



Universidade Estadual Paulista
"Júlio de Mesquita Filho"
Programa Interunidades



Doutorado

Engenharia Civil e Ambiental

ADMIR JOSÉ GIACON JUNIOR

**MAPEAMENTO DE ÁREAS SUSCETÍVEIS A INUNDAÇÕES NA
BACIA HIDROGRÁFICA DO RIO SOROCABA E MÉDIO TIETÊ (SP)**

Sorocaba
2022



ADMIR JOSÉ GIACON JUNIOR

**MAPEAMENTO DE ÁREAS SUSCETÍVEIS A INUNDAÇÕES NA
BACIA HIDROGRÁFICA DO RIO SOROCABA E MÉDIO TIETÊ (SP)**

Tese apresentada como parte dos requisitos
para obtenção do título de Doutor em
Engenharia Civil e Ambiental da
Universidade Paulista “Júlio de Mesquita
Filho”. Área de Concentração: Geotecnia.

Orientador: Prof. Dr. Alexandre Marco da Silva.

Bauru
2022



Giacon Junior, Admir José.

Mapeamento de Áreas Suscetíveis a Inundações
na Bacia Hidrográfica do Rio Sorocaba e Médio
Tietê (SP) / Admir José Giacon Junior, 2022

154 f.

Orientador: Alexandre Marco da Silva

Tese (Doutorado)-Universidade Estadual
Paulista (Unesp). Faculdade de Engenharia, Bauru,
2022

1. Mapeamento de Suscetibilidade a Inundações.
2. Previsão de Inundação. 3. Bacia Hidrográfica
do Rio Sorocaba e Médio Tietê. 4. Máquinas de
Vetores Suporte. 5. AHP-TOPSIS-2N. I.
Universidade Estadual Paulista. Faculdade de
Engenharia. II. Título.

ATA DA DEFESA PÚBLICA DA TESE DE DOUTORADO DE ADMIR JOSÉ GIACON JÚNIOR, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E AMBIENTAL, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.

Aos 12 dias do mês de agosto do ano de 2022, às 08:30 horas, por meio de Videoconferência, realizou-se a defesa de TESE DE DOUTORADO de ADMIR JOSÉ GIACON JÚNIOR, intitulada **Mapeamento de Áreas Suscetíveis a Inundações Via Máquinas de Vetores Suporte – Estudo de Caso Aplicado na Bacia Hidrográfica dos Rios Sorocaba e Médio Tietê**. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. ALEXANDRE MARCO DA SILVA (Orientador(a) - Participação Virtual) do(a) Departamento de Engenharia Ambiental / Unesp Instituto de Ciencia e Tecnologia de Sorocaba, Profa. Dra. LUIZA AMALIA PINTO CANTÃO (Participação Virtual) do(a) Departamento de Engenharia Ambiental / Campus Experimental de Sorocaba/UNESP/Sorocaba (SP), Prof. Dr. RENATO FERNANDES CANTÃO (Participação Virtual) do(a) Departamento de Matemática / Universidade Federal de São Carlos, Profa. Dra. NATÁLIA ZANETTI (Participação Virtual) do(a) Departamento Técnico / Fundação Agência da Bacia Hidrográfica do Rio Sorocaba e Médio Tietê - FABH-SMT, Prof. Dr. MAURÍCIO CETRA (Participação Virtual) do(a) Departamento de Ciências Ambientais / Universidade Federal de São Carlos. Após a exposição pelo doutorando e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, o discente recebeu o conceito final: APROVADO . Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(a) da Comissão Examinadora.



Prof. Dr. ALEXANDRE MARCO DA SILVA

PROPOSTA DE ALTERAÇÃO DO TÍTULO


A COMISSÃO EXAMINADORA PROPÕE A ALTERAÇÃO DO TÍTULO DO TRABALHO DO ALUNO: **ADMIR JOSÉ GIACON JÚNIOR**

DE: "MAPEAMENTO DE ÁREAS SUSCETÍVEIS A INUNDAÇÕES VIA MÁQUINAS DE VETORES SUPORTE – ESTUDO DE CASO APLICADO NA BACIA HIDROGRÁFICA DOS RIOS SOROCABA E MÉDIO TIETÊ"

PARA:

MAPEAMENTO DE ÁREAS SUSCETÍVEIS A INUNDAÇÕES NA BACIA HIDROGRÁFICA DO RIO SOROCABA E MÉDIO TIETÊ (SP)

Bauru, 12 de agosto de 2022.



Prof. Dr. Alexandre Marco da Silva
Orientador(a)

Dedico esse trabalho a minha família, a qual me moldou ensinou os valores fundamentais de um ser humano, a honestidade, a educação, a humildade e ser temente a Deus.

AGRADECIMENTOS

Primeiramente e sempre, agradeço a Deus, pois, somente Ele nos possibilita vencer os desafios da vida.

Agradeço aos meus pais Maria Raquel de Camargo Giacon e Admir José Giacon (in memoriam), meu irmão Cleyton Murilo Giacon e minha noiva Bianca Teixeira Morelli, que sempre foram minha base e minha estrutura. Sem eles meus sonhos seriam apenas sonhos.

Agradeço, em especial, ao professor e orientador Alexandre Marco da Silva, que me acolheu, dando a oportunidade da continuidade de um sonho. Agradeço pela amizade, prontidão, dedicação, profissionalismo, atenção e empenho. Sou muito grato por sua confiança e ensinamentos que hoje fazem parte do meu ser.

Agradeço ao Professor Caio Gorla Nogueira, grande mestre e amigo, o qual tenho enorme gratidão por abrir as portas do conhecimento pós-acadêmico.

Aos professores que compuseram as bancas de qualificação e de defesa, pelas inferências que contribuíram para que a tese final apresente nível ainda mais elevado.

Sou grato a todos os professores do Programa de Pós-Graduação de Engenharia Civil e Ambiental, que com essa profissão tão honrada transmitiram seus conhecimentos e sabedorias, com muita paciência e dedicação.

Agradeço aos amigos que a Pós-Graduação proporcionou, em especial, Higor Biondo de Assis e Jhaber Yacoub.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro que tornou possível a minha dedicação exclusiva a este projeto de pesquisa.

Aos funcionários da Seção Técnica de Pós-Graduação pelo profissionalismo, prontidão e cordialidade durante o período de minha estadia no Pós-Graduação. Em especial, a supervisora Alessandra Karine dos Santos Contador, profissional do mais alto nível de excelência, que sempre demonstrou solução para problemas, não somente a mim, mas para todos os alunos que fazem ou fizeram parte da Pós-Graduação de Engenharia Civil e Ambiental, que Deus te ilumine sempre.

Por fim, agradeço a todos que direta ou indiretamente contribuíram para que esse trabalho fosse concluído.

“E conhecereis a verdade e a verdade vos
libertará.”
(Jesus Cristo)

RESUMO

GIACON JUNIOR, A. J. **Mapeamento de Áreas Suscetíveis a Inundações na Bacia Hidrográfica do Rio Sorocaba e Médio Tietê (SP)**. 154f. Tese (Doutorado) – Universidade Estadual Paulista, Sorocaba, 2022.

Em razão aos danos associados às inundações, o mapeamento de áreas suscetíveis a esse fenômeno natural assume uma parte primordial na geotecnia ambiental. No Brasil, em virtude das características climáticas e hidrogeológicas, faz com que a inundação seja um dos desastres naturais de maior ocorrência. Nesse contexto, o presente estudo propôs o mapeamento de áreas suscetíveis a inundações da Bacia Hidrográfica do Rio Sorocaba e Médio Tietê (BH-SMT) por meio dos modelos AHP-TOPSIS-2N e Máquinas de Vetores Suporte (*Support Vector Machines* – SVM). A modelagem considerou 11 fatores condicionantes relacionados às características hidrogeomorfológicas e antropológicas, e 382 pontos inventariados de inundações e não inundações. A validação comparou o resultado gerado com mapeamentos realizados através do método Multicritério e do modelo híbrido AHP-SVM. A eficiência foi analisada através da Área Sob a Curva (*Area Under the Curve* – AUC). A análise demonstra eficiência do modelo SVM (AUC = 0,930) aplicado no mapeamento de áreas propensas a inundações, tendo como a principal variável a cobertura da terra e uso do solo. Por fim, é possível concluir que o modelo SVM pode ser aplicado como uma ferramenta científica no mapeamento de áreas suscetíveis a inundações por gestores públicos e gestores de riscos, sendo o mapa gerado capaz de fornecer prognósticos a fim de mitigar os impactos negativos relacionados ao evento de inundação.

PALAVRAS-CHAVE: Mapeamento de Suscetibilidade a Inundações; Previsão de Inundação; Bacia Hidrográfica do Rio Sorocaba e Médio Tietê; Máquinas de Vetores Suporte; AHP-TOPSIS-2N.

ABSTRACT

GIACON JUNIOR, A. J. **Mapping of Floods Susceptible Area in the Sorocaba and Middle Tietê River Hydrographic Basin (SP)**. 154p. Thesis (Doctorate Degree) – São Paulo State University, Sorocaba, 2022.

Due to flood damage, the mapping of areas susceptible to this natural phenomenon assumes a primordial part in environmental geotechnics. In Brazil, due to the climatic and hydrogeological characteristics, it makes flooding one of the most frequent natural disasters. In this context, the present study proposed the mapping of areas susceptible to flooding of the Sorocaba and Middle Tietê River Basin (BH-SMT) through the AHP-TOPSIS-2N models and Support Vector Machines (SVM). The modeling considered 11 conditioning factors related to hydrogeomorphological and anthropological characteristics, and 382 historical flood and non-flood points. The efficiency was analyzed through the Area Under the Curve – AUC. The analysis demonstrates the efficiency of the SVM model (AUC = 0.930) applied to the mapping of areas prone to flooding, with the main variable being the land use/land cover. Finally, it is possible to conclude that the SVM model can be applied as a scientific tool in the mapping of areas susceptible to flooding by public managers and risk managers, with the generated map being able to provide a prognosis to mitigate the negative impacts related to the event of flood.

KEYWORDS: Flood Susceptibility Mapping; Flood Forecasting; Sorocaba and Middle Tietê River Hydrographic Basin; Support Vector Machines; AHP-TOPSIS-2N.

LISTA DE FIGURAS

Figura 1 - Representação de áreas inundadas.....	10
Figura 2 - Conjunto de dados de treinamento de duas classes classificado a partir de três hipóteses.	16
Figura 3 - Hiperplano ótimo separando dados com maximização das margens, apoiado em vetores suporte.....	18
Figura 4 - (a) Conjunto de dados não linear; (b) Fronteira não linear no espaço de entradas; (c) Fronteira linear no espaço de características.....	19
Figura 5 - Conceito do método TOPSIS.....	23
Figura 6 - Roteiro metodológico da revisão estruturada.	28
Figura 7 - Publicações no campo de estudo de mapeamento de suscetibilidade a inundações.	33
Figura 8 - Resultado da análise de contexto.	38
Figura 9 - Localidade de aplicação dos métodos propostos pelos artigos revisados.....	39
Figura 10 - Resultado da análise de foco.....	40
Figura 11 - Resultado da análise de modelo empregado.	41
Figura 12 - Resultado da análise de métodos de pesquisa.....	42
Figura 13 - Resultado da análise de clima local.	43
Figura 14 - Resultado da análise de tamanho de área.	44
Figura 15 - Resultado da análise de fatores condicionantes.....	45
Figura 16 - Resultado da análise de benefício/desempenho.....	46
Figura 17 - Localização da Bacia Hidrográfica do Rio Sorocaba e Médio Tietê (BH-SMT) e divisão hidrográfica nacional.....	51
Figura 18 - Detalhe de localização BH-SMT.	52
Figura 19 - Fluxograma: modelo de mapeamento de suscetibilidade de inundação via SVM e via AHP-TOPSIS-2N modificado.	55
Figura 20 - Ponto de inundação na área urbana do município de Piedade (20/09/2019). ...	63
Figura 21 - Ponto de inundação na área urbana do município de Porto Feliz (01/10/2019).	64
Figura 22 - Ponto de inundação na área urbana do município de Laranjal Paulista (05/10/2019).	64
Figura 23 - Ponto de inundação na área de várzea da represa de Barra Bonita, município de Anhembi (06/10/2019).	64

Figura 24 - Mapa temático de inventário de inundações na BH-SMT.....	65
Figura 25 - Mapa temático de altimetria da BH-SMT.....	66
Figura 26 - Mapa temático de inclinação da BH-SMT.	67
Figura 27 - Mapa temático de orientação das vertentes da BH-SMT.	68
Figura 28 - Mapa temático de curvatura da BH-SMT.....	69
Figura 29 - Carta hídrica da BH-SMT.....	70
Figura 30 - Mapa temático de distância interfluvial da BH-SMT.....	71
Figura 31 - Mapa temático TWI da BH-SMT.	72
Figura 32 - Mapa temático de densidade de drenagem da BH-SMT.	73
Figura 33 - Mapa temático de solos da BH-SMT.....	74
Figura 34 - Mapa temático de SHG da BH-SMT.....	75
Figura 35 - Mapa temático de embasamento geológico da BH-SMT.	76
Figura 36 - Mapa temático de cobertura da terra e uso do solo da BH-SMT.....	78
Figura 37 - Estrutura hierárquica AHP aplicada no mapeamento de áreas suscetíveis a inundações.	80
Figura 38 - Mapa de suscetibilidade a inundações da BH-SMT - análise Multicritério AHP-TOPSIS-2N modificado: normalização sem proporcionalidade.	84
Figura 39 - Mapa de suscetibilidade a inundações da BH-SMT - análise Multicritério AHP-TOPSIS-2N modificado: normalização com proporcionalidade.....	85
Figura 40 - Mapa de suscetibilidade a inundações da BH-SMT - análise SVM.....	87
Figura 41 - Mapa de suscetibilidade a inundações da BH-SMT - análise SVM-AHP.....	88
Figura 42 - Validação das classes em função do inventário de inundações - (a) AHP-TOPSIS-2N Não Correlacionada; (b) AHP-TOPSIS-2N Correlacionada; (c) SVM; (d) AHP-SVM.	89
Figura 43 - AUC de validação dos modelos quanto à taxa de predição de mapeamento de suscetibilidade a inundações.....	92
Figura 44 - Sensibilidade dos fatores condicionantes - comparativo entre os modelos.....	93

