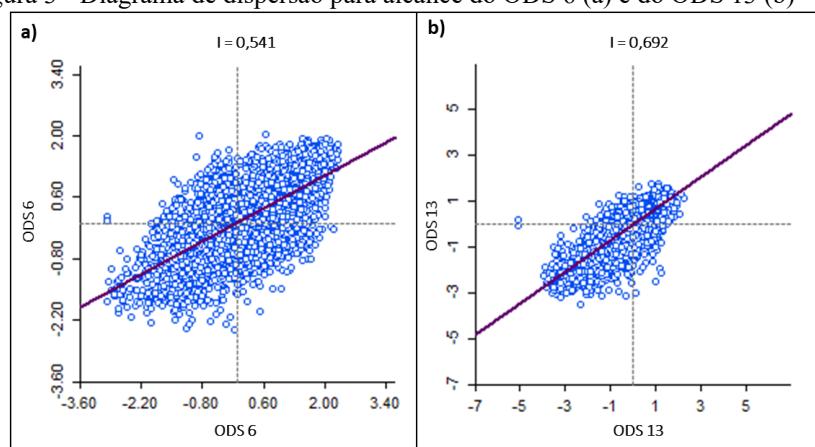
$$I_L = \frac{(y_i - \bar{y}) \sum_j w_{ij} (y_j - \bar{y})}{\sum_i (y_i - \bar{y})^2 / n} \quad (4)$$

Em que n é o número de observações, y_i é a observação da variável estudada na região i , y_j é a observação da variável estudada na região j , \bar{y} corresponde à média da variável estudada, e w_{ij} representa cada um dos elementos da matriz de pesos espaciais que captura a estrutura espacial da área de estudo.

RESULTADOS E DISCUSSÕES

A análise dos padrões espaciais dos ODS 6 e 13 no Brasil foi conduzida por meio do Índice de Moran Global e Local (LISA), utilizando a matriz de contiguidade espacial do tipo Rook. A escolha dessa matriz foi motivada pelos resultados ligeiramente superiores no índice de Moran Global para o ODS 6 (0,541) em comparação à matriz Queen (0,540), mantendo-se o valor do ODS 13 em 0,692 em ambas as matrizes. Salienta-se que o p -valor, tanto para a matriz Rook quanto para a matriz Queen de primeira ordem, foi significativo ao nível de 1% ($p < 0,01$), indicando a existência de autocorrelação espacial significativa em ambas as análises. Assim, optou-se pela matriz Rook por sua capacidade de evidenciar uma dependência espacial mais acentuada, sendo esta a base para as análises subsequentes.

Figura 3 - Diagrama de dispersão para alcance do ODS 6 (a) e do ODS 13 (b) – 2024

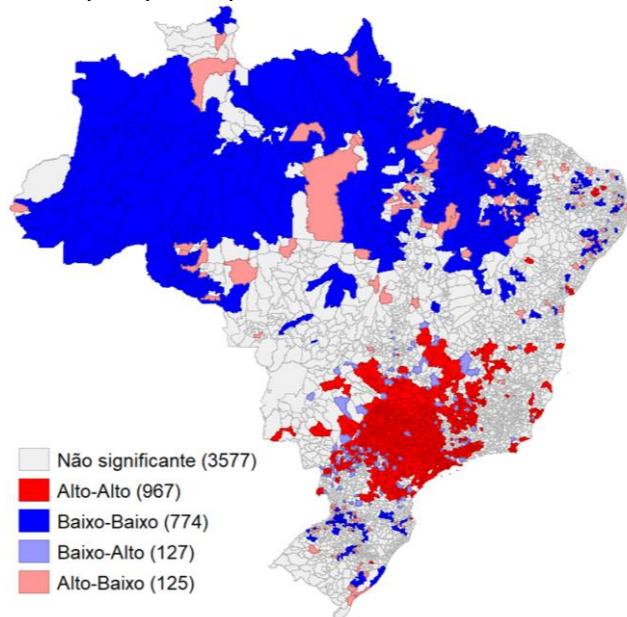


O Índice de Moran Global apresentou um valor de 0,541 para o ODS 6 e 0,692 para o ODS 13 (Figura 3), evidenciando autocorrelação espacial positiva moderada para o ODS 6 e forte para o ODS 13. Os resultados indicaram a existência de autocorrelação espacial positiva para ambos os objetivos, sugerindo a formação de aglomerados territoriais com padrões semelhantes de alcance dos objetivos do desenvolvimento sustentável.

