

INUNDAÇÕES NA BACIA HIDROGRÁFICA DO RIO TAMANDUATEÍ: Uma análise espacial e multifatorial.

MIRA, Í. R. C. de ¹; MONTEIRO, A. M. V. ²; RENNÓ, C. D³

Resumo

O entendimento das ocorrências de inundações e dos fatores condicionantes é essencial para promover a sustentabilidade de bacias hidrográficas urbanas. Apesar de sua relevância, poucos estudos analisam a variabilidade espacial dos fatores que influenciam esses eventos. Este estudo teve como área de análise a Bacia Hidrográfica do Rio Tamanduateí – SP e utilizou dados de múltiplas fontes para investigar as relações espaciais entre as variáveis ambientais e as inundações. Foram aplicados modelos de autocorrelação espacial, geodetector e regressão ponderada geográfica em múltiplas escalas, com o objetivo de explorar as relações não estacionárias entre os fatores condicionantes e as inundações. Os resultados indicaram forte dependência espacial nas ocorrências de inundações, sendo que as variáveis analisadas demonstraram efeitos simultâneos e significativos. Observou-se que as áreas mais planas da bacia apresentam maior suscetibilidade a esses eventos, conforme evidenciado pela concentração dos focos de inundações. Este trabalho oferece uma abordagem integrada para compreender as características e a heterogeneidade espacial das inundações urbanas, fornecendo subsídios para a mitigação desses eventos e uma metodologia replicável em outras áreas de estudo.

Palavras-chave: Regressão espacial; Fatores condicionantes; Bacias hidrográfica urbanas; Geodetector; MGWR.

Abstract

Understanding the occurrence of floods and the conditioning factors is essential for promoting the resilience and sustainability of urban watersheds. Despite their relevance, few studies analyze the spatial variability of the factors that influence these events. This study analyzed the Tamanduateí River Basin in São Paulo and used data from multiple sources to investigate the spatial relationships between environmental variables and flood density. Spatial autocorrelation, geodetector and geographically weighted regression models were applied at multiple scales in order to explore the non-stationary relationships between conditioning factors and flooding. The results indicated strong spatial dependence in the occurrence of floods, with the variables analyzed showing simultaneous and significant effects. It was observed that the flatter areas of the basin are more susceptible to these events, as evidenced by the concentration of flood hotspots. This work offers an integrated approach to understanding the characteristics and spatial heterogeneity of urban flooding, providing subsidies for mitigating these events and a methodology that can be replicated in other study areas.

Keywords: Spatial regression; Conditioning factors; Urban watersheds; Geodetector; MGWR.

1. INTRODUÇÃO

O processo de urbanização desordenada transforma o meio natural, aumentando a suscetibilidade a eventos extremos (Abreu et al., 2022). Em particular, a intensificação de eventos climáticos-meteorológicos extremos, como precipitações intensas em curto intervalo de tempo, amplifica essa suscetibilidade até tornar-se desastre (Rahmati et al., 2019). Dentre os diversos desastres, no Brasil e no mundo, as inundações são as mais prevalentes e impactantes (Suzen; Lacruz, 2015; Abreu et al., 2022).

Em cenários urbanos, sua ocorrência é intensificada por condições naturais e físicas das bacias hidrográficas, agravadas por ações antrópicas, especialmente em regiões de várzea (Caldana et al., 2018; Abreu et al., 2022). Essas áreas, muitas vezes caracterizadas por alta densidade populacional e infraestrutura urbana, apresentam vulnerabilidade elevada, resultando em perdas significativas (Chen et al., 2019; Zhao et al., 2020). Entre 2001 e 2018, inundações causaram 66.078 mortes em todo o mundo, afetando 1,4 bilhão de pessoas e gerando prejuízos de 309,4 bilhões USD (UN-WATER, 2020).

A redução dos impactos associados as inundações exigem a compreensão de fatores condicionantes físicos, históricos, geográficos, políticos e socioeconômicos (Filgueira et al., 2019). Esses fatores, também conhecidos como parâmetros geoambientais, são fundamentais para identificar causas e mapear áreas mais suscetíveis (Arabameri et al., 2022). Embora o controle total desses eventos seja inviável, a elaboração de mapas baseados em inventários de inundações e análises estatísticas multivariadas é uma ferramenta eficiente para gestão e mitigação de riscos (Kalantari et al., 2019).

Contudo, mapear áreas sujeitas a eventos é um processo desafiador, pois envolve a análise de múltiplos condicionantes, frequentemente complexos e dispendiosos de obter (Chicombo et al., 2024). Nesse contexto, o Sensoriamento Remoto e os Sistemas de Informação Geográfica (SIG) se destacam como alternativas ágeis e econômicas para extrair informações hidrológicas e realizar análises espaciais (Maarez et al. 2022). Essas tecnologias permitem identificar a relevância de cada elemento envolvido, contribuindo para um planejamento espacial mais eficiente (Nachappaa et al., 2020).

Apesar dos avanços nos estudos de inundações, as interações entre fatores condicionantes e a ocorrência de inundações permanecem complexas, frequentemente redundantes e pouco explicativas (Lei et al., 2021; Arabameri et al., 2022). Por essa razão, métodos avançados de análise estatística e espacial são necessários para investigar essas relações e aprimorar a precisão das previsões, bem como a eficácia das ações mitigadoras.

Neste estudo, busca-se avaliar como determinados condicionantes influenciam a ocorrência de inundações na Bacia Hidrográfica do Rio Tamanduateí (SP), utilizando pontos de registro de eventos para fundamentar as análises. A escolha dessa área de estudo justifica-se por sua localização em uma das regiões com maior número de registros de inundações no Brasil, segundo o Atlas Brasileiro de Desastres Naturais (Filgueira et al. 2013). Além disso, a bacia por ser berço do processo de urbanização paulista, apresenta uma diversidade de alterações antrópicas históricas (Gouveia; Rodrigues, 2017). A relevância histórica e atual da área, marcada pela desfiguração de sua paisagem natural, reforça sua importância como objeto de estudo (Ramalho, 2007).

2. ÁREA DE ESTUDO E BASE DE DADOS

2.1 Área de estudo

A bacia hidrográfica do Rio Tamanduateí, localizada na Região Metropolitana de São Paulo, cobre uma área de 323 km². O rio nasce no município de Mauá e deságua no Rio Tietê, confrontando a Bacia do Rio Pinheiros a oeste e sul, e as bacias dos rios Guiaó, Aricanduva e do Córrego Tatuapé a leste e nordeste (Gouveia, 2010). Sua abrangência territorial inclui parte dos municípios de São Paulo, São Bernardo do Campo, Diadema, Santo André, Mauá, São Caetano do Sul (Santos et al., 2019), conforme apresentado na Figura 1.




Figura 1. Área de estudo.

A região caracteriza-se por um relevo diversificado, composto por morros de topos convexos (baixos, médios e alongados), colinas, patamares planos-convexos e planícies fluviais com terraços e áreas de inundação. O terreno apresenta dissecação de média a alta, com vales entalhados e drenagem dendrítica que se alinha parcialmente às estruturas geológicas regionais. A litologia é composta por migmatitos, granitos, micaxistos, metarinitos, anfíbolitos e sedimentos inconsolidados (arenosos e argilosos). Quanto aos solos, predominam argissolo vermelho-amarelo, cambissolo e gleissolo, enquanto as planícies fluviais, embora restritas e descontínuas, possuem relevos planos associados a processos fluviais e coluvionares (Rodrigues, 2017).