LISTA DE TABELAS

Tabela 1 - Escala Fundamental de Saaty - AHP.....	20
Tabela 2 - Índices Randômicos.	22
Tabela 3 - Resultado da pesquisa no banco de dados.....	28
Tabela 4 - Sistema de classificação e codificação para os artigos analisados.	29
Tabela 5 - Classificação climática proposta por Köppen-Geiger.	32
Tabela 6 - Os dez artigos mais citados no banco de dados <i>Scopus</i>	34
Tabela 7 - Resultado da análise de classificação dos artigos.	34
Tabela 8 - Os 15 fatores condicionantes mais empregados.....	45
Tabela 9 - Número de habitantes por município com sede na BH-SMT.	53
Tabela 10 - Nomenclatura dos fatores condicionantes.....	79
Tabela 11 - Matriz de Julgamento - AHP-TOPISIS-2N modificado.	80
Tabela 12 - Matriz dos pesos normalizados - AHP-TOPISIS-2N modificado.....	81
Tabela 13 - Pesos dos fatores condicionantes - AHP-TOPISIS-2N modificado.....	81
Tabela 14 - Reclassificação dos fatores condicionantes qualitativos.	82
Tabela 15 - Métricas de validação dos modelos de mapeamento de áreas suscetíveis a inundações.	91
Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada.	125
Tabela 17 - Coordenadas do inventários de pontos de inundações e não inundações.....	147

SUMÁRIO

RESUMO.....	I
ABSTRACT.....	II
LISTA DE FIGURAS.....	III
LISTA DE TABELAS	V
1. INTRODUÇÃO E JUSTIFICATIVA.....	1
1.1 ESCOPO DA TESE	3
2. HIPÓTESE E OBJETIVOS	5
2.1 HIPÓTESE	5
2.2 OBJETIVOS GERAIS.....	5
2.3 OBJETIVOS ESPECÍFICOS.....	5
3. REFERENCIAL TEÓRICO.....	7
3.1 SUSCETIBILIDADE A INUNDAÇÕES	7
3.2 SUPPORT VECTOR MACHINE (SVM)	13
3.3 AHP-TOPSIS-2N MODIFICADO.....	20
4. REVISÃO BIBLIOMÉTRICA	27
4.1 MÉTODO DE REVISÃO BIBLIOMÉTRICA	27
4.2 ANÁLISE BIBLIOMÉTRICA.....	33
4.3 ANÁLISE DAS DIMENSÕES	34
4.3.1 Contexto	38
4.3.2 Foco.....	40
4.3.3 Modelo Empregado	41
4.3.4 Método da Pesquisa	42
4.3.5 Clima Local	42
4.3.6 Tamanho da Área	43
4.3.7 Fatores Condicionantes.....	44
4.3.8 Benefício/Desempenho	46
4.4 CONSIDERAÇÃO DA REVISÃO BIBLIOMÉTRICA	46
5. CARACTERIZAÇÃO DA ÁREA DE ESTUDO	51
6. ROTEIRO METODOLÓGICO	55
6.1 INVENTÁRIO DO HISTÓRICO DE INUNDAÇÕES E NÃO INUNDAÇÕES	56
6.2 FATORES CONDICIONANTES	57
6.3 MAPEAMENTO VIA AHP-TOPSIS-2N MODIFICADO.....	60
6.4 MAPEAMENTO VIA SVM.....	61
6.5 MAPEAMENTO VIA MÉTODO HÍBRIDO AHP – SVM	62

6.6	VALIDAÇÃO DOS RESULTADOS OBTIDOS	62
7.	RESULTADOS E DISCUSSÃO	63
7.1	INVENTÁRIO DO HISTÓRICO DE INUNDAÇÕES.....	63
7.2	FATORES CONDICIONANTES	65
7.2.1	<i>Altimetria</i>	65
7.2.2	<i>Inclinação</i>	67
7.2.3	<i>Orientação das Vertentes</i>	68
7.2.4	<i>Curvatura</i>	69
7.2.5	<i>Hidrografia e Distância Interfluvial</i>	70
7.2.6	<i>Índice de Umidade Topográfica</i>	71
7.2.7	<i>Densidade de Drenagem</i>	72
7.2.8	<i>Solos</i>	73
7.2.9	<i>Grupos Hidrológicos do Solo</i>	75
7.2.10	<i>Embasamento Geológico</i>	76
7.2.11	<i>Cobertura da Terra e Uso do Solo</i>	78
7.3	MAPEAMENTO DE ÁREAS SUSCETÍVEIS A INUNDAÇÕES	79
7.3.1	<i>Análise AHP-TOPSIS-2N</i>	79
7.3.2	<i>Análise SVM</i>	86
7.3.3	<i>Análise AHP-SVM</i>	87
7.4	VALIDAÇÃO DOS MAPAS DE ÁREAS SUSCETÍVEIS A INUNDAÇÕES	89
7.5	DISCUSSÃO	94
7.5.1	<i>Visão Geral do Método</i>	94
7.5.2	<i>Implicações Práticas</i>	96
7.5.3	<i>Implicações Futuras</i>	98
8.	CONSIDERAÇÕES FINAIS	101
	REFERÊNCIAS BIBLIOGRÁFICAS	105
	ANEXO A	125
	ANEXO B	147

1. INTRODUÇÃO E JUSTIFICATIVA

As inundações são um dos perigos naturais de comum ocorrência que afetam severamente a sociedade (HONG *et al.*, 2018A). Seu acontecimento quase sempre é relacionado à impactos negativos sociais, ambientais e tecnológicos (RAZAVI TERMEH *et al.*, 2018; ZHAO *et al.*, 2018). Somado a isso, a inexistência ou a inconsistência de dados de mapeamento de áreas suscetíveis a danos ambientais e, consequentemente, a falta de planejamento de ordenamento territorial fazem com que os riscos associados às inundações se maximizem.

Somente no ano de 2021, no Banco de Dados de Desastres Internacionais (EM-DAT) foram registrados 432 eventos geofísicos e relacionados ao clima, que trouxeram como consequência 10.492 mortes e mais de 101,8 milhões de pessoas afetadas em todo o mundo. Desse total de desastres inventariados, 223 eventos correspondem a inundações (CRED, 2022). De maneira geral, as inundações afetaram mais pessoas do que qualquer outro tipo de desastre natural (FROMENT; BELOW, 2020).

O evento natural de inundação, juntamente com as ferramentas de identificação e mitigação de tal evento, possui estreita relação e sintonia com alguns dos 17 Objetivos do Desenvolvimento Sustentável (ODS), estabelecido pela Organização das Nações Unidas (ONU) (ONU BRASIL, 2022), a saber:

- ODS 6 (Água Potável e Saneamento), mais especificamente as metas 6.5 – “até 2030, implementar a gestão integrada dos recursos hídricos em todos os níveis, inclusive via cooperação transfronteiriça, conforme apropriado”; 6.6.b – “apoiar e fortalecer a participação das comunidades locais, para melhorar a gestão da água e do saneamento”.
- ODS 11 (Cidades e Comunidades Sustentáveis) – especificamente as metas 11.1 – “até 2030, garantir o acesso de todos à habitação segura, adequada e a preço acessível, e aos serviços básicos e urbanizar as favelas”; 11.5 – “até 2030, reduzir significativamente o número de mortes e o número de pessoas afetadas por catástrofes e substancialmente diminuir as perdas econômicas diretas causadas por elas em relação ao produto interno bruto global, incluindo os desastres relacionados à água, com o foco em proteger os pobres e as pessoas em situação de vulnerabilidade”;

- ODS 13 (Ação Contra a Mudança Global do Clima) – especificamente a meta 13.2 – “Integrar medidas da mudança do clima nas políticas, estratégias e planejamentos nacionais”.

No âmbito nacional, após sucessíveis e incontáveis desastres (SPAUTZ, 2018; FERREIRA, 2019; G1, 2019) e apoiado nas leis: Lei nº 6.766 de 1979 e Lei nº 10.257 de 2001, as quais descrevem sobre o planejamento urbano, parcelamento e uso do solo, e a Lei nº 12.340 de 2010, que dispõe sobre a transferência de recursos da União a locais atingidos por desastres, criou-se a Política Nacional de Proteção e Defesa Civil (PNPDEC) instituída pela Lei nº 12.608 de 2012. A PNPDEC altera a Lei nº 10.257 de 2001 e estabelece que o plano diretor de municípios com áreas suscetíveis a desastres ambientais deve conter o mapeamento dessas áreas. Sendo assim, esses municípios devem apresentar carta de suscetibilidade de desastres ambientais.

Com base no PNPDEC, algumas localidades já apresentam cartas de suscetibilidade elaboradas por órgãos públicos ou entidades relacionadas ao tema, como universidades, institutos, centros de pesquisa e empresas privadas da área. Porém, dos 5.570 municípios brasileiros, apenas 531 apresentam cartas de suscetibilidade a movimentos gravitacionais de massa e inundações no banco de dados do Serviço Geológico Brasileiro (CPRM, 2022).

No cenário nacional, grande parte dos métodos empregados são baseados em análises Multicritério (BITAR, 2014), uma técnica quali-quantitativa, fundamentada na tomada de decisão através de atribuição de pesos para as variáveis envolvidas. Em termos práticos, na análise Multicritério ocorre a sobreposição de mapas temáticos (fatores condicionantes), em que cada fator condicionante recebe um peso numérico. Posteriormente a sobreposição dos mapas temáticos é realizada através de um equacionamento em função dos pesos atribuídos, gerando assim um mapa final. Uma questão importante de se considerar nos métodos com base em análise Multicritério é a atribuição de peso, que por ser subjetiva, pode gerar resultados inconsistentes caso não se aplique um meio de validação dos mapas obtidos.

Nesse contexto, o presente trabalho propõe a aplicação de um método de mapeamento de áreas suscetíveis a inundações via Máquinas de Vetores Suporte (*Support Vector Machines* - SVM). Baseado em aprendizado supervisionado, o SVM é um conceito de Aprendizado de Máquina (*Machine Learning* – ML) que, através de treinamento, analisa

os dados inseridos reconhecendo os padrões por meio de classificação de dados, consequentemente, predizendo novos dados que forem inseridos no modelo.

Sendo assim, este estudo tenderá a suprir de maneira eficiente a geração de cartas de suscetibilidade às inundações, fornecendo respostas consistentes através da aplicação de modelos diversos de mapeamento, os quais tendem facilitar a replicação, com intenção à minimização de erros em função da subjetividade e de modelos matemáticos que possam ser eventualmente adotados para elaboração desse tipo de carta. O resultado gerado via SVM foi comparado com os mapeamentos realizados através do método Multicritério AHP-TOPSIS-2N modificado e do modelo híbrido AHP-SVM.

Ressalta-se que os modelos empregados são baseados em fatores condicionantes topográficos, hidrológicos, geológicos e antropológicos, os quais são utilizados para treinamento e validação de respostas, de modo que a predição de suscetibilidade tenda a refletir um resultado mais próximo à realidade.

Os modelos propostos foram aplicados no mapeamento de áreas suscetíveis a inundações na região que compreende a Bacia Hidrográfica do Rio Sorocaba e Médio Tietê (BH-SMT). A validação dos mapas ocorreu por meio de informações históricas de inundações. O resultado obtido permitiu gerar mapas consistentes que podem ser utilizados como uma ferramenta científica de gestão pública, capaz de fornecer prognósticos para aplicação de políticas públicas de remediação em áreas já urbanizadas e de planejamento em áreas não urbanizadas, direcionando o ordenamento territorial e, consequentemente, evitando desastres naturais.

1.1 Escopo da Tese

Esta tese foi desenvolvida e é apresentada em oito capítulos. Neste primeiro capítulo, é apresentada a introdução ao tema, demonstrando a sua relevância, justificando sua escolha, além de demonstrar sua organização. O segundo capítulo explicita os objetivos gerais e as metas estabelecidas para conclusão deste estudo.

O terceiro capítulo traz como ideia central fundamentar a pesquisa através de referencial bibliográfico. Partindo ainda pelo princípio de respaldar este estudo, o quarto capítulo demonstra uma revisão estruturada sobre pesquisas relevantes que abordam o assunto apresentado no presente trabalho. Complementando o quarto capítulo, o Anexo A traz uma revisão sucinta dos trabalhos avaliados.

O quinto capítulo caracteriza a área onde será aplicado o estudo de caso, demonstrando informações geográficas, hidrológicas, geológicas e sociais da BH-SMT. Na sequência, o sexto capítulo elucida os procedimentos tomados e os métodos das análises realizadas.

Os resultados obtidos através das análises referenciadas no roteiro metodológico desta pesquisa são observados no sétimo capítulo. Finalizando o corpo principal do trabalho, o oitavo capítulo reúne as considerações finais obtidas em função de dados científicos e das análises realizadas.

2. HIPÓTESE E OBJETIVOS

2.1 Hipótese

Parte-se dos pressupostos de que eventos de inundações constituem o resultado da integração de fatores condicionantes hidrogeomorfológicos somados às precipitações pluviométricas. E, que métodos de mapeamentos com base em modelos distintos podem gerar resultados confiáveis e de valor prático para a sociedade e para os tomadores de decisão.

2.2 Objetivos Gerais

Avaliar a consistência e eficiência do SVM para mapeamento de áreas suscetíveis a inundações, prevendo um meio com minimização de erros subjetivos, facilitado e eficiente na obtenção de mapas que apresentem áreas suscetíveis a inundações.

2.3 Objetivos Específicos

Para atingir o objetivo deste trabalho, elencou-se e se alcançou as seguintes metas:

- i. Propor técnicas de mapeamento de áreas suscetíveis a inundações consistentes e de fácil replicação;
- ii. Determinar os fatores condicionantes de inundações;
- iii. Inventariar e mapear as inundações ocorridas na BH-SMT, com base em dados dos últimos 30 anos;
- iv. Produzir dados de entrada de fatores condicionantes da BH-SMT;
- v. Produzir a carta de suscetibilidade de inundações da BH-SMT;
- vi. Avaliar e validar as técnicas propostas de mapeamento de áreas suscetíveis a inundações e analisar a sensibilidade dos fatores condicionantes.

3. REFERENCIAL TEÓRICO

3.1 Suscetibilidade a Inundações

A ocorrência de eventos naturais hidrológicos, meteorológicos e geofísicos podem resultar em avalanches, escorregamentos, secas, temperaturas extremas, inundações, incêndios florestais, tempestades, ressacas, epidemia de insetos, terremotos, tsunamis e erupções vulcânicas. Esses fenômenos naturais, quando extremos, acarretam perdas físicas e materiais, além de danos ambientais, sendo possível caracterizá-los como desastres naturais (MENDONÇA; LEITÃO, 2008).

O conceito de desastre natural estabelecido pelo Banco de Dados de Desastres Internacionais (EM-DAT) descreve desastre como um evento ou uma ocorrência em um determinado local que gere danos e prejuízos, superando a capacidade de resposta, de maneira que necessite de ajuda externa para retorno da normalidade. O EM-DAT somente computa o evento como desastre quando ao menos um desses critérios é preenchido: a) 10 ou mais vítimas fatais; b) 100 ou mais pessoas afetadas; c) declaração de estado de emergência; d) pedido de assistência internacional (EM-DAT, 2022). Para a Organização das Nações Unidas (ONU), o desastre natural pode ainda ser caracterizado como o funcionamento anormal ou o não funcionamento de um determinado contexto socioeconômico local ou regional, desencadeado por um evento natural (GUHA-SAPIR *et al.*, 2012).