A Figura 4 apresenta os padrões de associação espacial para o alcance do ODS 6 entre os municípios brasileiros. Os clusters Alto-Alto (cor vermelha) indicam municípios que alcançaram elevados percentuais nas metas de água e saneamento (ODS 6), cercados por vizinhos com desempenhos também altos. Esses clusters são compostos por 967 municípios, majoritariamente concentrados nas regiões Sudeste e Centro-Oeste, onde se destaca a infraestrutura consolidada de saneamento básico, notadamente em estados como São Paulo, Minas Gerais e Goiás.

Em contrapartida, os clusters Baixo-Baixo (cor azul escuro) identificam municípios com baixo alcance nas metas do ODS 6, rodeados por áreas com desempenho semelhante. Ao todo, 774 municípios compõem esses clusters, situados predominantemente no Norte e Nordeste, refletindo déficits em saneamento básico. A configuração espacial desses clusters evidencia a perpetuação das desigualdades estruturais no território brasileiro, destacando a vulnerabilidade hídrica no contexto do alcance do ODS 6.

Figura 4 - Indicadores Locais de Associação Espacial (LISA) da análise do alcance do ODS 6 no Brasil. O número de municípios que compõem cada cluster é evidenciado entre parênteses.



A Figura 5 ilustra os padrões espaciais para o alcance do ODS 13. A configuração espacial apresenta um padrão de alta concentração e autocorrelação espacial positiva, conforme indicado pelo valor do Moran Global (0,692). Nesse contexto, 1.233 municípios foram classificados como clusters Alto-Alto (cor vermelha), concentrados especialmente no Sudeste e no Nordeste. O desempenho elevado nessas áreas é impulsionado principalmente pela maior implementação de estratégias de transição para baixo carbono, e pela menor concentração de focos de queimadas, refletindo a estrutura urbana e industrializada dessas regiões. Esse padrão é fortemente associado ao desenvolvimento econômico do Sudeste, que historicamente concentrou investimentos em infraestrutura e políticas públicas de mitigação climática, configurando um cenário mais favorável para o alcance das metas do ODS 13.

Em contrapartida, a Amazônia se configura como um extenso cluster Baixo-Baixo (cor azul escuro), evidenciando áreas de baixo alcance das metas climáticas, especialmente em estados como Amazonas, Acre e Roraima. Esse padrão é fortemente influenciado pela alta concentração de focos de queimadas e pela baixa implementação de estratégias para gestão de riscos e prevenção a desastres ambientais, conforme evidenciado pelas variáveis que compõem o indicador, reforçando a vulnerabilidade climática da região. Esse padrão reflete o contraste entre áreas que enfrentam baixa

implementação de políticas ambientais e regiões que, embora possuam cobertura florestal densa, carecem de ações integradas para mitigação climática.

Os clusters Alto-Baixo (125 municípios) e Baixo-Alto (127 municípios) são menos expressivos no contexto do ODS 6, mas evidenciam áreas de contraste territorial, onde o desempenho nos indicadores de saneamento e água potável diverge significativamente em relação às áreas vizinhas. Para o ODS 13, os clusters Alto-Baixo (67 municípios) e Baixo-Alto (71 municípios) também destacam áreas com discrepâncias locais, sinalizando potenciais regiões para intervenções políticas estratégicas. O Nordeste se destaca positivamente no alcance do ODS 13, diferentemente do ODS 6. Esse comportamento pode ser interpretado como um reflexo da resiliência climática necessária para a convivência com o semiárido, onde ações voltadas para adaptação às secas e à escassez hídrica se consolidaram ao longo das décadas, gerando um padrão de mitigação mais consolidado na região.

Figura 5 - Indicadores Locais de Associação Espacial (LISA) da análise do alcance do ODS 13 no Brasil. O número de municípios que compõem cada cluster é evidenciado entre parênteses.