O clima é tropical úmido de altitude, com chuvas concentradas entre outubro e março, marcadas por eventos extremos de precipitação e períodos de seca. Segundo Tarifa e Armani (2001), a região está inserida na Unidade Climática IA1, com precipitações anuais entre 1250 e 1450 mm. A interação entre os sistemas meteorológicos, como os frontais e a Zona de Convergência do Atlântico Sul, e o relevo contribui para intensificar a pluviosidade nas áreas mais elevadas em comparação às regiões planas, aumentando a variabilidade climática local (Rodrigues, 2017).

Historicamente, o Rio Tamanduateí apresentava meandros sinuosos e baixa declividade, favorecendo o escoamento das águas pluviais e a formação de áreas sazonalmente alagadas (Gaiarsa, 1991). Entretanto, a rápida urbanização desde a década de 1970, associada ao desenvolvimento do maior polo industrial e comercial de São Paulo, transformou profundamente as características naturais da bacia. Intervenções

como a canalização e retificação dos cursos d’água, impermeabilização das várzeas e supressão de áreas verdes reduziram drasticamente a capacidade de infiltração da água, culminando em um aumento significativo da frequência de enchentes e inundações nos últimos anos (Neves, 2016; Valverde, 2017).

2.2 Base de Dados e Pré-processamento

A coleta de dados de múltiplas fontes é indispensável para compreender e avaliar com maior precisão os riscos de inundações (Liu, et al. 2021). Neste estudo, foram empregados modelos digitais de elevação, redes hidrográficas, registros de pontos de inundação, entre outros dados, conforme apresentado na Tabela 1.

Tabela 1 – Metadados utilizados.

Dados	Tipo de dado	Ano do dado	Fonte
Ocorrência de inundações	Vetor e Arquivo CSV	2019	Centro de Gerenciamento de Emergências da cidade de São Paulo (CGE)
Contorno da Bacia do Rio Tamanduateí - SP	Vetor	2024	GEOSAMPA
Rede de Drenagem	Vetor	2024	GEOSAMPA
Divisões administrativas	Vetor	2022	Instituto Brasileiro de Geografia e Estatística (IBGE)
Modelo Digital de Elevação (MDE)	Raster	2020	EARTHDATA

Fonte: Elaborado pelos autores (2024).

2.2.1 Inventário da ocorrência de inundações

Os registros de ocorrências de inundações são fundamentais para o desenvolvimento de estratégias eficazes de gerenciamento e mitigação (Wang et al., 2017). Nesse contexto, utilizou-se a base de dados do Centro de Gerenciamento de Emergências da cidade de São Paulo (CGE, 2019), que continha 1.165 registros de pontos de inundação ocorridos entre janeiro e dezembro de 2019. Destaca-se que a escolha dessa base se deu pela qualidade e precisão das informações, que incluíam horário e endereço exato de cada ocorrência, devidamente validadas em campo (Figura 2).




Figura 2. Inventário de inundações.

2.2.2 Identificação e extração de fatores condicionantes

Diversos fatores geomorfométricos e topo-hidrológicos condicionantes influenciam a geomorfometria da paisagem, desempenhando um papel fundamental na confiabilidade e precisão dos mapas de ocorrência de inundações (Rahmati et al., 2019; Bui et al., 2020; Arabameri et al., 2022). Neste estudo, com base na literatura e em pesquisas recentes, foram selecionados os seguintes fatores: Índice de Posição Topográfica (TPI), Índice de Rugosidade do Terreno (TRI), Índice de Transporte de Sedimentos (STI), Índice de Potência de Fluxo (SPI), Índice Topográfico de Umidade (TWI), Densidade de Drenagem (DD), Height Above the Nearest Drainage (HAND), Declividade (Slope), Hillshade (HILLSHADE), Distância ao Rio (DR) e Área Acumulada Expandida (AEXPAND), conforme detalhado na Tabela 2.

Tabela 2 - Fatores condicionantes.

Fatores	Descrição	Equação	Legenda
TPI	Representa a diferença entre o valor de uma célula do MDE e a média dos valores das células vizinhas (Rahmati et al., 2019). Esse parâmetro é amplamente aplicado em estudos de inundações para identificar áreas de escoamento, estimar a velocidade	$Z_0 - \sum_{i=1}^n \frac{Z_i}{n}$	Z_0 = Elevação da célula central. Z_i = Elevação dentro da janela local.

	do fluxo e avaliar o potencial de transporte de sedimentos (Rahmati et al., 2019).		n = Número total de pontos circundantes.
TRI	Diferença entre a elevação do pixel do MDE e das células vizinhas (Rahmati et al., 2019). Esse parâmetro influencia diretamente a energia do fluxo, a capacidade de armazenamento da superfície e a velocidade do escoamento (Rahmati et al., 2019).	$\sqrt{\sum (z_{ij} - x_{00})^2}$	z_{ij} = Elevação de cada célula vizinha. x_{00} = Célula central.
STI	Representa o potencial de transporte de sedimentos na rede fluvial de uma bacia hidrográfica (Rahmati et al., 2019). Esse parâmetro quantifica a capacidade do movimento da água em transportar sedimentos ao longo da bacia (Rahmati et al., 2019).	$\left(\frac{\alpha}{22,13}\right)^{0.6} \left(\frac{\sin \beta}{0,0896}\right)^{1.3}$	
SPI	Mede o poder erosivo do escoamento superficial (Rahmati et al., 2019) e identifica áreas com potencial para saturação hídrica (Chowdhury, 2023).	$\alpha * \tan \beta$	α = Área de contribuição da bacia (m²). β = Gradiente de inclinação (Graus).
TWI	Quantifica o controle topográfico em processos hidrológicos (Rahmati et al. 2019) e indica os padrões espaciais de teor de água no solo (Rahmati et al., 2019).	$\ln\left(\frac{\alpha}{\tan \beta}\right)$	
DD	Mede a extensão e a densidade do sistema de drenagem de uma bacia hidrográfica, sendo um parâmetro essencial para análises morfométricas e modelagens hidrológicas (Chowdhury, 2023).	$\frac{L}{A}$	
HAND	Avalia a elevação de um ponto em relação ao canal de drenagem mais próximo, sendo um parâmetro crucial para a identificação de zonas suscetíveis a inundações (Rennó et al., 2008).	***	***
SLOPE	Calcula a inclinação entre dois pontos, sendo um parâmetro fundamental para compreender o fluxo da água e taxas erosivas (Ge et al. 2021).	$\arctan\left(\frac{\Delta_z}{d}\right)$	Δ_z = Diferença de elevação entre dois pontos. d = Distância horizontal entre dois pontos. Z = Zenit (radianos). S = Inclinação do terreno. Az = Direção do solo (radianos). As = Direção da inclinação do terreno (radianos).
HILLSHADE	Técnica de sombreamento utilizada para gerar uma representação visual do relevo, destacando colinas e vales em uma bacia hidrográfica, facilitando a interpretação do terreno (Brooks et al. 2002).	$255 * [(\cos(Z) \cos(S) + \sin(Z) \sin(S) \cos(Az - As))]$	
DR	Mede a distância de um ponto ao canal de drenagem mais próximo, identificando áreas com maior propensão a inundações devido à proximidade com os canais (Chicombo; Moreira, 2024).	$\sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$	x_1, y_1 = Coordenadas do ponto de interesse. x_2, y_2 = Coordenadas do ponto mais próximo no curso do rio.
AEXPAND	Corresponde a área de contribuição da drenagem mais próxima (Banon et al. 2019).	***	***

Fonte: Elaborado pelos autores (2024).