Nos dados atuais do EM-DAT, as inundações são um dos desastres naturais que mais causam danos no mundo (CRED, 2022). No Brasil, no período entre 2000 a 2018, o EM-DAT registrou 65 eventos de inundações, representando 71% dos desastres naturais registrados no período, totalizando 2.435 vítimas fatais (MARCELINO; NUNES; KOBAYAMA, 2006).

De maneira geral, os desastres naturais são correlacionados ao meio. Na geotecnia ambiental, a verificação de que determinado meio demonstra propensão ou predisposição à ocorrência do evento natural se caracteriza como suscetibilidade (DIAS; TRENTIN; DE SOUZA ROBAINA, 2019). Exemplo de como uma área possa ser suscetível a inundações: é aquela em que as superfícies possam demonstrar concavidades impermeáveis, que ainda não disponham de dispositivos de drenagem. Essa tendência de favorecimento de inundação não é relacionada com a ocorrência de eventos de inundações. Portanto, a suscetibilidade é

atribuída aos parâmetros apontados como fatores condicionantes, os quais evidenciam a propensão da ocorrência do fenômeno natural.

Devido à complexidade intrínseca dos eventos e, conseqüentemente, dos desastres naturais, outros termos se confundem com a suscetibilidade. O termo perigo, por exemplo, é empregado quando eventos naturais expressam uma situação potencialmente prejudicial, a qual possa trazer conseqüências negativas (MARANDOLA JR; HOGAN, 2016).

Por sua vez, as conseqüências negativas oriundas de um determinado fenômeno são associadas à vulnerabilidade do meio, a qual pode ser caracterizada por um grau de danos ou perdas que, geralmente, são expressas em valores entre 0 a 1, sendo que 0 corresponde a nenhum dano e ou perda, e, 1 danos e perdas totais. Quanto à classificação do evento que gere danos ou perdas, comumente se intitula o termo severidade, a qual é avaliada a magnitude dos parâmetros que o fenômeno apresenta, como velocidade, volume, duração, valores em escala Richter e área atingida (JULIÃO *et al.*, 2009; MENDONÇA; LEITÃO, 2008).

Cada vez mais usual no meio acadêmico, o termo resiliência, quando utilizado em concordância a desastres naturais, descreve a capacidade que um meio, ao ser exposto a determinado evento natural que apresente perigo, tenha em tolerar, assimilar, adequar-se e restabelecer-se em relação às conseqüências negativas (GUHA-SAPIR *et al.*, 2012).

Em analogia aos conceitos apresentados, a mensuração das ameaças, conseqüências e reação é fornecida pelo risco. O risco equaciona análises estatísticas de perigo e da conseqüência negativa gerada (perdas financeiras, tecnológicas e sociais), considerando ainda o fator de resiliência do meio (DILLEY, 2005; MENDONÇA; LEITÃO, 2008; GUHA-SAPIR *et al.*, 2012). De maneira simplificada, o risco pode ser assumido através da probabilidade de ocorrência de perigo agravada pela vulnerabilidade e minimizada pela resiliência.

Sendo assim, a resiliência está relacionada diretamente ao risco, uma vez que o meio seja preparado ou tenha desenvolvido infraestrutura ou até mesmo mapeado e ou gerenciado às áreas de risco, nesses casos existe a minimização do risco final. Exemplo prático disso é que após o mapeamento de áreas de risco pelos órgãos competentes, é possível realizar o direcionamento de políticas públicas de maneira a minimizar os riscos através de implementação da infraestrutura. Outro exemplo de minimização de risco pode ser observado em um caso de uso e ocupação do solo, o emprego de uma carta de suscetibilidade de movimento de massa ou inundações, permite efetuar o ordenamento territorial,

direcionando os locais de edificações essenciais, como hospitais, para áreas não suscetíveis a esses eventos, evitando que essas edificações sejam atingidas na ocorrência de um desses desastres naturais.

Dos eventos naturais que mais afetam a sociedade, os fenômenos hidrológicos, como a precipitação pluviométrica, podem acarretar desastres naturais com consequências severas. Esse evento apresenta frequência variável, que consiste na submersão de uma área seca, comumente em função do aumento da vazão hídrica em razão de precipitações intensas de longa duração ou em precipitações com níveis elevados em curtos períodos de tempo (RAMOS, 2013).

A submersão de áreas secas pode ser dividida em três categorias. A primeira se refere ao transbordamento de água de um corpo hídrico em terra normalmente seca na planície aluvial, denominado inundação ribeirinha. Na inundação costeira, o nível de água atinge pontos mais altos do que os normais ao longo da costa, em lagos ou reservatórios. Por fim, quando ocorrem represamentos d'água no ponto ou próximo onde ocorreu a precipitação devido à insuficiência de drenagem, esses represamentos podem ser classificados como inundação repentina (WALLEMACQ; DE ALMEIDA, 2018), ou como alagamento, quando o represamento é próximo ao canal do corpo d'água (IPT, 2007).

Visto que alguns termos podem demonstrar ambiguidades, é necessário detalhar demais eventos ocasionados em função de elevados níveis de precipitação, tais como: alagamentos, inundações, enchentes e enxurradas. As enchentes ou cheias são definidas como a elevação no nível normal d'água em um corpo hídrico ou em um canal de drenagem devido ao aumento de vazão. Enchentes atingem o nível máximo do canal, não apresentando extravasamento (IPT, 2007). A enxurrada pode ser descrita como o transporte de águas excedentes de corpos hídricos através de escoamento superficial apresentando alta energia, processo que pode estar ou não vinculado a áreas de domínio de sistemas fluviais (IPT, 2007). O alagamento é definido como a retenção momentânea de água em um determinado local em função de um sistema de drenagem insatisfatório, podendo ser ou não correlacionado ao regime de natureza fluvial (IPT, 2007). A deficiência do sistema de drenagem, por vezes, é correlacionada à impermeabilização do solo, o que diminui a capacidade natural de infiltração da água. Essa impermeabilização pode ser gerada pela compactação local do solo, pavimentação, construções de edificações de maneira adensada, desmatamento, falta de infraestrutura de drenagem como galerias pluviais ou entupimento de galerias pluviais quando essas infraestruturas são existentes (NASCIMENTO, 2016).

Eventos de inundações se relacionam diretamente com o excedente do acúmulo d'água nas calhas dos corpos hídricos, ou seja, a água que extravasa as áreas marginais a esses cursos d'água. Para alguns autores, inundações e alagamentos não se contrapõem (ARAGÃO; DE COLETIVIDADE, 1994; CRED, 2022), essa dimensão de significado pode ser observada na Figura 1. Para fins científicos e acadêmicos, este estudo assumirá que inundações e alagamentos possuem o mesmo significado e contém a mesma dimensão.




Figura 1 - Representação de áreas inundadas.
Fonte: CEMADEN, 2019.

Eventos naturais de inundação correlacionam aspectos multidisciplinares, que podem ser pertinentes às características geológicas, topográficas e morfológicas das bacias hidrográficas (ULLAH; CHOUDHURY, 2010; HOSSAIN *et al.*, 2014; RAZAVI TERMEH *et al.*, 2018; CHOUBIN *et al.*, 2019). Os fatores relacionados à ocorrência desse fenômeno podem ser divididos em:

- Transitórios, como precipitações, taxas de evapotranspiração e grau de saturação do subsolo;
- Permanentes, que correspondem às características morfométricas da bacia de drenagem, geologia e geotecnologia;
- Mistos, que estão relacionados ao processo antropológico de uso e ocupação do solo.

Fato relevante é que a inundação, constitui um evento natural, sendo parte integrante de ciclos hidrológicos que compõem variados ecossistemas. Dessa maneira, eventos de inundações que ocorram na natureza sem a interferência antropológica, tendem a

ter efeitos benéficos aos biomas, contribuindo com a reprodução e crescimentos de algumas espécies de vegetação e animais (REBELLATO; CUNHA, 2005). Alguns lagos formados por inundações são ainda responsáveis na conservação e manutenção da vida aquática, principalmente, quando se trata de algumas espécies de peixes de água doce (DA PONTE; DA SILVA OLIVEIRA; ZACARDI, 2019).

Deste modo, os desastres relacionados a inundações podem ter ligações diretas as ações antropológicas, essencialmente, em áreas ocupadas pelo ser humano sem o conhecimento prévio do ciclo hidrológico dos cursos d'água, ou ainda, negligenciando tais eventos naturais.

Os fatores que condicionam o evento de inundação é um dos pré-requisitos para o mapeamento de suscetibilidade a esse fenômeno. A determinação dos fatores condicionantes é norteadada através de literatura científica (COSTACHE *et al.*, 2021). Após o processo de precipitação pluviométrica elevada, os fatores comumente mencionados na literatura como condicionantes a inundações são:

- Altimetria: é considerado um fator permanente de alta influência no evento de inundação, ele é relacionado inversamente entre maior altitude e inundação (CHOUBIN *et al.*, 2019);
- Inclinação: é a inclinação do relevo da superfície terrestre. Relaciona-se diretamente com a inundação, contribui para a velocidade de percolação vertical e escoamento superficial, quanto menor a inclinação maior a propensão de acúmulo de água (HONG *et al.*, 2018A);
- Orientação das vertentes: é definido como a direção da inclinação máxima da superfície do terreno. Aliado à inclinação, a orientação das vertentes direciona o escoamento superficial (MUHAMAD *et al.*, 2019);
- Curvatura: a curvatura consiste em três categorias: superfície côncava, convexa e plana. É um fator no escoamento superficial e pode ser útil na detecção da suscetibilidade a inundações, observado que superfícies côncavas aliadas ao estado de impermeabilidade das superfícies tendem a acumular líquidos (LEE *et al.*, 2018);
- Distância interfluvial: corpos hídricos que apresentem fluxos são as principais vias de descargas de inundações. O outro ponto é que áreas

próximas a rios são suscetíveis a inundações (áreas de várzea) (LI *et al.*, 2019);

- Índice de umidade topográfica (*Topographic Wetness Index* - TWI): esse parâmetro indica as variações espaciais de umidade em bacias hidrográficas (exibe a quantidade de acúmulo de água em qualquer pixel da área da bacia hidrográfica) (BEVEN; KIRKBY, 1979). O TWI pode ser descrito pela Equação (1):

$$TWI = \ln\left(\frac{A_s}{\tan\beta}\right) \quad (1)$$

Sendo: A_s [$\text{m}^2.\text{m}^{-1}$] a área específica (área de inclinação do talude do local drenado) e β o grau de inclinação do talude;

- Densidade de drenagem: define a capacidade de áreas de drenagem. Esse fator tem importante influência na suscetibilidade à inundação (ZHAO *et al.*, 2018);
- Solo: considera o tipo de solo e suas características quanto à profundidade de camada. Correlaciona ainda a estrutura física e química do solo, como granulometria e composição, as quais têm influência na permeabilidade do solo e na absorção da água. Solos que se apresentem com grandes camadas de profundidade, mais arenosos e mais porosos tendem a ser menos suscetíveis a inundações (PINTO, 2016; BUI *et al.*, 2020);
- Grupos hidrológicos do solo (*Soil Hydrological Groups* - SHG): indicam a qualidade do solo, baseada em uma taxa mínima de infiltração de água. Os grupos hidrológicos do solo são quatro: A, B, C e D. Os solos do grupo A têm o potencial de escoamento mínimo, enquanto os solos do grupo D têm o potencial de escoamento máximo (GITTLEMAN *et al.*, 2017);
- Embasamento geológico: influencia os processos hidrológicos em uma bacia hidrográfica, isso em função de diferentes porosidades e fraturas que rochas podem apresentar. Diferentes unidades litológicas têm diferentes suscetibilidades às inundações. Rochas sedimentares como o arenito tendem a ser menos suscetíveis a inundações (SOZER *et al.*, 2018);

- Cobertura da terra e uso do solo: tem um papel significativo na velocidade de escoamento, interceptação e infiltração. Isso se deve às ações antrópicas que podem adensar e impermeabilizar o solo. A cobertura da terra e uso do solo tem parte fundamental na suscetibilidade a inundações (BITAR, 2014).

O mapeamento de áreas suscetíveis à inundação tem como objetivo principal subsidiar a prevenção de desastres naturais. Verifica-se que a suscetibilidade está associada às condições do terreno, seja ele natural ou modificado antropologicamente, que favorecem a elevação do nível d'água em determinado canal de drenagem, ocorrendo o transbordamento (BITAR, 2014).

Um avanço no mapeamento de suscetibilidade de grandes áreas ocorreu através da implementação de sensoriamento remoto e da plataforma de Sistema de Informação Geográfica (SIG). O sensoriamento remoto é baseado em sensores multiespectrais, pancromáticos e termais, alocados de maneira aeroespacial (satélites). Os sensores são alocados em bandas que permitem analisar a sensibilidade espectral através da captura de diferentes faixas de ondas, o que permite obter imagens da superfície terrestre. O SIG pode ser caracterizado como um conjunto de técnicas que coletam, armazenam, tratam e analisam dados de geoprocessamento (CÂMARA; DAVIS; MONTEIRO, 2001; FLORENZANO, 2007). O produto obtido pelo sensoriamento remoto aliado ao SIG é passível de manuseio e atribuição de informações detalhadas de determinada área através de *softwares* dedicados. Esses *softwares*, por sua vez, permitem o tratamento e edição das imagens geradas.

Por fim, as informações das superfícies terrestres, uma vez georreferenciadas, podem trazer informações de grande relevância, principalmente, no que diz respeito ao levantamento de dados hidrogeomorfológicos. Neste estudo, esses dados correspondem aos fatores condicionantes a suscetibilidade a inundações. Nesse contexto, o sensoriamento remoto e o SIG permitiram um avanço significativo no desenvolvimento de pesquisas referentes ao meio ambiente e recursos naturais, demonstrando ser ferramentas de grande valia em gestão pública e planejamento (FITZ, 2018).

3.2 Support Vector Machine (SVM)

O Aprendizado de Máquina ou, em inglês, *Machine Learning* (ML) se baseia em Inteligência Computacional, que tem como premissa desenvolver modelos capazes de assimilar conceitos e conhecimentos com base em uma determinada amostra de dados

(MITCHELL, 1997). Entende-se que esse processo de aprendizado é denominado como processo indutivo, e que pode ser principalmente realizado de maneira supervisionada, não supervisionada e por reforço (RUSSELL; NORVIG, 1995).

No aprendizado indutivo supervisionado, o conhecimento e o conceito são realizados através de um agente externo, representado a figura de um professor, o qual demonstra ao modelo exemplos de dados de entrada e a saída desejada. Com base no conhecimento gerado pelo treinamento inicial, em teoria, o algoritmo se torna capaz de gerar saídas de dados desejadas para novos dados de entrada, agora desconhecidos (HAYKIN; NETWORK, 2004).