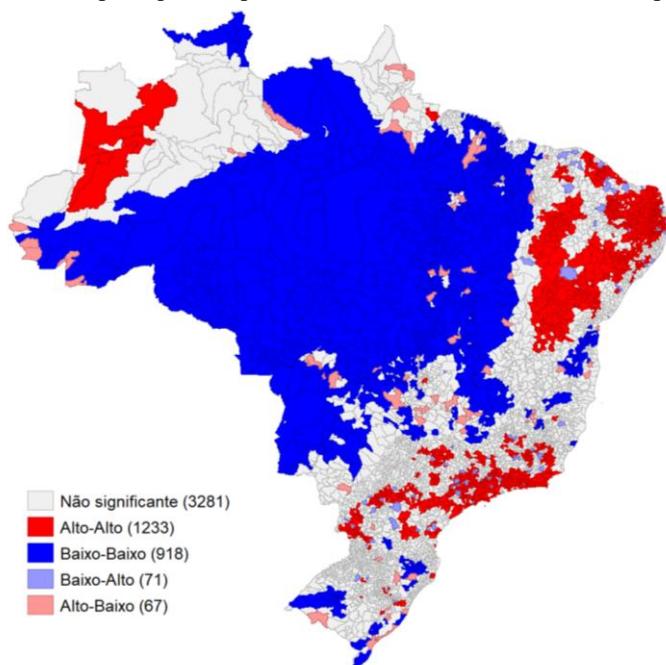
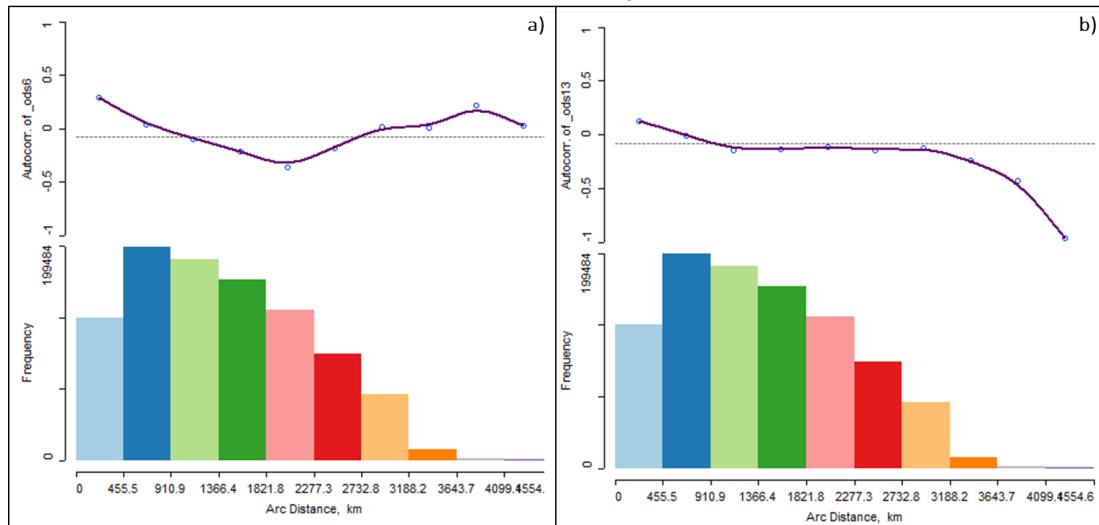


Figura 6 - Correlogramas espaciais para os indicadores de alcance do ODS 6 (a) e ODS 13 (b) nos municípios brasileiros em 2024.



A Figura 6 apresenta os correogramas apresentam a variação da autocorrelação espacial em diferentes intervalos de distância (km), destacando a intensidade e o padrão de associação espacial para os indicadores de alcance das metas do ODS 6 (a) e ODS 13 (b). Observa-se que, em distâncias mais curtas (até 910 km), a autocorrelação espacial positiva é mais acentuada para ambos os ODS, em conformidade com a Primeira Lei de Tobler (1970), a qual afirma que todas as coisas estão relacionadas entre si, mas as coisas mais próximas no espaço têm uma relação mais forte do que as coisas distantes.

CONSIDERAÇÕES FINAIS

A análise espacial dos desempenhos municipais nos ODS 6 e 13 revelou padrões territoriais marcantes no Brasil, evidenciando a persistência de desigualdades regionais. Os clusters Alto-Alto no ODS 6 concentraram-se no Sudeste, onde a infraestrutura consolidada de saneamento impulsiona os indicadores hídricos. Em contrapartida, o Norte e o Nordeste apresentaram concentrações significativas de clusters Baixo-Baixo, refletindo déficits estruturais em saneamento e acesso à água potável, perpetuando um cenário de vulnerabilidade hídrica.

No contexto do ODS 13, o padrão espacial se mostrou mais complexo. Embora o Sudeste e o Nordeste tenham se destacado positivamente, a Amazônia emergiu como um extenso cluster Baixo-Baixo, impactado pela alta concentração de focos de queimadas e pela ausência de estratégias robustas de prevenção a desastres ambientais. Esse contraste revela a dicotomia entre áreas de alta cobertura florestal, mas com baixa capacidade institucional para ações climáticas, e regiões urbanizadas onde a transição para baixo carbono está mais consolidada.

A resiliência climática do Nordeste no ODS 13, diferentemente do ODS 6, destaca-se como um aspecto singular. A convivência histórica com o semiárido impulsionou a adoção de estratégias de mitigação e adaptação, resultando em um padrão de alcance relativamente superior às expectativas.