Dado o exposto, após a correção do MDE seguindo a metodologia proposta por Mira et al. (2023), os fatores condicionantes foram extraídos e espacializados utilizando as funções do *plug-in PC Raster Tools* no QGIS, conforme ilustrado nas Figura 3.




Figura 3. Fatores condicionantes.

3. METODOLOGIA

3.1 Densidade de pontos de inundação

A análise de padrões espaciais é essencial para compreender a ocorrência de inundações, permitindo identificar os principais focos de ocorrências e destacar áreas prioritárias para intervenções estratégicas (Wang et al., 2017). Nesse contexto, a utilização da Densidade de Kernel (KDE) possibilitou representar visualmente a distribuição espacial das inundações em torno dos pontos de ocorrência, oferecendo uma visão mais clara da situação.

A KDE é amplamente reconhecida como um dos métodos mais populares para analisar a distribuição de eventos pontuais, devido à sua simplicidade de aplicação e facilidade de interpretação (Liu et al., 2023). Esse método gera superfícies de densidade contínuas que permitem inferir a intensidade dos eventos com base na estimativa de densidade (Liu et al., 2023). Assim, utilizando o QGIS, aplicou-se a equação da KDE ajustando a largura de banda até obter resultados consistentes:

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$

onde $\hat{f}(x)$ é a densidade de kernel estimada no ponto x de interesse, n é o número de pontos de alagamento, h é a largura da banda, K é a função Kernel e $(x - x_i)$ é a distância de um pixel do raster (x) para o ponto de inundação (x_i).

Ressalta-se que a largura de banda foi ajustada iterativamente, pois ela é um dos parâmetros mais críticos na suavização e distribuição da densidade (Liu et al., 2023).

3.2 Autocorrelação e dependência espacial de pontos de inundação

A autocorrelação e dependência espacial dos pontos de inundação e suas características de propagação são fundamentais para compreender a dinâmica desses eventos e dos fatores que influenciam sua ocorrência (Deidda et al. 2021). Para avaliar a autocorrelação espacial e dependência espacial dos pontos, utilizou-se de dois indicadores: a autocorrelação espacial global (GSA) e a autocorrelação espacial local (LISA).

O GSA foi avaliado por meio do Índice de Moran (I), que mede a dependência ou heterogeneidade espacial dos elementos em escala global (Wu et al., 2020). O Índice de Moran pode ser calculado por:

$$I = \left(\frac{n}{\sum_{i=1}^n (X_i - \bar{X})^2} \right) \left(\frac{\sum_{i=1}^n \sum_{j=1}^n (X_i - \bar{X})(X_j - \bar{X})}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \right)$$

onde n é o número de células da grade indexadas por i e j , X_i e X_j são as KDE dos pontos de inundação, $\bar{X}$ é a KDE média dos pontos de inundação e W_{ij} são os pesos espaciais das células da grade. Ressalta-se que a relação adjacente é do tipo Queen, onde as células adjacente são aquelas que compartilham o mesmo vértice ou bordas (Anselin, 1995). O valor do Índice de Moran (I) varia de -1 a 1, conforme descrito na Tabela 3.

Tabela 3 – Índice de Moran (I).

Índice de Moran (I)	Autocorrelação Espacial	Significado
≈ 1	Positiva	Há padrão de agrupamento
≈ 0	Ausente	Não há padrão
≈ -1	Negativa	Há padrão de dispersão

Fonte: Elaborado pelos autores (2024).

Para calcular o Índice de Moran, utilizou-se o ambiente Python e a biblioteca PySAL v.24.7, disponível em: <https://pysal.org/esda/generated/esda.Moran.html>.

Já a análise local foi realizada por meio do Índice de Moran Local (LISA), que avalia o grau de correlação espacial em escala local, enfatizando a similaridade entre cada unidade espacial e sua vizinhança (Wu et al., 2020; Liu et al., 2023):

$$I_i = \frac{(X_i - \bar{X}) \sum_{j=1}^n w_{ij} (X_j - \bar{X})}{\left(\frac{n}{\sum_{i=1}^n (X_i - \bar{X})^2} \right)}$$

O LISA identifica cinco tipos de clusters espaciais, conforme a Tabela 4:

Tabela 4 – LISA cluster.

Cluster	Significado	Corr. Espacial
Alto-Alto (HH)	Alto KDE e alta similaridade na vizinhança	Positiva
Alto-Baixo (LH)	Alto KDE e baixa similaridade na vizinhança	Negativa
Baixo-Baixo (LL)	Baixo KDE e alta similaridade na vizinhança	Positiva
Baixo-Alto (HL)	Baixo KDE e baixa similaridade na vizinhança	Negativa
N. Significativo (ns)	Não há padrões	Ausente

Fonte: Elaborado pelos autores (2024).

A aplicação do LISA também foi realizada no ambiente Python utilizando a biblioteca PySAL v.24.7, disponível em: <https://pysal.org/esda/generated/esda.Moran.html>. Os resultados geraram um mapa de clusters que evidencia áreas com padrões locais significativos de autocorrelação.

3.3 Detecção de fatores

A ocorrência de inundações resulta da interação de múltiplos fatores condicionantes, cuja análise é essencial para fornecer sugestões práticas de prevenção e mitigação. No entanto, a presença de colinearidade entre esses fatores pode dificultar análises tradicionais. Para superar essa limitação, foi utilizado o Geodetector, um método estatístico que não é sensível à colinearidade, permitindo avaliar e explorar a influência dos fatores condicionantes sobre os eventos de inundação (Wang; Xu, 2017).

O Geodetector é amplamente empregado em estudos de sensoriamento remoto e geociências, pois explora a heterogeneidade espacialmente estratificada de fenômenos geográficos e revela a correlação entre variáveis dependentes (Y) e independentes (X) (Yang et al., 2024; Xu et al., 2024). Sua escolha deve-se à simplicidade em termos de hipóteses sobre os dados de entrada e à sua capacidade de gerar resultados estatisticamente significativos. Entre os quatro módulos analíticos do Geodetector, este

estudo optou pelo detector de fatores de risco e pelo detector de interação (Wang; Xu, 2017).

3.3.1 Detector de Fatores de Risco

Este módulo identifica os fatores dominantes que influenciam a ocorrência de inundações. A contribuição explicativa de cada fator é representada pelo valor q calculado conforme a Equação 4:

$$q = 1 - \frac{1}{N\sigma^2} \sum_{h=1}^n N_h \sigma_h^2$$

onde q representa o poder explicativo da variável independente (X), N_h e N são o número de células da grade estratificada em regiões h de toda a área de estudo, σ^2 e σ_h^2 representam a variância dos valores da variável dependente na região h . Ressalta-se que o intervalo de q é $[0,1]$. Quanto maior o valor de q , mais forte o controle de X sobre a distribuição espacial de Y (Yang et al. 2024).