No aprendizado não-supervisionado, não existem conceitos definidos *a priori*, nem a presença de um agente externo. Nesse caso, o modelo aprende a rotular ou a agrupar os dados de entrada de acordo com uma medida de similaridade. Essa técnica geralmente é utilizada quando se pretende estabelecer tendências ou padrões para classificação e entendimento dos dados (HAYKIN; NETWORK, 2004).

O aprendizado por reforço é realizado por meio de recompensas ou punições ao indutor que são fornecidas a depender do desempenho do algoritmo em aproximar o algoritmo a uma função desejada (BISHOP; NASRABADI, 2006).

As técnicas desenvolvidas no ML tiveram estímulos diversificados de criação. Alguns modelos foram inspirados em sistemas biológicos, caso do método de Redes Neurais Artificiais, cuja arquitetura e funcionamento do modelo se baseia em neurônios. Outro modelo estabelecido em sistemas biológicos é o método de Algoritmos Genéticos, o qual tem como fundamento a evolução natural e genética. Na área de aprendizado simbólico, existe o método de Árvores de Decisão. Já o método de Sistema de Raciocínio Baseados em Casos teve inspiração em processos cognitivos. Por fim, o método de aprendizado supervisionado SVM foi conceituado na Teoria de Aprendizado Estatístico (TAE) (LORENA; CARVALHO, 2003).

A TAE estabelece critérios matemáticos e estatísticos para a escolha do classificador que apresente desempenho ótimo em consideração ao conjunto de dados fornecidos para treinamento e teste (VON ZUBEN; VERONEZE, 2013).

O conceito básico da TAE considera que o desempenho esperado para um classificador denominado por uma função f de determinado conjunto de todos os classificadores F , demonstre o menor erro durante o treinamento. Para isso, durante o aprendizado se utiliza um conjunto de treinamento, formado de n pares (X_i, y_i) , em que X_i

representa o vetor com os dados de entrada e y_i descreve o rótulo da classe, desenvolvendo assim, um classificador individual $\hat{f} \in F$ (LORENA; CARVALHO, 2003).

Deste modo, inicialmente, assume-se que os dados do domínio em que o aprendizado está acontecendo são formados de maneira independente e identicamente distribuídos, isso em função de uma distribuição de probabilidades $P(X, y)$, descrevendo, assim, a relação entre os dados de entrada e seus rótulos (BURGES, 1998). Visto que o TAE busca o classificador que forneça o menor erro, onde o erro é medido em função do número de predições incoerentes com as predições desejadas de f , faz-se necessário caracterizá-lo. Desse modo, o erro pode ser definido como o risco $R(f)$, podendo ser dimensionado pela Equação (2).

$$R(f) = \int c(f(X_i), y_i) dP(X_i, y_i) \quad (2)$$

Onde: $c(.)$ é uma função de custo pertinente da previsão do classificador $f(X_i)$ com saída desejada de y_i .

De modo geral, a função custo $c(.)$ empregada em modelos de classificação são do tipo “perda 0/1”, retornando o valor de 0 quando X_i é classificado corretamente e 1 se X_i for classificado de maneira incorreta, conforme a Equação (3).

$$c(f(X_i), y_i) = \frac{1}{2} |y_i - f(X_i)| \quad (3)$$

Porém, devido à distribuição de probabilidade $P(X, y)$ ser desconhecida, não é possível minimizar o risco esperado, mostrado na Equação (2). Nesses casos, utiliza-se o risco empírico $R_{emp}(f)$, de maneira a fornecer a medida do desempenho do classificador em função do erro entre o resultado desejado e o resultado obtido (SMOLA *et al.*, 2000; HAYKIN; NETWORK, 2004), como na Equação (4).

$$R_{emp}(f) = \frac{1}{n} \sum_{i=1}^n c(f(X_i), y_i) \quad (4)$$

Sucintamente, considerando um determinado conjunto de dados de treinamento (X_i, y_i) com $X_i \in \mathbb{R}^N$ e $y_i \in \{-1, +1\}$, $i = \{1, 2, \dots, n\}$, sendo X_i o vetor com dados de

entrada e y_i o rótulo da classe, o objetivo, então, é obter uma função classificadora f . Se nenhuma restrição for imposta na classe de funções em que se escolhe a estimativa do classificador f , a tendência é que a função demonstre excelentes resultados no conjunto de treinamento. Porém, para padrões desconhecidos o classificador f pode cometer erros, tendência denominada *overfitting*.

Em outra situação, em que o modelo apresente um classificador f que desconsidere pontos de classes diferentes que se apresentem muito próximas, muitos erros podem ser gerados, isso até mesmo no treinamento de dados, ocorrência denominada de *underfitting*. Salienta-se que o classificador f desejado deve estar entre as hipóteses de classificação que gerem tendências de *overfitting* e *underfitting*. Um exemplo de hipóteses de classificação é sugerido na Figura 2.




Figura 2 - Conjunto de dados de treinamento de duas classes classificado a partir de três hipóteses.

Com o intuito de prevenir a obtenção de modelos com funções de classificadores que levem ao *overfitting* e limitar classes de funções (hiperplanos), a TAE pode implementar uma função com a devida capacidade de conjunto de dados de treinamento (HEARST *et al.*, 1998). Essa função é descrita como limites que são impostos ao risco funcional do classificador. Os limites são baseados nos conceitos propostos por Vapnik-Chervonenkis, denominados dimensão VC (GOODFELLOW; BENGIO; COURVILLE, 2016). A dimensão VC pode ser definida como o número máximo de exemplos de treinamento que a máquina pode aprender sem gerar erros, isso em relação a um conjunto de funções de classificação G , em que G é um conjunto de funções sinal (HAYKIN; NETWORK, 2004). Genericamente, para funções lineares no $\mathbb{R}^N$ para $n \geq 2$ a dimensão VC é expressa pela Equação (5).

$$VC(n) = n + 1 \quad (5)$$

O método de SVM desenvolvido por Vladimir Vapnick, Bernhard Boser, Isabelle Guyon e Corrina Cortes, tem como principais objetivos adaptar-se e aprender através de estímulos por inserção de dados. A partir do treinamento do modelo, o algoritmo SVM é capaz de prever dados por classificação (ANDREOLA, 2009).

O conceito de margem e vetores suporte parte do princípio de que $f(x) = (w \cdot X) + b$ é um hiperplano, o que define a margem como a menor distância entre os conjuntos de treinamento e o hiperplano empregado para separação dessas classes (LORENA; CARVALHO, 2003). Formalmente a margem pode ser definida conforme a Equação (6).

$$\rho = \min_i y_i f(X_i) \quad (6)$$

Onde: ρ é a margem do classificador f .

A margem é definida pela distância entre o hiperplano ótimo e os vetores que apresentam as menores distâncias em relação a ele. Esses vetores são chamados de vetores suporte. O hiperplano em um espaço bidimensional e os vetores suporte de um conjunto de amostras de treinamento de dois dados classificados linearmente pode ser observado na Figura 3.




Figura 3 - Hiperplano ótimo separando dados com maximização das margens, apoiado em vetores suporte.

Deste modo, é possível conceituar o SVM através de um conjunto de classificadores baseados em TAE para mapeamento das informações fornecidas, inicialmente, para um espaço de natureza de alta-dimensão, onde o treinamento é supervisionado. Por intermédio de um estabelecimento de condições matemáticas, o SVM realiza mapeamento de dados de entrada, que pode ser linear ou não linear (SEMOLINI, 2002; LORENA; CARVALHO, 2007). Para isso, o SVM constrói um hiperplano para separar os dados em classes.

Se os dados de entrada fornecidos forem linearmente separáveis ou que possuam uma distribuição aproximadamente linear, o emprego de SVM com classificação linear é eficaz, demonstrando resultados com presença de erros toleráveis. Porém, na maior parte das aplicações de SVM, os dados se apresentam com classificações não lineares, em que o treinamento através de um hiperplano em seu espaço original gera erros que não são toleráveis. Nesses casos, o método SVM mapeia o conjunto de treinamento para um novo espaço que apresente maior dimensão, produzindo um hiperplano ótimo, até que o conjunto de treinamento desses dados possam ser separados através de SVM com classificação linear (VON ZUBEN; VERONEZE, 2013), conforme ilustrado na Figura 4.




Figura 4 - (a) Conjunto de dados não linear; (b) Fronteira não linear no espaço de entradas; (c) Fronteira linear no espaço de características.

Fonte: Adaptado de Lorena e Carvalho, 2007.

Nos casos em que o número de dimensões demonstre um processamento extremamente custoso e inviável de dados, o mapeamento é executado por meio de um produto interno *kernel* (LORENA; CARVALHO, 2007).

Uma função *kernel* tem por objetivo receber dois dados X_i e X_j do espaço de entradas e produzir o produto escalar no espaço de características, conforme a Equação (7).

$$\text{kernel}(X_i, X_j) = \Phi(X_i) \cdot \Phi(X_j) \quad (7)$$

Define-se como função *kernel* a que seguem as condições definidas pelo Teorema de Mercer (SMOLA *et al.*, 2000). Sucintamente, o Teorema de Mercer determina que a função *kernel* forneça matrizes semidefinidas positivas, em que cada elemento da matriz *kernel* K_{ij} seja definida por $K_{ij} = K(X_i, X_j)$, para todo $i, j = 1, \dots, n$ (HERBRICH, 2001).

As funções *kernel* de maior emprego em modelos SVM são as polinomiais, de base radial e sigmodal (LORENA; CARVALHO, 2003; VON ZUBEN; VERONEZE, 2013).

O método SVM é robusto diante de dados de grande dimensão, em comparação a outras técnicas de aprendizado. Por exemplo, Rede Neurais (RNA), visto que o SVM apresenta convexidade do problema de otimização formulado em seu treinamento, gerando a existência de um mínimo global único, já o RNA gera mínimos locais na função objetivo minimizada (HAYKIN; NETWORK, 2004).

3.3 AHP-TOPSIS-2N Modificado

O modelo Multicritério AHP-TOPSIS-2N é baseado no método *Analytical Hierarchy Process* – AHP, desenvolvido por Thomas Saaty em 1977 (VAIDYA; KUMAR, 2006) e no método *Technique for Order Preference by Similary to Ideal Solution* – TOPSIS (TZENG; HUANG, 2011). O 2N que compõe a nomenclatura se refere às duas normalizações dos dados de entrada que o método emprega (DE SOUZA; GOMES; DE BARROS, 2018).

O AHP-TOPSIS-2N foi modelado para tomadas de decisões em problemas complexos que buscam o resultado ideal com base em fatores qualitativos e quantitativos. O termo “modificado”, que compõe a nomenclatura, está relacionado à substituição de uma das normalizações utilizada pelo método original, conforme se demonstra na elucidação.

A primeira etapa do método é fundamentada na ponderação de pesos dos fatores condicionantes que envolvem o problema. Para isso, o AHP é empregado, inicialmente, para gerar uma Matriz de Julgamento, que expressa a dominância de um critério em relação a outro. Essa dominância faz com que uma alternativa de menor importância seja mantida na ponderação e na tomada de decisão final.

A verificação da importância é realizada entre dois critérios, sendo concretizada por meio de embasamento de um ou mais especialistas na ponderação da dominância. A dominância é atribuída de acordo com a Escala Fundamental definida por Saaty (SAATY, 1994), conforme a Tabela 1.

Tabela 1 - Escala Fundamental de Saaty - AHP.

Valor do peso ou da importância	Definição do peso ou da importância
1	Igual
2	Um Pouco Melhor
3	Algo Melhor
4	Moderadamente Melhor
5	Melhor
6	Bem Melhor
7	Muito Melhor
8	Criticamente Melhor
9	Absolutamente Melhor

Com base na dominância, define-se a Matriz de Julgamento, composta por colunas de critérios e linhas com os critérios transpostos, conforme Equação (8).

$$\text{Matriz de Julgamento} = \begin{bmatrix} 1 & a_{1,2} & \dots & a_{1,n} \\ \frac{1}{a_{1,2}} & 1 & \dots & a_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{1}{a_{1,m}} & \frac{1}{a_{2,m}} & \dots & 1 \end{bmatrix} \quad (8)$$

Sendo a_i o critério, $a_{i,j}$ a dominância do critério, a_i em relação ao critério a_j estabelecido conforme a Tabela 1. O valor 1 é empregado quando analisamos a importância do critério em relação a ele próprio. Ressalta-se que é de extrema importância a verificação da relação inversamente proporcional existente entre $a_{i,j}$ e $a_{j,i}$.

Definida a Matriz de Julgamento, calcula-se o seu autovetor (W_i) com o objetivo de ordenar as prioridades hierárquicas das características das alternativas. O cálculo de autovetor é mostrado na Equação (9).

$$W_i = \left(\prod_{j=1}^n w_{i,j} \right)^{\frac{1}{n}} \quad (9)$$

Para que os critérios e as alternativas tenham comparabilidade entre eles, realiza-se o cálculo da normalização dos autovetores (T), como demonstra a Equação (10).

$$T = \left| \frac{w_1}{\sum w_i}; \frac{w_2}{\sum w_i}; \dots; \frac{w_n}{\sum w_i} \right| \quad (10)$$

A consistência assumida pela Matriz de Julgamento é avaliada pelo Índice de Consistência (IC) e, posteriormente, pela Razão de Consistência (RC). Para o cálculo do IC é necessária a definição do autovalor máximo ($\lambda_{m\acute{a}x}$). O $\lambda_{m\acute{a}x}$ é o índice que relaciona os critérios da Matriz de Julgamento aos pesos de cada critério e é definido pela média dos autovalores, como representado pela Equação (11).

$$\lambda_{m\acute{a}x} = T \times W \quad (11)$$

Com o valor de $\lambda_{m\acute{a}x}$ e o número de critérios envolvidos (n) no problema, define-se o IC através da Equação (12).

$$IC = \frac{\lambda_{m\acute{a}x} - n}{(n - 1)} \quad (12)$$

A RC estabelece como regra geral que o valor mínimo aceitável para consistência da dominância atribuída aos critérios é de 0,1 (SAATY, 1994). Caso o resultado ultrapasse o referido valor, é necessário refazer a dominância dos critérios. O equacionamento de RC leva em consideração a Tabela 2 de Índices Randômicos (IR) (SAATY, 1994).

Tabela 2 - Índices Randômicos.