Em síntese, os resultados reiteram a necessidade de políticas públicas integradas, capazes de mitigar as vulnerabilidades estruturais em saneamento e fortalecer as estratégias de adaptação climática em áreas críticas. Além disso, a articulação regional deve ser priorizada, especialmente em contextos onde as disparidades no alcance dos ODS evidenciam riscos socioambientais e econômicos, contribuindo para a formulação de políticas mais inclusivas e eficazes, em alinhamento com os compromissos da Agenda 2030 e da COP 30.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, E. S. (2012). *Econometria Espacial Aplicada*. Editora Alínea, n. 1988.

ALPHONSO, S. R.; ANDREWS, M. R.; REGAN, S. D.; SHISHKOV, A.; CANTOR, J. H.; POWELL-WILEY, T. M.; TAMURA, K. (2024). “Geospatially clustered low COVID-19 vaccine rates among adolescents in socially vulnerable US counties”. *Preventive Medicine Reports*, 37, 1 jan. 2024.

BRASIL. Ministério das Cidades. (2023). *Sistema Nacional de Informações sobre Saneamento – SNIS: série histórica 2022*. Brasília: Ministério das Cidades. Disponível em: <https://app4.cidades.gov.br/serieHistorica/>. Acesso em: 9 jun. 2025.

CHEN, H.; TUO, Y.; XU, C. Y.; DISSE, M. (2023). “Compound events of wet and dry extremes: Identification, variations, and risky patterns”. *Science of the Total Environment*, 905, 20 dez. 2023.

CHEONG, Y. L.; GHAZALI, S. M.; IBRAHIM, M. K. C.; KEE, C. C.; IDERUS, N. H. M.; RUSLAN, Q. B.; GILL, B. S.; LEE, F. C. H.; LIM, K. H. (2022). "Assessing the spatiotemporal spread pattern of the COVID-19 pandemic in Malaysia". *Frontiers in Public Health*, 10.

GIOVANINI, A.; PEREIRA, W. M.; ALMEIDA, H. J. F. (2022). "Productive diversity and economic growth: some evidence for Brazilian municipalities". *Nova Economia*, 32(3).

HAN, Y.; JIA, H.; XU, C.; BOCKARJOVA, M.; VAN WESTEN, C.; LOMBARDO, L. (2024). "Unveiling spatial inequalities: Exploring county-level disaster damages and social vulnerability on public disaster assistance in contiguous US". *Journal of Environmental Management*, 351, 1 fev. 2024.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. (2023). *Malha Municipal 2023*. Disponível em: <https://www.ibge.gov.br>. Acesso em: abr. 2025.

INSTITUTO CIDADES SUSTENTÁVEIS. (2024). *IDSC-BR – Índice de Desenvolvimento Sustentável das Cidades – Brasil*. Disponível em: <https://idsc.cidadessustentaveis.org.br>. Acesso em: abr. 2025.

LOPES, T. M. X. de M.; SILVA, S. M. O. da; SAMPAIO, L. de S.; SOARES, R. B. (2024). "Water and socioeconomic inequalities: spatial analysis of water consumption in Brazil". *Urban Water Journal*, 21(10), pp. 1056–1070. Disponível em: <https://doi.org/10.1080/1573062X.2024.2397791>. Acesso em: 9 mai. 2025.

MARCONATO, M.; PAULA, A. R.; CARVALHO, A. X. Y.; FERNANDES, L. A. M. (2013). "Taxa de pobreza e população rural no Brasil: análise espacial dos períodos 2000 e 2010". *Economia e Desenvolvimento*, 27(1), pp. 183–201.

MATHUR, M. (s.d.). "Spatial autocorrelation analysis in plant population: An overview". *Journal of Applied and Natural Science*. Disponível em: <www.ansfoundation.org>.

MEDINA-RIVAS, C. M.; RODRÍGUEZ-TAPIA, L.; MORALES-NOVELO, J. A.; REVOLLO-FERNÁNDEZ, D. A. (2022). "Spatial inequality of domestic water consumption in Mexico city". *Water Resources and Economics*, 40.

SDSN – Sustainable Development Solutions Network; BERTELSMANN STIFTUNG. (2023). *Sustainable Development Report 2023: dashboards*. New York: SDSN. Disponível em: <https://dashboards.sdgindex.org/>. Acesso em: 9 mai. 2025.

UNESCO-UIS. (2020). *SDG 4 Data Digest 2020: The Quality Factor – Strengthening National Data to Monitor Sustainable Development Goal 4*. UNESCO Institute for Statistics. Disponível em: <https://uis.unesco.org>. Acesso em: abr. 2025.

XIANG, Y.; YUAN, C.; CEN, Q.; HUANG, C.; WU, C.; TENG, M.; ZHOU, Z. (2024). "Heat risk assessment and response to green infrastructure based on local climate zones". *Building and Environment*, 248, 15 jan. 2024.