3.3.2 Detector de Interação

Este módulo avalia o poder explicativo e a influência da interação entre dois fatores independentes (X_1 e X_2) na distribuição espacial da variável dependente (Y) (Yang et al. 2024). O efeito da interação é classificado em cinco categorias, conforme apresentado na Tabela 5.

Tabela 5 – Interação de fatores do Geodetector.

Interação	Descrição	Equação
Enfraquecimento não linear	$q(X_1 \cap X_2) < \min[q(X_1), q(X_2)]$	O efeito da interação dos fatores X_1 e X_2 na variável dependente Y é menor que os efeitos independentes.
Enfraquecimento unitário	$\min[q(X_1), q(X_2)] < q(X_1 \cap X_2) < \max[q(X_1), q(X_2)]$	Interação enfraquece o efeito de um dos fatores.
Realce binário	$q(X_1 \cap X_2) > \max[q(X_1), q(X_2)]$	Interação entre os fatores X_1 e X_2 tem impacto maior em Y do que um único valor.
Independente	$q(X_1 \cap X_2) = q(X_1) + q(X_2)$	Interação independente. Os fatores X_1 e X_2 não interferem um no outro.
Realce não linear	$q(X_1 \cap X_2) > q(X_1) + q(X_2)$	Efeito de interação tem impacto maior em Y do que a soma dos efeitos independente de X_1 e X_2 .

Fonte: Elaborado pelos autores (2024).

3.3.3 Implementação

Para aplicar o Geodetector, utilizou-se o RStudio e o pacote Geodetector v.1.0-5, disponível no CRAN. Os fatores condicionantes foram discretizados em cinco intervalos de suscetibilidade à inundação, conforme a Figura 6.

Tabela 6 – Discretização dos fatores para o Geodetector.

Fatores	Intervalo	Classe
TPI	<= -0.875	5
	-0.875 - -0.25	4
	-0.25 - 0.25	3
	0.25 - 0.875	2
	> 0.875	1
TRI	<= 4.4751	5
	4.4751 - 6.3245	4
	6.3245 - 8.4261	3
	8.4261 - 11.6189	2
	> 11.6189	1
STI	<= 0.5110	5
	0.5110 - 0.9373	4
	0.9373 - 1.4839	3
	1.4839 - 2.4923	2
	> 2.4923	1
SPI	<= -3.5174	5
	-3.5174 - -2.7350	4
	-2.7350 - -1.9554	3
	-1.9554 - -0.9933	2
	> -0.9933	1
TWI	<= 7.2204	1
	7.2204 - 7.8239	2
	7.8239 - 8.4237	3
	8.4237 - 9.5457	4
	> 9.5457	5
DD	<= 0.0010	1
	0.0010 - 0.0013	2
	0.0013 - 0.0016	3
	0.0016 - 0.0019	4
	> 0.0019	5
HAND	<= 2.9999	5
	2.9999 - 8.9999	4
	8.9999 - 18.0001	3
	18.0001 - 29.0000	2
	> 29.0000	1
SLOPE	<= 2.4669	5
	2.4669 - 4.1148	4
	4.1148 - 5.8092	3
	5.8092 - 8.2707	2
	> 8.2707	1
HILLSHADE	<= 168.9377	5
	168.9377 - 177.5251	4
	177.5251 - 183.5011	3
	183.5011 - 190.7410	2
	> 190.7410	1
DR	<= 7.0711	5
	7.0711 - 14.1421	4
	14.1421 - 21.9545	3
	21.9545 - 31.8277	2
	> 31.8277	1
AEXPAND	<= 2.3979	1
	2.3979 - 2.5922	2
	2.5922 - 2.9455	3
	2.9455 - 3.5436	4
	> 3.5436	5

Fonte: Elaborado pelos autores (2024).

3.4 Análise de Regressão Espacial

A análise da influência, variação e evolução espaço-temporal de fatores associados à ocorrência de eventos é amplamente aplicada em pesquisas geográficas (Luo et al., 2024). Nesse contexto, o Modelo de Regressão Geograficamente Ponderada (GWR) destaca-se como um método eficaz para lidar com a variação espacial de fatores dependentes e independentes, capturando sua heterogeneidade e não estacionariedade geográfica (Luo et al., 2024):

$$Y_i = \beta_0(u_i v_i) + \sum_{k=1}^p \beta_k(u_i v_i) X_{ik} + \varepsilon_i$$

onde Y_i representa a variável dependente para a unidade espacial (i), enquanto $\beta_0(u_i v_i)$ é o intercepto localizado nas coordenadas espaciais ($u_i v_i$). Os coeficientes $\beta_k(u_i v_i)$ correspondem as variáveis independentes, k define a largura de banda associada ao coeficiente de regressão da variável independente (X_{ik}), e ε_i é o erro. Entre esses elementos, a largura de banda (k) é o parâmetro crucial, pois determina a extensão espacial da influência de cada variável explicativa (Wang et al., 2024).

No entanto, o modelo GWR utiliza a mesma largura de banda para todas as variáveis, o que pode simplificar as relações espaciais e resultar em estimativas imprecisas (Luo et al., 2024). Para superar essa limitação, foi desenvolvido o Modelo de Regressão Geograficamente Ponderada Multiescala (MGWR). Esse modelo permite que diferentes variáveis tenham diferentes larguras de banda para melhor lidar com a heterogeneidade e não estacionariedade dos dados espaciais (Wang et al., 2024):

$$Y_i = \beta_0(u_i v_i) + \sum_{k=1}^p \beta_k(u_i v_i, s_k) X_{ik} + \varepsilon_i$$

onde s_k representa a escala de variação dos coeficientes.

No ambiente Python, os modelos GWR e MGWR foram implementados utilizando o script desenvolvido por Oshan et al. (2019). Destaca-se que ambos os modelos foram aplicados exclusivamente às variáveis mais significativas, identificadas pelos maiores valores de q no Geodetector. A avaliação dos modelos foi realizada com base no coeficiente de determinação (R^2) e no Critério de Informação de Akaike Corrigido (AICc), sendo que um R^2 elevado e um AICc reduzido indicam um melhor ajuste do modelo em relação aos dados (Wang et al., 2024). Com base nesses resultados, a espacialização foi realizada apenas para o modelo que apresentou o desempenho superior.

4. RESULTADOS

4.1 Autocorrelação espacial das ocorrências de inundação

A Figura 4 (a) apresenta a distribuição da densidade de kernel das inundações, evidenciando uma clara estrutura de agregação espacial nas ocorrências. Esse padrão é corroborado pelo Índice de Moran Global, que apresentou um valor de 0,8710, com significância estatística ($p\text{-value} < 0,005$). Isso indica uma correlação espacial positiva significativa na distribuição das inundações, como representado na Figura 4 (b). Assim sendo, observa-se que as inundações não estão distribuídas aleatoriamente no espaço, mas organizam-se de forma geograficamente coerente, formando *clusters* espaciais.