Números de critérios (<i>n</i>)	Índices Randômicos (IR)
1	0,00
2	0,00
3	0,58
4	0,90
5	1,12
6	1,24
7	1,32
8	1,41
9	1,45
10	1,49
11	1,51
12	1,48
13	1,56
14	1,57
15	1,59

O RC é demonstrado pela Equação (13).

$$RC = \frac{IC}{IR} \quad (13)$$

Admitidos e verificados os pesos atribuídos a cada critério envolvido pelo método AHP, gera-se a agregação desses pesos à matriz inicial e se obtém a ordenação final das alternativas por meio do TOPSIS. No método TOPSIS, considera-se a melhor alternativa aquela mais próxima da solução ideal e mais distante da solução não ideal, conforme ilustrado pela Figura 5, na qual se observa que mesmo o ponto A sendo a solução mais próxima à solução ideal, a melhor alternativa de acordo com o método seria o ponto B. A justificativa da melhor solução pressupõe que um problema, por vezes, composto por várias variáveis (fatores condicionantes), pode apresentar soluções em mais de uma dimensão.




Figura 5 - Conceito do método TOPSIS.

O modelo axiomático do TOPSIS assume a matriz inicial do problema, denominada Matriz de Decisão (D), composta por colunas de alternativas e linhas de critérios, conforme Equação (14).

$$D = \begin{bmatrix} x_{1,1} & \cdots & x_{1,n} \\ \vdots & \ddots & \vdots \\ x_{m,n} & \cdots & x_{m,n} \end{bmatrix} \quad (14)$$

Definida a Matriz de Decisão, os valores são normalizados através de dois equacionamentos. Neste estudo em específico, a relação da modificação proposta do método AHP-TOPSIS-2N consiste em assumir a normalização que desconsidere a proporcionalidade como indica o método inicial (Equação (15)) e a substituição da normalização que conserva a proporcionalidade (Equação (16)).

$$r_{i,j} = \frac{x_{ij} - \min(x_{ij})}{\max(x_{ij}) - \min(x_{ij})} \quad (15)$$

$$r_{i,j} = \frac{x_{ij}}{\max(x_{ij})} \quad (16)$$

A normalização da Matriz de Decisão pode ser observada na Equação (17).

$$R = [r_{i,j}]m \times n \quad (17)$$

Normalizada a Matriz de Decisão, os pesos definidos anteriormente são utilizados na ponderação de cada critério normalizado, em que a somatória dos pesos deve ser igual a 1, conforme Equação (18).

$$p = [r_{i,j}]m \times n : p_{i,j} = w_j \times r_{i,j} \quad (18)$$

Na sequência, verifica-se a alternativa ideal (A^+) (Equação (19)) e a alternativa não ideal (A^-) (Equação (20)).

$$A^+ = (p_1^+, p_2^+, \dots, p_n^+) \quad (19)$$

$$A^- = (p_1^-, p_2^-, \dots, p_n^-) \quad (20)$$

Onde: p_j^+ e p_j^- são os critérios normalizados e ponderados, onde na alternativa ideal.

Se o critério é de benefício utiliza-se o máximo $p_{i,j}$, se o critério é de malefício emprega-se o mínimo $p_{i,j}$. No caso da alternativa não ideal, a aplicação do $p_{i,j}$ é inversa a alternativa ideal.

Encontradas as soluções ideal e “anti-ideal”, verifica-se a distância euclidiana em relação a essas soluções. A distância euclidiana (d_i^+) em relação a (A^+) é demonstrada pela Equação (21).

$$d_i^+ = \sqrt{\sum_{j=1}^n (d_{i,j})^2 \rightarrow p_j^+ - p_{i,j}} \quad (21)$$

A distância euclidiana em relação a solução (A^-) é fornecido pela Equação (22).

$$d_i^- = \sqrt{\sum_{j=1}^n (d_{i,j})^2 \rightarrow p_j^- - p_{i,j}} \quad (22)$$

Por fim, calcula-se o Índice de Proximidade Relativa (ξ) verificando qual alternativa que mais se aproxima da solução ideal e se apresenta mais distante da solução não ideal, conforme a Equação (23).

$$\xi = \frac{d_i^-}{d_i^+ + d_i^-} \quad (23)$$

Como observado no equacionamento do método, as duas normalizações geram dois resultados. Ambos são comparados, e com isso, é possível analisar e optar pela escolha do melhor produto obtido.

4. REVISÃO BIBLIOMÉTRICA

O evento natural de inundação é um fenômeno complexo, que somado a seu potencial danoso, proporciona a esse assunto relevância no meio acadêmico, que por sua vez procura entender e explorar os mecanismos que o regem.

Diversos pesquisadores procuram em seus estudos mapear áreas suscetíveis a inundações (SHAFIZADEH-MOGHADAM *et al.*, 2018; CHEN *et al.*, 2020; TIEN BUI *et al.*, 2019B). Os estudos de mapeamento de áreas suscetíveis a inundações quase sempre estão associados a um estudo de caso, ou seja, confirmando a existência de áreas propensas a inundações. Os modelos empregados podem ser baseados em sobreposição de mapas (BRAUD *et al.*, 2020), análise Multicritério (STAVROPOULOS *et al.*, 2020; DAS, 2020), análise Estatística (ABUZIED *et al.*, 2016; HANG *et al.*, 2021), análise baseada em ML (ZHAO *et al.*, 2018; AVAND, MORADI, RAMAZANZADEH LASBOYEE, 2021B).

Essa diversidade de informações, juntamente com a relevância do assunto, orientou o presente capítulo, de modo que a premissa fosse em identificar e sistematizar estudos sobre mapeamento de áreas suscetíveis a inundações, verificando quais assuntos já foram abordados, de modo ainda a servir de suporte teórico, justificar os argumentos e, conseqüentemente, direcionar esta pesquisa e outras demais relacionadas a áreas correlatas. Assim, realizou-se uma revisão estruturada da literatura, identificando os estudos mais relevantes, classificando-os e categorizando-os.

4.1 Método de Revisão Bibliométrica

A revisão da literatura é parte integrante dos estudos científicos. Através dela é possível verificar o que já foi publicado, identificar os avanços alcançados e analisar lacunas existentes, o que resulta em estudos com contribuições originais. O método empregado tem base nos estudos de artigos publicados na área de gerenciamento humano e de suprimentos (MARIANO; SOBREIRO; DO NASCIMENTO REBELATTO, 2015). A elaboração da revisão está descrita na Figura 6.




Figura 6 - Roteiro metodológico da revisão estruturada.

A etapa 1 é caracterizada pela definição das palavras-chave utilizadas na pesquisa dos artigos suporte da revisão estruturada. A escolha das palavras-chave considerou o foco desta pesquisa, que procura realizar o mapeamento de áreas suscetíveis a inundações. O critério de escolha foi direcionado através da leitura de artigos de autores referência do assunto (BUI *et al.*, 2020; KHOSRAVI *et al.*, 2018; TEHRANY; KUMAR, 2018; TIEN BUI *et al.*, 2018). Com isso, obteve-se dois conjuntos de palavras-chave relevantes, conforme demonstrado na Tabela 3.

Na segunda etapa se efetivou a pesquisa por meio do banco de dados *Scopus* através do campo “Search - Article title; Abstract; Keywords”. Foram utilizados para compor os termos definidos como palavras-chave os operadores lógicos “AND” e “OR”, conforme demonstra a Tabela 3.

Tabela 3 - Resultado da pesquisa no banco de dados.

Palavras-Chave	Resultado da Pesquisa em Nº. de Artigos	Nº. de Artigos Final após Descarte
"Flood Susceptibility Mapping" OR "Flood Susceptibility Map"	199	166
"Flood Forecasting" OR "Flood Prediction" AND "Susceptibility"	16	39
		(-26 duplicados)
Total		179

Para os termos definidos, a pesquisa obteve como resposta 248 artigos. Na terceira etapa, dentre os 248 artigos iniciais, 26 deles se apresentaram duplicados e 43 artigos não estavam relacionados com o assunto de interesse ou não estavam disponíveis. Sendo assim, um total de 69 artigos foi descartado da revisão estruturada. Ressalta-se que a pesquisa considerou os artigos publicados até 2022. Portanto novos artigos podem ter sido publicados após esse período.

O sistema de classificação realizado na etapa 4 procurou categorizar as pesquisas em 8 classes, onde cada classe apresentou subcategorias. As classes foram listadas numericamente de 1 a 8 enquanto as subclasses foram elencadas através do sistema alfabético (A, B, C...).

A categoria 1 (contexto) do sistema de classificação refere-se ao cenário em que se realizou a pesquisa. Na categoria 2 (foco) verifica-se o foco da aplicação do estudo. As categorias 3 (modelo empregado) e 4 (método da pesquisa) analisam respectivamente o modelo e o método empregados. As categorias 5 (clima) e 6 (tamanho de área) classificam as localidades onde foram aplicadas as pesquisas. A categoria 7 (fatores condicionantes) averigua quais foram os fatores que o estudo utilizou como dados de entrada para os métodos propostos. Por fim, a categoria 8 (benefício/desempenho) avalia os resultados obtidos. O sistema de classificação pode ser observado pela Tabela 4.

Tabela 4 - Sistema de classificação e codificação para os artigos analisados.

Classificação	Categoria	Código	Subcategorias
1	Contexto	A	País Desenvolvido
		B	País em Desenvolvimento
		C	Economias em Transições
		D	Não Aplicado
2	Foco	A	Mapeamento da Suscetibilidade
		B	Mapeamento do Perigo
		C	Mapeamento do Risco
		D	Outros
3	Modelo Empregado	A	<i>Machine Learning</i>
		B	Modelos Estatísticos
		C	Análise Multicritério
		D	Outros
4	Método de Pesquisa	A	Quantitativo
		B	Qualitativo
		C	Revisão
		D	Estudo de caso

Tabela 4 - Sistema de classificação e codificação para os artigos analisados (continuação).

Classificação	Categoria	Código	Subcategorias
5	Clima	A	Af
		B	Am
		C	Aw/As
		D	BSh
		E	BSk
		F	BWh
		G	BWk
		H	Cfa
		I	Cfb
		J	Cfc
		K	Csa
		L	Csc
		M	Cwa
		N	Cwb
		O	Dfa
		P	Dfb
		Q	Dfc
		R	Dsa
		S	Dsb
		T	Dwa
		U	Dwb
		V	ET
		X	Todos os Climas
		Z	Não Aplicado
6	Área	A	0 - 1000 km ²
		B	1000 - 10000 km ²
		C	10000 - 20000 km ²
		D	20000 - 40000 km ²
		E	> 40000 km ²
		F	Não Aplicado
7	Fatores Condicionantes	A	Meteorológicos
		B	Antropológicos
		C	Geomorfológicos
		D	Hidrológicos
		E	Não Aplicado
8	Benefício/Desempenho	A	Ambiental
		B	Financeiro
		C	Social
		D	Operacional
		E	Revisão

A categoria “contexto” apresenta subcategorias que definem o cenário de aplicação do estudo. As classificações desses cenários são baseadas na consideração do desenvolvimento econômico local. O desenvolvimento econômico é atrelado ao sistema capitalista e ao acúmulo de riqueza gerado por uma nação e, conseqüentemente, a incorporação do progresso técnico (BRESSER-PEREIRA, 2022; VIEIRA; DOS SANTOS, 2012). Nesse sentido, os locais onde os estudos foram realizados são classificados como países desenvolvidos, em desenvolvimento ou em transição econômica (UNOPS, 2021).

A subcategoria da classe “foco” define três focos principais quanto à inundações, que poderiam ser observados nos artigos, sendo: Suscetibilidade; Perigo; Risco. A suscetibilidade pode ser considerada como uma predisposição ou propensão à ocorrência de um evento (DIAS; TRENTIN; DE SOUZA ROBAINA, 2019). O perigo pode ser definido como um evento que corresponda a uma potencial ação prejudicial, que causará perdas ou danos. O risco pode ser considerado como a probabilidade de ocorrência de um evento natural que gere um desastre multiplicado pelo valor do impacto minimizado pela resiliência local (AITSI-SELMi *et al.*, 2015).

Quanto à análise da categoria de “modelo empregado”, procurou-se verificar quatro subcategorias de modelos generalizados, ML, métodos estatísticos, análises de multicritérios e outros. Os métodos baseados em ML, são baseados em inteligência artificial, esses métodos tendem a identificar e repetir padrões e, com isso, fornecer dados menos subjetivos para os tomadores de decisões (HUANG; ZHU; SIEW, 2006). Os métodos estatísticos têm como premissa assumir variáveis como dados de entrada resultando em uma probabilidade de ocorrência do evento analisado (SPRINTHALL, 2003). Os métodos baseados em análises Multicritérios buscam tratar a complexidade do problema analisado através da decomposição dos fatores que os dimensionam, gerando níveis hierárquicos e, depois, sintetizados de maneira a obter um resultado (ROY; VINCKE, 1981). A subcategoria outros classifica um método que não se enquadre nas demais categorias elencadas.

O “método de pesquisa” demonstra, por meio das subcategorias, qual o critério de pesquisa que conduziram os artigos, como pesquisa quantitativa, qualitativa, revisão e estudo de caso. As análises quantitativas buscam mensurar os dados, permitindo resultados baseados em premissas e regras matemáticas e estatísticas. Em pesquisas qualitativas, os resultados são baseados na interpretação de fatos, de modo a sugerir hipóteses e conceitos (DE LIMA, 1999). A revisão busca analisar estudos com o intuito de demonstrar os resultados obtidos e, ainda, possíveis lacunas oriundas das pesquisas. O estudo de caso

procura aplicar um determinado método em um evento real, ou utilizar-se da aplicação de dados reais, de modo a validar esse método (VERGARA; PECCI, 2003).

Quanto à categoria “clima”, buscou-se avaliar o clima do local onde o estudo foi realizado, baseado no método proposto por Köppen-Geiger. Esse método pressupõe uma classificação baseada na fitossociologia e ecologia da vegetação natural (KOTTEK *et al.*, 2006), como observada na Tabela 5.

Tabela 5 - Classificação climática proposta por Köppen-Geiger.

Clima Médio	Precipitação	Temperatura
A equatorial	W árido	h quente
B seco	S semiárido	k frio
C temperado	f equatorial	a verão quente
D continental	s verão seco	b verão frio
E polar	w inverno seco	c verão frio
	m de moção	d inverno muito frio
		F glacial
		T tundra

A categoria “tamanho da área” traz subcategorias que avaliam o tamanho da área em que o estudo foi realizado. Os “fatores condicionantes” que embasaram o método utilizado nos artigos revisados foram divididos nas seguintes subcategorias:

- Meteorológicos: são fatores conexos a meteorologia como a precipitação anual e período de retorno;
- Antropológicos: correspondem ao tipo de uso e ocupação do solo;
- Geomorfológicos: são fatores condicionantes que descrevem o padrão de relevo correlacionado à estrutura geológica e tipo de solo;
- Hidrológicos: são aqueles relacionados às bacias hidrográficas, refletindo propriedades de drenagem e vazão da bacia.

A categoria “benefício/desempenho” avaliou as consequências que os resultados obtidos pelas pesquisas proporcionaram. Suas subcategorias procuram elencar os resultados em ambiental, financeiro, social e operacional.

No Anexo A encontra-se uma revisão sucinta da contribuição científica dos estudos revisados.

Os critérios assumidos na revisão estruturada condizem com a maioria das estruturas dos artigos analisados, onde existe a proposição de método de mapeamento de áreas suscetíveis a inundações juntamente com a aplicação de um estudo de caso. Baseado nisso, a análise se justifica em evidenciar estudos realizados e métodos consistentes nesse tipo de análise.

4.2 Análise Bibliométrica

A análise quantitativa dos artigos procurou mensurar a contribuição científica e evidenciar a relevância do assunto. Através dos artigos considerados do resultado da busca no banco de dados *Scopus*, verificou-se que o assunto é relativamente novo, sendo o primeiro artigo datado do ano de 2009. Observou-se, ainda, uma tendência de crescimento de publicações nessa área de atuação, conforme aponta Figura 7.

Verifica-se, também, que entre os anos de 2009 a 2012 o assunto não obteve grandes avanços a respeito de publicações. Porém, a partir de 2013 se observa um crescimento, com uma leve oscilação em 2015, e na sequência um crescimento constante em número de publicações. Frisa-se que as pesquisas se deram até o ano de 2022.




Figura 7 - Publicações no campo de estudo de mapeamento de suscetibilidade a inundações.

Um dos métodos utilizados para avaliar o impacto da publicação no meio científico é por intermédio do número de citações. Sendo assim, a Tabela 6 demonstra os dez artigos mais citados no banco de dados *Scopus*.

Tabela 6 - Os dez artigos mais citados no banco de dados *Scopus*.

Autor (Ano)	Número de citações
Tehrany, M.S., Pradhan, B., Jebur, M.N. (2014)	422
Tehrany, M.S., Pradhan, B., Jebur, M.N. (2013)	371
Tehrany <i>et al.</i> (2015)	330
Khosravi <i>et al.</i> (2018)	282
Choubin <i>et al.</i> (2019)	253
Pradhan, B. (2009)	247
Razavi Termeh <i>et al.</i> (2018)	200
Rahmati, O., Pourghasemi, H.R., Zeinivand, H. (2016)	197
Khosravi <i>et al.</i> (2019B)	190
Khosravi <i>et al.</i> (2016A)	189

4.3 Análise das Dimensões

A análise das dimensões procurou avaliar as 8 categorias definidas para classificar os artigos, o resultado sintetizado é demonstrado na Tabela 7. O Anexo A traz de maneira sucinta a contribuição de cada um dos artigos.

Tabela 7 - Resultado da análise de classificação dos artigos.

Estudo	Classificação							
	1	2	3	4	5	6	7	8
Pradhan (2009)	B	AC	B	ABD	C	C	ABCD	BC
Pradhan e Youssef (2011)	B	A	BD	AD	C	C	ABD	BC
Tehrany, Pradhan, Jebur (2013)	B	A	AB	ABD	C	A	ABCD	BC
Tehrany e Jones (2013)	A	A	B	ABD	G	A	BCD	BC
Tehrany, Pradhan, Jebur (2014)	B	A	AB	ABD	C	B	ABCD	C
Tehrany <i>et al.</i> (2014)	A	A	B	ABD	AG	A	ABCD	BC
Yeganeh e Sabri (2014)	B	A	AC	BD	C	B	BCD	BC
Lawal <i>et al.</i> (2014)	B	A	C	ABD	D	A	ABC	BC
Tehrany <i>et al.</i> (2015)	B	A	AB	ABD	C	B	BCD	BC
Tehrany, Pradhan, Jebur (2015)	B	A	AB	ABD	G	A	ABCD	BC
Dhamodaran e Allwyn Raja (2015)	B	A	AB	BD	U	A	ABCD	C
Rahmati, Pourghasemi, Zeinivand (2016)	B	A	B	ABD	EF	C	BCD	BC
Khosravi <i>et al.</i> (2016A)	B	A	BC	ABD	F	B	ABCD	BC
Tien Bui <i>et al.</i> (2016)	B	A	A	ABD	U	B	ABCD	BC
Khosravi <i>et al.</i> (2016B)	B	A	B	ABD	F	B	ABCD	BC
Youssef, Pradhan, Sefry (2016)	B	A	B	ABD	B	A	BCD	BC
Abuzied <i>et al.</i> (2016)	B	AC	B	ABD	B	B	ABCD	BC
Marconi <i>et al.</i> (2016)	B	A	B	ABD	CD	A	ABCD	AC
Lee <i>et al.</i> (2017)	A	A	AB	ABD	I	A	BCD	ABC
Shafapour Tehrany <i>et al.</i> (2017)	C	A	B	ABD	G	B	ABCD	BC
Rahmati e Pourghasemi (2017)	B	A	AB	ABD	B	B	BCD	BC
Haghizadeh <i>et al.</i> (2017)	B	A	B	ABD	EF	B	BCD	BC
Dahri e Abida (2017)	B	C	BC	ABD	B	A	ABCD	C

Tabela 7 - Resultado da análise de classificação dos artigos (continuação).

Estudo	Classificação							
	1	2	3	4	5	6	7	8
Tien Bui e Hoang (2017)	B	A	AB	ABD	U	B	ABCD	C
Sachdeva, Bhatia, Verma (2017)	B	A	AB	ABD	J	B	ABCD	BC
Samela, Manfreda, Troy (2017)	A	A	A	BD	BEFGHKLM NOPQRST	E	ABCD	BC
Stathopoulos <i>et al.</i> (2017)	A	A	C	ABD	K	B	BCD	BC
Tang e Xiao (2017)	C	A	BC	BD	G	B	ABCD	BC
Khosravi <i>et al.</i> (2018)	B	A	A	ABD	F	B	ABCD	BC
Razavi Termeh <i>et al.</i> (2018)	B	A	A	ABD	B	B	ABCD	BC
Hong <i>et al.</i> (2018A)	C	A	AC	ABD	G	A	ABCD	BC
Hong <i>et al.</i> (2018B)	C	A	AB	ABD	G	B	BCD	BC
Shafizadeh-Moghadam <i>et al.</i> (2018)	B	A	AB	ABD	F	B	ABCD	BC
Zhao <i>et al.</i> (2018)	C	A	A	ABD	AEFGHIMNO PRTUV	E	ABCD	BC
Tien Bui <i>et al.</i> (2018)	B	A	AC	ABD	F	B	ABCD	BC
Siahkamari <i>et al.</i> (2018)	B	A	AB	ABD	EF	D	BCD	BC
Mahmoud e Gan (2018A)	B	A	C	ABD	B	D	ABCD	BC
Mahmoud e Gan (2018B)	B	A	C	ABD	B	C	ABCD	BC
Samanta <i>et al.</i> (2018)	B	A	B	ABD	U	B	ABCD	BC
Al-Abadi (2018)	B	A	A	ABD	B	C	BCD	BC
Al-Juaidi, Nassar, Al-Juaidi (2018)	B	A	B	ABD	B	A	ABCD	BC
Tehrany e Kumar (2018)	A	A	B	ABD	G	B	ABCD	BC
Lee <i>et al.</i> (2018)	A	A	B	ABD	I	A	BCD	ABC
Harley e Samanta (2018)	B	A	C	ABD	CD	B	ABCD	BC
Tiryaki e Karaca (2018)	B	A	C	BD	K	A	BCD	C
Sozer <i>et al.</i> (2018)	B	A	C	BD	F	D	BCD	BC
Choubin <i>et al.</i> (2019)	B	A	A	ABD	F	A	BCD	BC
Khosravi <i>et al.</i> (2019A)	C	A	AC	ABD	G	B	ABCD	C
Wang <i>et al.</i> (2019A)	C	A	A	ABD	AGMOP	B	ABCD	BC
Tien Bui <i>et al.</i> (2019A)	B	A	AB	ABD	A	B	ABD	BC
Tien Bui <i>et al.</i> (2019B)	B	A	A	ABD	A	B	ABCD	BC
Ahmadlou <i>et al.</i> (2019)	B	A	AC	ABD	EF	C	ABCD	BC
Janizadeh <i>et al.</i> (2019)	B	A	A	ABD	EF	B	ABCD	BC
Tien Bui <i>et al.</i> (2019C)	B	A	B	ABD	F	B	ABCD	BC
Zhao <i>et al.</i> (2019)	C	A	AB	ABD	FI	B	ABCD	BC
Dano <i>et al.</i> (2019)	B	A	C	ABD	D	A	ABCD	BC
Tehrany, Jones, Shabani (2019)	A	A	A	ABD	G	B	BCD	BC
Pourghasemi <i>et al.</i> (2019)	B	ABC	ABC	ABD	BFH	C	ABCD	BC
Wang <i>et al.</i> (2019B)	C	A	AC	ABD	G	B	ABCD	BC
Kanani-Sadat <i>et al.</i> (2019)	B	A	AC	ABD	FH	D	ABCD	BC
Rahman <i>et al.</i> (2019)	B	A	ABC	ABD	ADJU	E	ABCD	BC
Shafapour Tehrany <i>et al.</i> (2019)	A	A	B	ABD	G	B	BCD	BC
Das (2019)	B	A	C	ABD	HU	B	ABCD	BC
Vojtek e Vojteková (2019)	A	A	C	ABD	OP	E	BCD	C
Sahana e Patel (2019)	B	A	AB	ABD	MU	C	ABCD	BC
Adnan <i>et al.</i> (2019)	B	A	C	BD	U	C	BCD	BC
Tehrany, Kumar, Shabani (2019)	A	A	AB	ABD	GM	B	ABCD	BC
Tien Bui <i>et al.</i> (2019D)	B	A	A	ABD	A	B	ABCD	BC
Hammami <i>et al.</i> (2019)	B	A	C	BD	BHK	A	ABCD	BC
Khosravi <i>et al.</i> (2019B)	C	A	AB	ABD	G	B	ABCD	BC

Tabela 7 - Resultado da análise de classificação dos artigos (continuação).

Estudo	Classificação							
	1	2	3	4	5	6	7	8
Li <i>et al.</i> (2019)	ABC	A	AB	ABD	X	E	ABCD	ABC
Liuzzo, Sammartano, Freni (2019)	A	A	B	ABD	P	B	ABCD	BC
Sheikh, Kornejady, Ownegh (2019)	B	A	AC	ABD	EF	D	ABCD	BC
Muhamad <i>et al.</i> (2019)	B	A	C	BD	C	A	BC	CE
Chen <i>et al.</i> (2020)	C	A	A	ABD	AGMOP	B	ABCD	BC
Tien Bui <i>et al.</i> (2020)	B	A	A	ABD	A	B	ABCD	BC
Shahabi <i>et al.</i> (2020)	B	A	A	ABD	F	B	ABCD	BC
Costache <i>et al.</i> (2020A)	A	A	AC	ABD	QV	B	BCD	BC
Dodangeh <i>et al.</i> (2020A)	B	A	AB	ABD	F	C	ABCD	BC
Chowdhuri, Pal, Chakraborty (2020)	B	A	B	ABD	AU	B	ABCD	BC
Souissi <i>et al.</i> (2020)	B	A	C	ABD	BH	B	ABCD	BC
Bui <i>et al.</i> (2020)	B	A	A	ABD	A	B	ABCD	BC
Wang <i>et al.</i> (2020)	C	A	A	ABD	G	B	ABCD	BC
Pham <i>et al.</i> (2020A)	B	A	A	ABD	EF	B	ABCD	BC
Costache e Tien Bui (2020)	A	A	ABC	ABD	P	A	BC	BC
Ali <i>et al.</i> (2020)	A	A	ABC	ABD	OP	B	ABCD	ABC
Gudiyangada Nachappa <i>et al.</i> (2020)	A	A	ABC	ABD	PV	B	ABCD	C
Talukdar <i>et al.</i> (2020)	B	A	A	ABD	A	B	ABCD	BC
Dodangeh <i>et al.</i> (2020B)	B	A	A	ABD	F	C	ABCD	BC
Pham <i>et al.</i> (2020B)	B	A	A	ABD	D	C	BCD	BC
Tang <i>et al.</i> (2020)	B	A	A	ABD	G	B	ABCD	BC
Pourghasemi <i>et al.</i> (2020)	B	A	A	ABD	AGMOP	B	ABCD	BC
Yanar, Kocaman, Gokceoglu (2020)	B	A	AC	BD	MO	A	BCD	BC
Rahmati <i>et al.</i> (2020)	B	A	AB	ABD	F	A	AB	BC
Das (2020)	B	ABC	C	ABD	DU	B	ABCD	BC
Vafakhah <i>et al.</i> (2020)	B	A	AB	ABD	F	B	ABCD	BC
Yariyan <i>et al.</i> (2020)	B	A	BC	ABD	F	B	ABCD	BC
Nhu <i>et al.</i> (2020)	B	A	A	ABD	A	B	ABCD	BC
Sepehri <i>et al.</i> (2020)	B	A	AC	ABD	BF	A	BCD	BC
Costache, Ngo, Tien Bui (2020)	A	A	ABC	ABD	QV	B	BCD	BC
Mukherjee e Singh (2020)	A	A	C	BD	G	B	ABCD	BC
Abu El-Magd, Amer, Embaby (2020)	B	A	C	BD	B	B	BCD	BC
Swain, Singha, Nayak (2020)	B	A	C	BD	A	B	ABCD	BC
Khosravi <i>et al.</i> (2020)	B	A	A	ABD	BEFH	E	ABCD	BC
Costache <i>et al.</i> (2020B)	A	A	ABC	ABD	PQ	B	ABCD	BC
Zhao <i>et al.</i> (2020)	C	A	A	ABD	F	A	ABCD	C
Arabameri <i>et al.</i> (2020)	B	A	A	ABD	EF	C	ABCD	BC
Shirzadi <i>et al.</i> (2020)	B	A	AB	ABD	F	B	ABCD	BC
Hadipour, Vafaie, Deilami (2020)	B	C	C	BD	E	A	AB	BC
Esfandiari <i>et al.</i> (2020A)	A	A	AD	ABD	P	A	BCD	BC
Tella e Balogun (2020)	B	A	AC	ABD	U	B	ABCD	BC
Mohammadi <i>et al.</i> (2020)	B	A	A	ABD	B	B	ABCD	BC
Braud <i>et al.</i> (2020)	A	A	D	ABD	M	A	BCD	BC
Bouamrane <i>et al.</i> (2020)	B	A	AC	ABD	B	C	ABCD	BC
Cao <i>et al.</i> (2020)	C	A	B	ABD	AG	E	ABCD	BC
Oliveira Campos e Paz (2020)	B	A	B	ABD	U	B	ABCD	BC
Esfandiari <i>et al.</i> (2020B)	A	A	A	ABD	P	A	BCD	BC
Stavropoulos <i>et al.</i> (2020)	A	A	C	ABD	K	A	ABCD	BC
Gudiyangada Nachappa e Meena (2020)	B	A	BC	ABD	A	B	BCD	BC

Tabela 7 - Resultado da análise de classificação dos artigos (continuação).