A análise do Índice de Moran Local (LISA), ilustrada na Figura 4 (c), complementa essa avaliação, destacando a presença de aglomerados espaciais do tipo Alto-Alto (HH), onde áreas com alta densidade de inundações estão rodeadas por outras áreas de densidade similar. Esses aglomerados concentram-se principalmente nas regiões mais planas da bacia e próximas ao enxutório, zona de acumulação das águas provenientes da bacia. Essas áreas, caracterizadas por intensa urbanização e frequentes alterações históricas em seus corpos hídricos (Gaiarsa, 1991), localizam-se próximas ao Rio Tietê, conhecido por ser o curso d'água com maior número de transbordamentos no estado de São Paulo (Peixoto, 2017).

Em contrapartida, o LISA também identificou aglomerados do tipo Baixo-Baixo (LL), representando áreas de baixa densidade de inundações, mas com alta similaridade espacial. Essas regiões estão situadas nas partes mais elevadas da bacia, que possuem menor densidade populacional urbana e menor intervenção em seus corpos hídricos.




Figura 4. Distribuição espacial das ocorrências de inundação: (a) Distribuição da Densidade de Kernel; (b) Índice de Moran Local; (c) Índice de Moran Global.

Os resultados estatisticamente significativos fornecem uma base sólida para compreender os padrões espaço-temporais das inundações, abrindo caminho para a aplicação de modelos avançados, como a GWR e MGWR.

4.2 Fatores dominantes na ocorrência de inundações

A identificação dos fatores condicionantes mais significativos destacou o poder explicativo dos indicadores na distribuição espacial e ocorrência de inundações. Conforme apresentado na Figura 5, dos 11 fatores analisados, cinco se destacaram por seus elevados valores de q e significância estatística ($p\text{-value} < 0,005$): AEXPAND, DR, DD, HAND e SPI.




Figura 5. Resultados Geodetector.

Áreas com valores mais altos de AEXPAND apresentaram maior concentração de fluxo hídrico, o que aumenta a vulnerabilidade a inundações, como observado por Banon et al. (2019). No caso do fator DR, a proximidade aos canais de drenagem mostrou-se determinante, pois essas áreas estão mais sujeitas ao impacto direto do escoamento hídrico principal (Wang et al., 2023). De forma semelhante, regiões com maior densidade de drenagem (DD) foram associadas a maior risco de inundação, devido ao maior volume de água acumulado a partir da área de contribuição da bacia (Ahad et al., 2022). Valores reduzidos de HAND indicaram áreas próximas ao nível da água nos canais de drenagem, caracterizadas por maior suscetibilidade, conforme Momo et al. (2016). Por fim, valores baixos de SPI revelaram regiões mais vulneráveis, em função da menor capacidade do terreno em dissipar a energia hidráulica (Mira; Silva, 2023).

Além disso, a análise conjunta dos fatores, ilustrada na Figura 6, demonstrou que sua interação possui um impacto ainda mais expressivo sobre os eventos de inundação do que suas influências individuais. As interações do tipo realce binário indicam que as interações entre os indicadores amplificam seus efeitos sobre a suscetibilidade às inundações, como sugerido por Olbert et al. (2023).




Figura 6. Matriz de interação de fatores.

Tais resultados evidenciam a relevância de abordar múltiplos fatores de maneira integrada, permitindo uma compreensão mais profunda e precisa dos padrões espaciais associados a esses eventos.

4.3 Comparação de Modelos

Ao comparar os dois modelos de análise espacial apresentados na Tabela 7, observa-se que o modelo MGWR apresentou desempenho superior em diversos critérios estatísticos. Este modelo exibiu um valor de log-verossimilhança mais alto, uma qualidade de ajuste superior (R^2) e um menor valor de AICc, destacando-se como o modelo com melhor ajuste. Além disso, a soma residual dos quadrados (RSS) do MGWR foi menor, indicando que o modelo utilizou menos parâmetros para alcançar resultados de regressão mais realistas.

Tabela 7 – Indicadores de modelo GWR e MGWR.

Modelo	Log-Likelihood	AICc	R ²	RSS
GWR	-195,405	811,395	0,872	63,966
MGWR	40,535	348,208	0,950	24,893

Fonte: Elaborado pelos autores (2024).

Esses resultados evidenciam a maior capacidade do modelo MGWR em capturar e explicar, com maior precisão, a variabilidade e a correlação espacial entre os fatores condicionantes analisados. Dessa forma, o MGWR foi selecionado como a abordagem mais adequada para aplicação nas análises subsequentes, garantindo maior robustez e fidelidade na interpretação dos padrões espaciais.

4.4 Análise da variação espacial dos coeficientes

A Tabela 8 sintetiza a especificidade de cada variável sobre a ocorrência de inundações, evidenciando como os fatores condicionantes variam espacialmente em sua influência. As diferenças nas larguras de banda dos fatores refletem a ampla variabilidade espacial e as características intrínsecas de cada um. HAND e AEXPAND apresentaram as menores larguras de banda, indicando que possuem uma influência predominantemente local. Isso pode ser explicado pela concentração desses fatores em áreas urbanizadas e planas da bacia, onde a suscetibilidade a inundações é maior devido ao acúmulo de água e à proximidade ao nível dos canais de drenagem. Por outro lado, SPI, DD e DR exibiram larguras de banda maiores, sugerindo impactos mais distribuídos e generalizados ao longo de toda a bacia.


O desvio padrão dos coeficientes reflete a heterogeneidade espacial na influência de cada variável sobre as inundações. O HAND, por exemplo, apresenta um desvio padrão elevado, o que sugere uma forte variabilidade em sua influência espacial, reforçando sua relevância em áreas específicas (Wu et al., 2024). Já a média dos coeficientes representa o grau de influência global de cada fator. HAND e AEXPAND destacaram-se como os mais influentes, o que pode ser atribuído à densa rede de drenagem e ao acúmulo de água em áreas planas da bacia, regiões que concentram os principais pontos de inundação.

Tabela 8 – Descrição estatística do MGWR.

Variáveis	Largura de Banda	Média	Desvio Padrão (Resíduos)	Mínimo	Mediana	Máximo
Intercepto	12	0,057	1,003	-0,426	-0,408	4,720
SPI	489	0,012	0,008	0,003	0,009	0,025
DD	498	0,002	0,003	-0,04	0,003	0,006
HAND	74	0,055	0,137	-0,081	0,011	0,611
DR	498	-0,008	0,002	-0,012	-0,008	-0,005
AEXPAND	76	0,039	0,079	-0,040	0,000	0,291

Fonte: Elaborado pelos autores (2024).

Os coeficientes, positivos ou negativos, apresentados na Tabela 8 e ilustrados na Figura 7, indicam a direção e a intensidade da influência de cada variável sobre as inundações (Wu et al., 2024).






Figura 7. Variação espacial dos coeficientes do MGWR.

O coeficiente de intercepto, variando de -0,426 a 4,750, demonstra uma ampla variação na densidade de inundações entre áreas altas e baixas da bacia. Áreas mais baixas, com coeficientes positivos, são marcadas por maior concentração de inundações devido ao relevo plano e à proximidade dos canais, enquanto as áreas mais altas, com coeficientes negativos, apresentam menor suscetibilidade.