Estudo	Classificação							
	1	2	3	4	5	6	7	8
Domakinis <i>et al.</i> (2020)	A	A	C	ABD	KU	B	ABCD	BC
Yousefi <i>et al.</i> (2020)	B	AC	AB	ABD	FS	C	ABCD	BC
Kamal <i>et al.</i> (2020)	B	A	B	ABD	B	C	ABCD	BC
Towfiqul Islam <i>et al.</i> (2021)	B	A	A	ABD	ADU	B	ABCD	BC
Arora <i>et al.</i> (2021A)	B	A	A	ABD	A	C	ABCD	BC
Azareh <i>et al.</i> (2021)	B	A	AC	ABD	F	B	ABCD	BC
Mirzaei <i>et al.</i> (2021)	B	A	AB	ABD	F	B	ABCD	C
Pham <i>et al.</i> (2021A)	B	A	AC	ABD	C	B	ABCD	BC
Fang <i>et al.</i> (2021)	C	A	A	ABD	G	B	ABCD	BC
Pham <i>et al.</i> (2021B)	B	A	AB	ABD	C	C	ABCD	BC
Arora <i>et al.</i> (2021B)	B	A	B	ABD	A	C	ABCD	BC
Pham <i>et al.</i> (2021C)	B	A	A	ABD	D	B	BCD	BC
El-Haddad <i>et al.</i> (2021)	B	A	AB	ABD	B	B	BCD	BC
Ahmadlou <i>et al.</i> (2021)	B	A	AB	ABD	AF	B	ABCD	BC
Rahman <i>et al.</i> (2021)	B	A	AC	ABD	A	C	BCD	BCD
Wang <i>et al.</i> (2021)	C	A	AB	ABD	G	B	ABCD	BC
Pham <i>et al.</i> (2021D)	B	A	AC	ABD	C	C	ABCD	BC
Panahi <i>et al.</i> (2021A)	B	A	A	ABD	F	C	ABCD	BC
Malik e Pal (2021)	B	A	B	ABD	U	B	ABC	BC
Avand, Moradi, Ramazanzadeh Lasboyee (2021A)	B	A	A	ABD	F	B	ABCD	BC
Shahabi <i>et al.</i> (2021)	B	A	ABC	ABD	F	B	ABCD	BC
Panahi <i>et al.</i> (2021B)	B	A	A	ABD	EF	C	ABCD	BC
Feizizadeh, Gheshlaghi, Tien Bui (2021)	B	A	AB	ABD	F	A	ABCD	BC
Avand, Moradi, Ramazanzadeh Lasboyee (2021B)	B	A	A	ABD	F	B	ABCD	BC
Msabi e Makonyo (2021)	B	A	C	BD	ABCHJ	E	BCD	BC
Kalantar <i>et al.</i> (2021)	A	A	A	ABD	GM	B	ABCD	BC
Ngo <i>et al.</i> (2021)	B	A	AB	ABD	A	A	ABCD	BC
Das e Gupta (2021)	B	A	C	ABD	U	D	ABCD	BC
Chou <i>et al.</i> (2021)	B	A	A	ABD	A	B	ABCD	BC
Prasad <i>et al.</i> (2021)	B	A	AB	ABD	CU	A	ABCD	BC
Ding <i>et al.</i> (2021)	D	D	D	C	Z	F	E	E
Ahmed, Hewa, Alrajhi (2021)	A	A	C	ABD	K	B	BD	BC
Abedi <i>et al.</i> (2021)	A	A	AB	ABD	PQ	A	BCD	BC
Vojtek <i>et al.</i> (2021)	A	A	BC	ABD	OP	B	BCD	BC
Natarajan <i>et al.</i> (2021)	B	A	A	ABD	U	A	ABC	BC
Malik <i>et al.</i> (2021)	B	A	ABC	ABD	AU	B	ABCD	BC
Malekinezhad <i>et al.</i> (2021)	B	A	D	ABD	F	A	BCD	BC
Luu <i>et al.</i> (2021A)	B	A	A	ABD	D	A	ABCD	BC
Chakraborty <i>et al.</i> (2021)	B	A	A	ABD	U	A	ABCD	BC
Ha <i>et al.</i> (2021)	B	A	A	ABD	A	B	ABCD	BC
Goumrassa <i>et al.</i> (2021)	B	A	C	ABD	K	A	ABCD	BC
Darabi <i>et al.</i> (2021A)	B	A	AB	ABD	F	A	ABCD	BC
Janizadeh <i>et al.</i> (2021)	B	A	A	ABD	F	A	ABCD	BC
Darabi <i>et al.</i> (2021B)	B	A	A	ABD	F	A	ABCD	BC
Luu <i>et al.</i> (2021B)	B	AD	A	ABD	D	A	ABCD	BC
Narimani <i>et al.</i> (2021)	A	A	C	ABD	I	A	ABCD	BC
Mudashiru, Sabtu, Abustan (2021)	D	D	D	C	Z	F	E	E

Tabela 7 - Resultado da análise de classificação dos artigos (continuação).

Estudo	Classificação							
	1	2	3	4	5	6	7	8
Das e Scaringi (2021)	B	A	C	ABD	HU	D	ABCD	BC
Costache <i>et al.</i> (2021)	A	A	A	ABD	PQ	B	ABCD	BC
Islam, Tahir, Parveen (2021)	B	A	B	ABD	G	B	ABCD	BC
Irawan <i>et al.</i> (2021)	B	A	B	ABD	CDU	A	ABCD	BC
Shahiri Tabarestani e Afzalimehr (2021)	B	A	ABC	ABD	F	D	ABCD	BC
Santos, Pinheiro, Gallo Junior (2021)	B	A	D	ABD	GM	A	ABCD	BC
Pandey <i>et al.</i> (2021)	B	A	AB	ABD	G	C	ABCD	BC
Aprilia e Hidayah (2021)	B	A	B	ABD	DU	A	ABCD	BC
Stamellou <i>et al.</i> (2021)	A	A	C	ABD	K	A	ABCD	BC
Suppawimut (2021)	B	A	B	ABD	U	A	ABCD	BC
Hang <i>et al.</i> (2021)	B	A	B	ABD	A	A	ABCD	D
Wubalem <i>et al.</i> (2021)	B	A	BC	ABD	AF	A	ABCD	BC
Masoumi (2021)	B	A	C	ABD	F	A	BD	D

4.3.1 Contexto

A categoria “contexto” apresenta subcategorias que definem o cenário de aplicação do estudo. As classificações desses cenários são baseadas na consideração do desenvolvimento econômico local. A análise do contexto verificou que 72,07% da produção científica referente a mapeamento de suscetibilidade a inundações foram produzidos em países em desenvolvimento. Em países desenvolvidos foram contabilizados 32 estudos, conforme a Figura 8.

**Figura 8** - Resultado da análise de contexto.

É possível verificar a quantidade de estudos desenvolvidos em cada país, conforme a Figura 9. O país que mais gerou estudos de casos foi o Irã seguido de Índia e China.




Figura 9 - Localidade de aplicação dos métodos propostos pelos artigos revisados.

No continente americano, seis estudos foram verificados pela revisão. Desses, quatro deles foram realizados nos Estados Unidos da América (EUA) e Canadá, com dois estudos cada. O destaque foi a pesquisa de Samela, Manfreda, Troy (2017), que por meio de dados geomorfométricos, mapeou as áreas propensas a inundações em todo os EUA,

apresentando um mapa que pode ser considerado de nível continental, com resolução de 30m.

Em território nacional, a revisão estruturada identificou dois estudos: o primeiro publicado por Oliveira Campos e Paz (2020). A pesquisa aplicou Análise Fractal (*Fractal Analysis*) em Itaperuna, Rio de Janeiro, objetivando avaliar a suscetibilidade a inundações locais com base em inundações históricas permanentes (cheias naturais) e inundações transitórias. O segundo estudo, Santos, Pinheiro, Gallo Junior (2021), foi aplicado em São Luiz do Paraitinga, São Paulo, utilizando-se do *Height Above the Nearest Drainage* (HAND) para mapear áreas suscetíveis a inundações. Ambos os locais no Brasil apresentam históricos negativos relacionados às inundações e, de maneira geral, essas pesquisas tendem a minimizar os impactos negativos gerados pelas inundações.

4.3.2 Foco

A subcategoria da classe “foco” define três focos principais quanto às inundações, que podem ser observados nos artigos, sendo: Suscetibilidade; Perigo; Risco. Por vezes, os termos são utilizados de maneira equivocada, o que justifica a revisão.

A análise de foco verificou que quatro pesquisas que utilizavam o termo “*Susceptibility*” definindo como o objetivo do artigo realizaram o mapeamento de perigo e risco (Figura 10).




Figura 10 - Resultado da análise de foco.

Com base na análise é possível observar ainda estudos que se utilizam do mapeamento de áreas suscetíveis a inundações como base para mapear perigo e riscos associados a inundações, exemplo disso são os estudos de Pourghasemi *et al.* (2019) e Das (2020).

4.3.3 Modelo Empregado

A avaliação dos modelos empregados nas pesquisas demonstrou que os mapeamentos de suscetibilidade a inundações são realizados de modo diversificado.

O mesmo artigo aplica diversos modelos nos mapeamentos para reforçar e validar o proposto. Porém, modelos baseados em ML são dominantes, encontrando-se em cerca de 61% nos estudos avaliados.

O resultado da avaliação dos modelos empregados é observado na Figura 11.




Figura 11 - Resultado da análise de modelo empregado.

4.3.4 Método da Pesquisa

As pesquisas demonstraram o uso majoritário dos métodos compostos de dados quali-quantitativo aplicados ainda em um estudo de caso, valor correspondente a cerca de 90% em do total.

De maneira geral, os estudos de caso são empregados para validação do método proposto. Quase sempre essa validação é relacionada ainda com outros modelos de análise, conforme a Figura 12.




Figura 12 - Resultado da análise de métodos de pesquisa.

4.3.5 Clima Local

O clima que apresenta maior frequência de emprego é o Seco Árido Quente (BWh) (16,20%) seguidos do Seco Árido Frio (BWk) (10,61%) e Tropical Equatorial (Af) (8,94%), como demonstra a Figura 13.

Os climas mais abordados podem ser associados aos locais que apresentem economias em desenvolvimentos e consequentemente a falta de infraestruturas adequadas em funções das características das precipitações pluviométricas.

A ocorrência de um único clima presente no estudo pode ser relacionada diretamente ao tamanho da área analisada na pesquisa.




Figura 13 - Resultado da análise de clima local.

4.3.6 Tamanho da Área

Assim como o clima, a análise das áreas em que os estudos foram aplicados procurou demonstrar a efetividade em relação ao método e modelo empregado (Figura 14).

Cerca de 50% das pesquisas que aplicaram o método em um estudo de caso, utilizaram-se de áreas entre 1.000 a 10.000 km²





Figura 14 - Resultado da análise de tamanho de área.

4.3.7 Fatores Condicionantes

Os fatores condicionantes podem definir o sucesso do estudo, pois são eles que quantificam a suscetibilidade a inundação de um local. Questão importante é que fatores condicionantes podem apresentar relevâncias diferentes em função da área de aplicação de estudo.

A Figura 15 mostra que cerca de 75% dos estudos analisados utilizaram-se do conjunto de fatores condicionantes relacionados à meteorologia, antropologia, geomorfologia e hidrologia.



Fatores Condicionantes

A - Meteorológicos

B - Antropológicos

C - Geomorfológicos

D - Hidrológicos

E - Não Aplicado

Figura 15 - Resultado da análise de fatores condicionantes.

Os 15 fatores condicionantes mais utilizados são demonstrados na Tabela 8.

Tabela 8 - Os 15 fatores condicionantes mais empregados.

Fatores Condicionantes	Porcentagem
Inclinação	96,6
Altitude	94,3
Cobertura da terra e uso do solo	85,2
Distância interfluvial	76,1
Precipitação pluviométrica	74,4
Embasamento geológico	73,9
Curvatura	69,3
Índice de umidade topográfica (TWI)	67,0
Solo	50,0
Orientação das vertentes	46,6
Densidade de drenagem	44,9
Índice de potência de fluxo (SPI)	43,8
Índice de vegetação por diferença normalizada (NDVI)	26,1
Distância de estradas	15,3
Acúmulo de fluxo	15,3

4.3.8 Benefício/Desempenho

O benefício e o desempenho que os trabalhos concluíram quase sempre estão atrelados a uma questão financeira e social, correspondendo a uma parcela de 90% do total, conforme Figura 16.




Figura 16 - Resultado da análise de benefício/desempenho.

4.4 Consideração da Revisão Bibliométrica

Relato de eventos naturais de inundação são observados desde a antiguidade (KJELDSEN *et al.*, 2014). Já os estudos de mapeamento de áreas suscetíveis a inundações são mais recentes, podendo ser ligados diretamente aos avanços e ao acesso à tecnologia, em especial a tecnologia SIG e aos softwares de análise espacial e análise de dados. A tecnologia SIG juntamente com o sensoriamento remoto permite em ter dados da superfície terrestre, com alta precisão e de grandes áreas. Acoplado a softwares de análise de dados, os estudos hidrogeomorfológicos apresentam grandes evoluções de quantidade e qualidade.

Os softwares mais observados de sensoriamento remoto foram ArcGIS, QGIS e SAGA GIS. Quanto aos satélites, existe a limitação do satélite que orbita a respectiva região de estudo. Porém, os mais citados são Landsat (7 ETM e 8 OLI) e Sentinel (1 e 2). Os softwares para mapeamento de áreas suscetíveis a inundações mais utilizados são os contidos no próprio ArcGIS (análise Multicritério e mais recentemente análise estatística e baseadas em ML), e softwares com linguagem R, MATLAB e Python, esses mais utilizados para análises estatísticas e ML.

O modelo empregado para analisar áreas propensas a inundações apresenta um avanço no decorrer do tempo. Uma parte dos primeiros estudos avaliados tinham base na análise Multicritério, um método semiquantitativo, que fornece uma estrutura de tomada de decisão. Sucintamente, a análise Multicritério se utiliza da adoção de pesos para classificar os fatores condicionantes. O mapa final é obtido através da estruturação dos fatores condicionantes ponderados. Apresenta como vantagem a facilidade de implementação. A sua desvantagem é a subjetividade, já que a ponderação é realizada através de raciocínio humano. Dentre os estudos analisados que se utilizam de algum modelo baseado em análise Multicritério destaca-se Khosravi *et al.* (2019A) (*Simple Additive Weighting – SAW*), Mahmoud e Gan (2018A) (*Analytical Hierarchy Process – AHP*) e Costache *et al.* (2020A) (AHP).