O SPI exibiu coeficientes variando de 0,003 a 0,025, com valores positivos associados a regiões mais planas, caracterizadas por maior saturação hídrica e maior densidade de inundações. A densidade de drenagem (DD), por sua vez, variou de -0,004 a 0,006. Coeficientes positivos foram observados em áreas mais baixas da bacia, onde a densidade de canais menores é maior e mais suscetível a sobrecarga em eventos extremos. Já os coeficientes negativos se concentraram em áreas mais altas, com menor densidade de drenagem.

O HAND apresentou coeficientes variando de -0,081 a 0,611. Coeficientes positivos foram registrados em áreas mais planas, onde a susceptibilidade à inundação é mais intensa devido ao maior acúmulo de água, alterações no regime de escoamento e proximidade ao nível dos canais.

Para o DR, os coeficientes variaram de -0,012 a -0,005, sendo todos negativos. Isso indica que, quanto menor a distância aos canais de drenagem, maior a probabilidade de inundações, refletindo a influência direta dessas áreas no escoamento superficial. Por fim, os coeficientes de AEXPAND variaram de -0,040 a 0,291. Em áreas planas, os coeficientes positivos indicam maior suscetibilidade a inundações devido ao acúmulo de

água, enquanto os coeficientes negativos representam regiões menos sujeitas a esses eventos.

5. DISCUSSÃO

5.1 Relações espaciais não estacionária dos fatores que afetam as inundações

Os mecanismos que conduzem as inundações ao longo da Bacia do Rio Tamanduateí – SP são variados, refletindo uma dinâmica complexa condicionada por múltiplos fatores. A análise revelou que a interação entre esses fatores desempenha um papel crucial na distribuição espacial e densidade das inundações, criando um efeito sinérgico que amplifica a suscetibilidade em áreas planas. Esses achados corroboram o estudo de Tehrany et al. (2015), que destacou a vulnerabilidade dos terrenos planos devido à dificuldade de escoamento, especialmente em condições de alta impermeabilização do solo.

Historicamente, o crescimento urbano acelerado na região não foi acompanhado por uma expansão adequada da infraestrutura de drenagem. Em alguns casos, modificações no sistema de drenagem resultaram em impactos negativos (Valverde, 2017). Assim, as áreas urbanizadas mais próximas da rede de drenagem enfrentam riscos significativos de inundação, conforme apontado por Liu et al. (2021). Adicionalmente, o aumento das superfícies impermeáveis e o relevo predominantemente plano intensificam o transbordamento dos canais, reduzindo a capacidade de infiltração e aumentando a frequência e a severidade dos alagamentos (Oñate-Valdivieso et al. 2022).

Esses resultados reforçam a importância de abordagens integradas no planejamento urbano, que considerem tanto a mitigação dos impactos naturais quanto a melhoria da infraestrutura de drenagem. Políticas públicas baseadas em soluções baseadas na natureza e a gestão adequada do uso do solo são essenciais para reduzir os riscos e os impactos das inundações nessa bacia densamente urbanizada.

5.2 Recomendações

Para mitigar os riscos associados aos alagamentos, é crucial implementar estratégias eficazes voltadas para otimizar o ambiente construído em áreas urbanas de alta densidade. A modelagem realizada por meio do Geodetector evidenciou de forma clara o impacto individual e combinado dos fatores condicionantes sobre as ocorrências de inundações, destacando a complexidade das interações entre eles.

Dada a dinâmica amplificada e não uniforme dessas interações, é essencial que as políticas públicas considerem tais mecanismos no planejamento urbano. A variação espacial significativa na influência dos fatores condicionantes reforça a necessidade de diretrizes integradas que alinhem o desenvolvimento urbano à gestão ambiental (Wang et al., 2024).

Nesse contexto, gestores de bacias hidrográficas e planejadores urbanos devem priorizar ações que promovam um equilíbrio entre densidade urbana e áreas permeáveis. Isso inclui a modernização de sistemas de drenagem, a implantação de soluções baseadas na natureza, como jardins de chuva e telhados verdes, e o controle da expansão de superfícies impermeáveis.

5.3 Limitações e trabalhos futuros

Apesar dos resultados significativos, este estudo apresenta algumas limitações que indicam a necessidade de melhorias futuras. Primeiramente, os dados de alagamento utilizados, baseados em ocorrências pontuais e densidade estimada, podem conter imprecisões, resultando em uma representação menos precisa das áreas suscetíveis a inundações. Além disso, a análise foi restringida pelo número limitado de fatores condicionantes, especialmente no que tange às características topográficas e ao uso do solo. Por fim, os detectores geográficos empregados consideraram apenas interações entre dois fatores, enquanto as inundações frequentemente envolvem dinâmicas mais complexas com múltiplos fatores simultâneos.

Para abordar essas limitações, recomenda-se que futuras pesquisas avancem em diversas frentes. A espacialização das inundações na área de estudo pode revelar padrões mais precisos e aprofundar a compreensão das dinâmicas envolvidas. A inclusão de variáveis que representem características físicas, morfométricas, hidrológicas e de uso do solo contribuirá para uma análise mais abrangente. Ademais, o uso de algoritmos de aprendizado de máquina oferece um caminho promissor para explorar interações multifatoriais, permitindo uma explicação mais detalhada das causas das inundações.

Essas iniciativas têm o potencial de construir bases científicas mais robustas e fornece suporte prático para o planejamento urbano e a gestão de riscos de inundações em diferentes escalas.

5. CONCLUSÃO

Neste artigo, realizamos uma análise abrangente dos mecanismos que influenciam as ocorrências de inundações na Bacia do Rio Tamanduateí – SP. Identificamos que os focos de alagamento estão concentrados, principalmente, em áreas planas e altamente urbanizadas, onde a interação entre múltiplos fatores condicionantes desempenha um papel determinante. Essas interações apresentaram variações espaciais significativas, evidenciando a não estacionariedade espacial na relação entre os fatores analisados e a densidade das inundações. Entre os condicionantes avaliados, HAND e AEXPAND se destacaram como os de maior impacto, pois representam, com precisão, o acúmulo de água nas regiões mais suscetíveis da bacia.

Os resultados deste estudo oferecem uma contribuição relevante para a compreensão das dinâmicas multifatoriais que caracterizam as inundações em bacias urbanas. Eles também destacam a importância de integrar fatores ambientais e antrópicos no planejamento territorial e na gestão de riscos, fornecendo informações estratégicas para a mitigação de eventos de alagamento.

Por fim, a metodologia aplicada e os achados reforçam a necessidade de intervenções integradas e sustentáveis, além de servir como base para futuros estudos e medidas eficazes. Espera-se que essas informações auxiliem no desenvolvimento de políticas públicas e estratégias que aumentem a resiliência das cidades frente aos desafios impostos pelas inundações.

AGRADECIMENTOS

Os autores agradecem ao Departamento de Sensoriamento Remoto do Instituto Nacional de Pesquisas Espaciais (INPE), bem como ao próprio INPE e a CAPES, pelo valioso suporte técnico e financeiro. Expressam, ainda, sua gratidão ao projeto *Intelligent Flood Alert Surveillance Tools* (iFAST) pela parceria e colaboração indispensáveis ao desenvolvimento deste trabalho.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ABREU CLAUDINO, C. M.; ABRANTES, S. L. M.; ALMEIDA, A. A. R. D. et al. Avaliação de diferentes modelos digitais de elevação na geração de mapas de suscetibilidade a inundações a partir do modelo Height Above The Nearest Drainage (HAND): Evaluation of different digital elevation models in the generation of flood

susceptibility maps from the Height Above the Nearest Drainage (HAND) model. **Geociências**, v. 41, n. 1, p. 227-241, 2022.

AHAD, U.; ALI, U.; ALI, S. A. Flood Hazard Assessment using Morphometry in Geospatial Environment. **Research Square**, v. 1, p. 1 – 21, 2022.

ANSELIN, L.; FLORAX, R. J. G. M. Small sample properties of tests for spatial dependence in regression models: Some further results. In: **New directions in spatial econometrics**. Berlin, Heidelberg: Springer Berlin Heidelberg, 1995. p. 21-74, 1995.

ARABAMERI, A.; SEYED DANESH, A.; SANTOSH, M. et al. Flood susceptibility mapping using meta-heuristic algorithms. **Geomatics, Natural Hazards and Risk**, v. 13, n. 1, p. 949-974, 2022.

BANON, G.; ARRAUT, E.; VILLAMARÍN, F.; MARIONI, B.; MOULATLET, G.; RENNÓ, C.; BANON, G.; NOVO, E. A review on crocodilian nesting habitats and their characterisation via remote sensing. **Amphibia-Reptilia**, v. 1, p. 1-21, 2019.

BROOKS, S, K.; LACHENBRUCH, A, H.; WENTWORTH, C. M. **Shaded Relief, Topographic Slope, and Land Use Planning in the Los Altos Hills Area, California, an Example of the Use of Elevation Data**. US Geological Survey, 2002.

BUI, D. T.; HOANG, N. D.; MARTÍNEZ-ÁLVAREZ, F. et al. A novel deep learning neural network approach for predicting flash flood susceptibility: A case study at a high frequency tropical storm area. **Science of The Total Environment**, v. 701, p. 134413, 2020.

CALDANA, N. F. S.; YADA JUNIOR, G. M.; MOURA, D. A. V.; COSTA, A. B. F.; CARAMORI, P. H. Ocorrências de alagamentos, enxurradas e inundações e a variabilidade pluviométrica na Bacia hidrográfica do Rio Iguaçu. **Revista Brasileira de Climatologia**, v. 23, p. 343-355, 2018.

CENTRO DE GERENCIAMENTO DE EMERGÊNCIAS CLIMÁTICAS – CGE. **Registros de inundação em São Paulo em 2019, Brasil**. Acesso em: 02 nov. 2024. Disponível em: <https://www.cgesp.org/v3/>

CHEN, W.; HONG, H.; LI, S. et al. Flood susceptibility modelling using novel hybrid approach of reduced-error pruning trees with bagging and random subspace ensembles. **J Hydrol**. v. 575, p. 864–873, 2019.

CHICOMBO, T. F.; MOREIRA, A. A. M. Mapeamento de suscetibilidade às inundações com base na Análise Multicritério (AHP): Estudo de caso do distrito de Chókwe, em Moçambique. v. 25, n. 99, **Caminhos de Geografia**. p. 301-319. 2024.

CHOWDHURY, M. S. Modelling hydrological factors from DEM using GIS. **MethodsX**, v. 10, p. 102062, 2023.

DEIDDA, C.; RAHIMI, L.; DE MICHELE, C. Causes of dependence between extreme floods. **Environmental Research Letters**, v. 16, n. 8, p. 084002, 2021.

FILGUEIRA, H. J. A.; SILVA, T. C.; ROSENDO, E. E. Q. Estratégias de ação para a redução de risco de desastres por inundação, alagamento e movimento de massa em João Pessoa, Paraíba. In: **Atlas brasileiro de desastres naturais 1991 a 2012: volume Brasil**. Florianópolis: CEPED-UFSC, 127 p., 2013.

FILGUEIRA, H. J. A.; SILVA, T. C.; ROSENDO, E. E. Q. Estratégias de ação para a redução de risco de desastres por inundação, alagamento e movimento de massa em João Pessoa, Paraíba. In: CRUZ, D. D.; MIRANDA, G. E. C.; SOUZA, B. I. de; LUCENA, R. F. P. de. (Orgs.). **Meio ambiente e desenvolvimento: os desafios da sustentabilidade ambiental**. João Pessoa, PB: Editora UFPB, p. 157-169. 2019.

GAIARSA, O. A. **Santo André: ontem, hoje, amanhã**. Santo André: Prefeitura Municipal de Santo André - PMSA, 1991, 362 p.

GE, Y.; GUO, X.; ZHAN, M.; YAN, H. Erosion Rate of Lateral Slope Deposit Under the Effects of Different Influencing Factors. **Frontiers in Earth Science**, v. 9, p. 670087, 2021.

GOUVEIA, I. C. M-C. **Da originalidade do sítio urbano de São Paulo às formas antrópicas**: aplicação da abordagem da Geomorfologia Antropogênica na bacia hidrográfica do rio Tamanduateí, na Região Metropolitana de São Paulo. 2010. 363 f. Tese (Doutorado em Geografia Física) – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, 2010.

GOUVEIA, I. C. M-C.; RODRIGUES, C. Mudanças morfológicas e efeitos hidrodinâmicos do processo de urbanização na bacia hidrográfica do rio Tamanduateí–RMSP. **GEOUSP Espaço e Tempo (Online)**, v. 21, n. 1, p. 257-283, 2017.

- KALANTARI, Z.; FERREIRA, C. S. S.; KOUTSOURIS, A. J. et al. Assessing flood probability for transportation infrastructure based on catchment characteristics, sediment connectivity and remotely sensed soil moisture. **Science of the total environment**, v. 661, p. 393-406, 2019.
- LEI, X.; CHEN, W.; PANAHI, M. et al. Urban flood modeling using deep-learning approaches in Seoul, South Korea. **Journal of Hydrology**, v. 601, p. 126684, 2021.
- LIU, F.; LIU, X.; XU, T.; YANG, G.; ZHAO, Y. Driving Factors and Risk Assessment of Rainstorm Waterlogging in Urban Agglomeration Areas: A Case Study of the Guangdong-Hong Kong-Macao Greater Bay Area, China. **Water**, v. 13, p. 770, 2021.
- LIU, W.; ZHANG, X.; FENG, Q.; YU, T.; ENGEL, B. A. Analyzing the impacts of topographic factors and land cover characteristics on waterlogging events in urban functional zones. **Science of The Total Environment**, v. 904, p. 166669, 2023.
- LUO, F.; ZHANG, Y.; ZHAO, X. Understanding the Spatiotemporal Dynamics and Influencing Factors of the Rice–Crayfish Field in Jiangnan Plain, China. **Remote Sensing**, v. 16, p. 1541, 2024.
- MAAREZ, H. G.; JABER, H. S.; SHAREEF, M. A. Utilization of Geographic Information System for hydrological analyses: A case study of Karbala province, Iraq. **Iraqi Journal of Science**, p. 4118-4130, 2022.
- MANDYCH, A. F. Classification of Floods. In: KOTLYAKOV, W, M (Ed.). **Encyclopedia of Life Support. Natural Disasters**. v. 2. UNESCO: Eolss Pbl. Co., 2010. p. 63-88.
- MIRA, I. R. C.; SILVA, M. L. Mapeamento da suscetibilidade à inundação na Bacia do Alto-Médio Rios Mogi Guaçu e Pardo – MG. **Revista Caderno de Geografia**, v. 33, n. 74, p. 782-810, 2023.
- MOMO, M. R.; PINHEIRO, A.; SEVERO, D. L.; CUARTAS, L. A.; NOBRE, A. D. Desempenho do modelo HAND no mapeamento de áreas suscetíveis à inundação usando dados de alta resolução espacial. **RBRH**, v. 21, p. 200-208, 2016.
- NACHAPPA, T. G.; PIRALILOU, S. T.; GHOLAMNIA, K. et al. Flood susceptibility mapping with machine learning, multi-criteria decision analysis and ensemble using Dempster Shafer Theory. **Journal of hydrology**, v. 590, p. 125275, 2020.

- NEVES, B. F. **Estudo das inundações no município de Santo André e sua relação com as chuvas intensas**. 2016. 99 p. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Ambiental e Urbana) - Universidade Federal do ABC, Santo André, 2016.
- OLBERT, A. I.; MORADIAN, S.; NASH, S.; COMER, J.; KAZMIERCZAK, B.; FALCONER, R. A.; HARTNETT, M. Combined statistical and hydrodynamic modelling of compound flooding in coastal areas-Methodology and application. **Journal of Hydrology**, v. 620, p. 129383, 2023.
- OÑATE-VALDIVIESO, F.; OÑATE-PALADINES, A.; COLLAGUAZO, M. Spatiotemporal dynamics of soil impermeability and its impact on the hydrology of an urban basin. **Land**, v. 11, n. 2, p. 250, 2022.
- OSHAN, T. M.; LI, Z.; KANG, W.; WOLF, L. J.; FOTHERINGHAM, A. S. MGWR: A Python implementation of multiscale geographically weighted regression for investigating process spatial heterogeneity and scale. **ISPRS International Journal of Geo-Information**, v. 8, n. 6, p. 269, 2019.
- PEIXOTO, N. B. O rio, a inundação e a cidade A várzea do Tietê como situação crítica. **Estudos Avançados**, v. 31, p. 157-170, 2017.
- RAHMATI, O.; KALANTARI, Z.; SAMADI, M. et al. GIS-based site selection for check dams in watersheds: considering geomorphometric and topo-hydrological factors. **Sustainability**, v.11, n. 20, p. 563, 2019.
- RAMALHO, D. Rio Tamanduateí-Nascente à Foz: percepções da paisagem e processos participativos. **Paisagem e Ambiente**, n. 24, p. 99-114, 2007.
- RENNÓ, C. D.; NOBRE, A. D.; CUARTAS, L. A.; SOARES, J. V.; HODNETT, M. G.; TOMASELLA, J. HAND, a new terrain descriptor using SRTM-DEM: Mapping terra-firme rainforest environments in Amazonia. **Remote Sensing of Environment**, v. 112, n. 9, p. 3469-3481, 2008.
- RODRIGUES, J. G. F. **Análise dos fatores morfométricos e hidroclimáticos da bacia hidrográfica do Tamanduateí que influenciam na ocorrência de inundações no município de Santo André – SP**. 2017. 131 p. Dissertação (Mestrado em Ciência e Tecnologia Ambiental) – Universidade Federal do ABC (UFABC), Santo André, 2017.

Disponível em: https://bdtd.ibict.br/vufind/Record/UFBC_7f3222182c6a8446457315d2ef50c474. Acesso em: 26 nov. 2024.

SANTOS, D. F. F.; VALVERDE, M. C.; BRAMBILA, R. B.; FERREIRA, M. C. A. Inundações na Bacia do Rio Tamanduateí – Santo André: Estudo de caso dos dias 10 e 11/03/2019. In: Anais: XXIII Simpósio Brasileiro de Recursos Hídricos, 23, Foz de Iguaçu. **Anais...** 2019. Disponível em: <https://files.abrhidro.org.br/Eventos/Trabalhos/142/XXIV-SBRH0060-1-20210518-114127.pdf>. Acesso em: 26 nov. 2024.

SUZEN, T. M.; LACRUZ, M. S. **Sensoriamento Remoto para Desastres**. São Paulo: Oficina Textos, 2015.

TARIFA, J. R.; ARMANI, G. Os climas “naturais”. **Os climas na cidade de São Paulo: teoria e prática**. São Paulo: Pró-Reitoria de Cultura e Extensão. Universidade de São Paulo: Laboratório de Climatologia. Faculdade de Filosofia, Letras e Ciências Humanas. Universidade de São Paulo, 2001a. Cap, v. 2, p. 34-46, 2001.

TEHRANY, M. S.; PRADHAN, B.; MANSOR, S.; AHMAD, N. Flood susceptibility assessment using GIS-based support vector machine model with different kernel types. **Catena**, v. 125, p. 91-101, 2015.

UN-WATER. **United Nations World Water Development Report 2020: Water and Climate Change**, Paris, UNESCO, 2020.

VALVERDE, M. C. A interdependência entre vulnerabilidade climática e socioeconômica na região do abc paulista. **Ambiente & Sociedade**, p. 39-60, 2017.

WANG, C.; DU, S.; WEN, J. et al. Analyzing explanatory factors of urban pluvial floods in Shanghai using geographically weighted regression. **Stochastic Environmental Research and Risk Assessment**, v. 31, p. 1777-1790, 2017.

WANG, J.; XU, C. Geodetector: Principle and prospective. **Acta Geographica Sinica**, , v. 72, n. 1, p. 116-134, 2017.

WANG, N.; SUN, F.; KOUTSOYIANNIS, D. et al. How can changes in the human-flood distance mitigate flood fatalities and displacements? **Geophysical Research Letters**, v. 50, 2023.

WANG, Q.; ZHAO, R.; WANG, N. Spatially non-stationarity relationships between high-density built environment and waterlogging disaster: Insights from Xiamen Island, China. **Ecological Indicators**, v. 162, p. 112021, 2024.

WU, J.; SHA, W.; ZHANG, P.; WANG, Z. The spatial non-stationary effect of urban landscape pattern on urban waterlogging: A case study of Shenzhen City. **Scientific reports**, v. 10, n. 1, p. 7369, 2020.

WU, M.; WEI, X.; GE, W. et al. Analyzing the spatial scale effects of urban elements on urban flooding based on multiscale geographically weighted regression. **Journal of Hydrology**, v. 645, p. 132178, 2024.

XU, T.; LIU, F.; WAN, Z.; ZHANG, C.; ZHAO, Y. Spatio-temporal evolution characteristics and driving mechanisms of waterlogging in urban agglomeration from multi-scale perspective: A case study of the Guangdong-Hong Kong-Macao Greater Bay Area, China. **Journal of Environmental Management**, v. 368, p. 122109, 2024.

YANG, Z.; WANG, H.; CHEN, B. Assessment of urban waterlogging-induced road traffic safety risk and identification of its driving factors: A case study of Beijing. **Transportation research part A: policy and practice**, v. 183, p. 104080, 2024.

ZHAO, G.; PANG, B.; XU, Z.; PENG, D.; ZUO, D. Urban flood susceptibility assessment based on convolutional neural networks. **Journal of Hydrology**, v. 590, p. 125235, 2020.