As análises por meio de modelos estatísticos têm base na matemática e na estatística, também são observados nas primeiras publicações como em Pradhan (2009) com o uso de *Frequency Ratio – FR* e Pradhan e Youssef (2011) utilizando-se de *Probability Density Moisture – PDM* e *Evidential Belief Function – EBF*. Modelos estatísticos apresentam boa capacidade preditiva, mas em contrapartida podem apresentar processamentos custosos e modelos complexos para aplicação em mapeamento de áreas suscetíveis a inundações.

Modelos baseados em ML compõem cerca de 61% das publicações revisadas. ML se baseia em Inteligência Computacional, a qual tem como premissa desenvolver modelos capazes de assimilar conceitos e conhecimentos com base em uma determinada amostra de dados (MITCHELL, 1997). As vantagens de modelos ML mais comuns são eliminação da subjetividade, possibilidade de incorporação de outros modelos e alta eficiência de previsão. Como desvantagem o ML pode apresentar um alto custo computacional e dependências de conjuntos de dados de treinamento otimizados. Dos estudos analisados é possível ver a evolução dos modelos ML empregados, temos o emprego de *Decision Trees – DT* por

Tehrany, Pradhan, Jebur (2013); o *Support Vector Machine* – SVM por Tehrany, Pradhan, Jebur (2015) e modelos ML mais modernos e híbridos como *AdaBoostM1 based Credal Decision Tree* – ABM-CDT, *Radom Subspace* – RS, *Dagging* e *Bagging* sendo aplicados em conjunto por Luu *et al.* (2021B).

A eficiência do modelo ML pode ser vista através da análise AUC, nos estudos de Ha *et al.* (2021) que por meio de modelos ML híbridos MBREPT (*MultiBoostAB-REPT*) obteve a eficiência AUC = 0.992 e DCREPT (*Decorate-REPT*) AUC = 0.991, e, no estudo de Costache *et al.* (2021) com AUC *Random Forest* (RF) = 0.996.

O foco demonstra estudos que se baseiam no mapeamento de áreas suscetíveis a inundações para avaliar o perigo e risco. Sendo assim, o presente estudo pode ser base de mapeamento de áreas de perigo e risco associados a inundações.

A análise de contexto demonstra que o mapeamento de suscetibilidade a inundações tem maior aplicação em países em desenvolvimento. O grande destaque é o Irã com 46 estudos de mapeamento de áreas suscetíveis a inundações, fato relacionado à concentração de grande parte dos pesquisadores que trabalham com esse assunto. A aplicação de 72.07% dos estudos em países em desenvolvimentos. Pode ser vinculada à ideia de falta de infraestrutura que permita maior resiliência local.

A análise de contexto demonstra ainda que algumas localidades não apresentam estudos de mapeamento de suscetibilidade a inundações. Outros aspectos importantes são a morfologia e o clima local dos países que apresentam estudos de mapeamentos de áreas suscetíveis. Esses locais quase sempre se caracterizam como terrenos acidentados com climas desérticos, áridos e semiáridos com recorrência de precipitações intensas e climas tropicais com presença de estações chuvosas. Salienta-se que nos últimos anos outras localidades apresentaram estudos, fato que pode ser atribuído à mudança climática. Relacionando-se a caracterização da área do estudo de caso a categoria Área, não é um impeditivo do sistema de obtenção dos mapas de suscetibilidade a inundações, visto os modelos empregados, exemplo disso é o estudo de Li *et al.* (2019) que obteve em seu estudo o mapa global.

Quanto ao método de pesquisa, tratando-se da palavra-chave “*Flood Susceptibility Mapping*” era de se esperar muitos estudos de casos. O estudo de caso aplicado em mapeamento de áreas suscetíveis a inundações é uma maneira de qualificar a efetividade do modelo proposto e ainda obter como resultado um mapa que pode ser utilizado como ferramenta de gestão pública.

As lacunas encontradas nos estudos ficam a cargo da dificuldade da obtenção dos fatores condicionantes e do desempenho e benefício alcançado. Os fatores condicionantes demonstram ser o item de maior dificuldade de obtenção, principalmente em países em desenvolvimento. O SIG e o sensoriamento remoto permitiram um avanço quanto aos fatores condicionantes relacionados à superfície terrestre, como por exemplo a cobertura da terra e uso do solo, a altitude e a inclinação. Porém, quando se trata de questões pertinentes à geomorfologia e hidrologia encontram-se certas restrições de informações em determinados locais, o que pode ser um impeditivo na realização desses estudos.

A maior lacuna encontrada é em relação ao benefício alcançado. Nesta revisão cerca de 98% citam ganhos sociais e financeiros. Porém, existe a possibilidade/necessidade da verificação do impacto da aplicação dos mapas de suscetibilidade a inundações gerados, e quanto à possibilidade de analisar-se os benefícios ambientais que o mapa proporciona. Ainda faltam informações de como é possível aplicar o mapa gerado como uma ferramenta de gestão pública.

5. CARACTERIZAÇÃO DA ÁREA DE ESTUDO

O mapeamento de áreas suscetíveis a inundação é aplicado na região que compreende a Bacia Hidrográfica do Rio Sorocaba e Médio Tietê (BH-SMT). A BH-SMT está situada no Estado de São Paulo, região sudeste do Brasil, conforme apresenta Figura 17.




Figura 17 - Localização da Bacia Hidrográfica do Rio Sorocaba e Médio Tietê (BH-SMT) e divisão hidrográfica nacional.

Fonte: Otero, 2009.

A área da bacia hidrográfica é de 11.829 km² e está localizada entre o Planalto Atlântico e a Depressão Periférica Paulista. O primeiro apresenta altitudes mais elevadas, altas declividades e vales encaixados a sudeste. Já a Depressão Periférica Paulista é composta por relevo suave e colinas amplas (OTERO, 2009). A altimetria da bacia varia entre 393 a 1.301 metros.

O quadrante que engloba a BH-SMT está alocado entre as latitudes 46°52'30" e 48°22'51,6" ao sul do Equador e longitudes 22°29'45,6" e 23°50'45,6" a oeste de Greenwich, conforme demonstrado pela Figura 18.




Figura 18 - Detalhe de localização BH-SMT.

De acordo com a classificação do clima proposto por Köppen-Geiger na BH-SMT, verifica-se três tipos climáticos: clima úmido quente com inverno seco (Cwa), predominante a oeste da cidade de Sorocaba; o clima quente úmido sem estação seca (Cfa), próximo aos municípios de Ibiúna e Piedade; e o clima temperado úmido sem estação seca, próximo ao município de São Roque (Cfb). A precipitação tem média anual em torno de 1.200 mm e temperatura média variando entre 18 a 22 °C (IPT, 2005).

Historicamente, essa região vem apresentando papel fundamental na colonização e em avanços socioeconômicos do Brasil. Tendo como ponto de partida a cidade de São Paulo, o rio Tietê foi o principal meio de acesso para explorar e colonizar o interior do Estado de São Paulo e desbravar o centro do Brasil.

O rio Tietê em sua totalidade tem cerca de 1.100 km de extensão, com a nascente situada em Salesópolis e desague no rio Paraná em Itapura e, devido à boa parte ser navegável, justificou o seu uso. Apenas as corredeiras e saltos localizados entre os municípios de Santana do Parnaíba e Salto, cidades localizadas no estado de São Paulo, obrigavam os desbravadores da época a realizar esse trecho do percurso por terra.

O rio Sorocaba, apresentando-se como o maior afluente à margem esquerda do rio Tietê, com comprimento de 277 km, também teve participação importante na colonização local (OTERO, 2009). Atualmente, a região apresenta papel importante na economia do país, demonstrando atividades industriais no ramo alimentício, metalúrgico e extrativista, e no ramo agrícola, pelos cultivos de cana-de-açúcar, milho, hortaliças e pastagem (INVEST SP, 2022).

A bacia hidrográfica é composta por 34 municípios com sede nesta, somando uma população estimada de 2.298.550 habitantes (IBGE, 2022). As cidades e suas respectivas populações podem ser observadas na Tabela 9.

Tabela 9 - Número de habitantes por município com sede na BH-SMT.
Fonte: IBGE, 2022.

Município	Habitantes	Município	Habitantes
Alambari	6.231	Laranjal Paulista	29.047
Alumínio	18.903	Mairinque	47.723
Anhembi	6.911	Pereiras	8.875
Araçariguama	23.343	Piedade	55.731
Araçoiaba da Serra	35.389	Porangaba	10.205
Bofete	12.107	Porto Feliz	53.698
Boituva	63.310	Quadra	3.902
Botucatu	149.718	Salto	120.779
Cabreúva	51.130	Salto de Pirapora	46.285
Capela do Alto	21.257	São Roque	93.076
Cerquillo	50.631	Sarapuí	10.493
Cesário Lange	18.595	Sorocaba	695.328
Conchas	18.138	Tatuí	124.134
Ibiúna	80.062	Tietê	42.946
Iperó	38.771	Torre de Pedra	2.432
Itu	177.150	Vargem Grande Paulista	54.315
Jumirim	3.467	Votorantim	124.468
Total de habitantes		2.298.550	

Para garantir a qualidade e o gerenciamento das águas do Estado de São Paulo, o território paulista foi subdividido em 22 Unidades de Gerenciamento de Recursos Hídricos (UGRHI), as quais correspondem a divisões do Estado em bacias hidrográficas.

A gestão local de cada bacia é realizada pelo Comitê de Bacia Hidrográfica (CBH). Sua composição é dada por um grupo de técnicos vinculados a órgãos competentes, profissionais da área ligados a instituições de ensino, representantes de prefeituras e

membros representantes da sociedade civil. A BH-SMT é representada pela UGHRI de número 10 (DA COSTA *et al.*, 2016).

6. ROTEIRO METODOLÓGICO

A primeira etapa do estudo consiste no levantamento de dados que são base para a validação do método e a realização do estudo de caso. Os dados coletados dizem respeito ao inventário de inundações e aos fatores condicionantes da BH-SMT. A confecção dos fatores condicionantes foi realizada por meio de SIG, especificamente pelo *software* livre QGIS (QGIS, 2022). Com base nos dados levantados de inundações e dos fatores condicionantes, o modelo de mapeamento de suscetibilidade a inundações foi gerado, inicialmente, pelo modelo AHP-TOPSIS-2N modificado e via SVM realizado através do complemento Dzezsaka. Ambos os métodos foram aplicados se utilizando do *software* QGIS.

Uma ideia geral sobre o roteiro metodológico aplicado no mapeamento de áreas suscetíveis a inundações é verificada no fluxograma apresentado na Figura 19.




Figura 19 - Fluxograma: modelo de mapeamento de suscetibilidade de inundação via SVM e via AHP-TOPSIS-2N modificado.

O *hardware* e os *softwares* utilizados para implementação dos modelos propostos apresentavam as seguintes configurações:

- Processador: 11th Gen Intel Core i7-11800H @ 2.30GHz;
- Memória RAM: 16,0 GB;
- Placa de Vídeo: RTX 3070;
- Sistema operacional: Windows 11;
- *Software* QGIS: versão 3.22.0.

6.1 Inventário do Histórico de Inundações e Não Inundações

O inventário de inundações é um ponto importante para definir a relação mútua entre a ocorrência de inundação e seus impulsionadores. Os eventos históricos de inundação são considerados como a base de previsão da ocorrência de inundações futuras (POURGHASEMI; BEHESHTIRAD, 2015). O levantamento histórico foi realizado com auxílio do Banco de Dados de Desastres Naturais do Instituto Nacional de Meteorologia (IPMet), catálogo de informações ambientais do Sistema Ambiental Paulista - DataGEO e visitas técnicas em campo.

Elaborado no ano de 2015, na plataforma web do IPMet, o banco de dados detalha e quantifica eventos severos ocorridos em municípios do Estado de São Paulo e Paraná. Os dados encontrados no banco são relacionados à boletins de ocorrência da Defesa Civil, notícias veiculadas na mídia e de observadores voluntários. O banco de dados foi elaborado de forma a fornecer os danos ocorridos, os fenômenos atmosféricos causadores, localização, data e horário dos eventos.

Os fenômenos atmosféricos são codificados como granizo, ventos fortes/vendavais, chuvas fortes, raios, tornado, ciclone, frente fria/chuvas contínuas e chuvas moderadas. Os danos e ocorrências foram quantificados em 36 grupos distintos: número de desabrigados, vítimas fatais, feridos, quedas (de muros, barreiras, poste e torres), inundação em via pública, enchentes, escorregamento e deslizamento de terra, erosões e outros (IPMET, 2019). A interface do banco de dados permite ao usuário buscar por fenômenos e danos distintos em datas e cidades específicas, a busca é executada de acordo com os parâmetros de pesquisa.

Os dados podem ser visualizados *online*, bem como baixados em formato de arquivo texto (extensão “*.txt”). Fato importante é que ainda que a data de início disponível no sistema seja o ano de 1967, para as cidades que compõe a BH-SMT, as informações estão dispostas a partir de 01/12/2002.

Outra fonte de dados utilizada é o catálogo de informações ambientais DataGEO, que apresenta a infraestrutura de referências espaciais ambientais do Estado de São Paulo. Através dele é possível ter acesso a grandes volumes de informações, como abastecimento de água, geologia, monitoramento ambiental, riscos naturais, dentre outros, produzidos por diferentes instituições (DATAGEO, 2019).

Os dados de áreas não inundáveis e parte do histórico de inundações contaram com o levantamento de dados de campo, através de visitas técnicas realizadas na BH-SMT. As informações de campo foram criteriosamente levantadas com base na hidrogeomorfologia local, permitindo ainda a validação de pontos demonstrados pelos bancos de dados utilizados. As informações de pontos de inundações e de áreas não inundáveis inventariadas serão utilizadas para treinamento do modelo SVM e na validação dos dois modelos de mapeamento propostos.

6.2 Fatores Condicionantes

Os fatores condicionantes se baseiam em dados obtidos através de sensoriamento remoto e da ferramenta SIG. O levantamento de dados para confecção dos mapas na plataforma QGIS foi elaborado por meio de consulta de banco de dados de órgãos e agências, como Instituto de Pesquisas Tecnológicas (IPT), Serviço Geológico do Brasil – Companhia de Pesquisa de Recursos Minerais (CPRM), Banco de Dados Geomorfométricos do Brasil – TOPODATA, Instituto Nacional de Dados Espaciais (INDE), *The European Space Agency*, bem como entidades envolvidas no gerenciamento de dados da BH-SMT, como o Comitê da Bacia Hidrográfica do Rio Sorocaba e Médio Tietê (CBH-SMT) e Fundação Agência da Bacia Hidrográfica do Rio Sorocaba e Médio Tietê (FABH-SMT).

A seleção de fatores de condicionamento de inundação é um dos pré-requisitos para o mapeamento de suscetibilidade a inundações e é norteadada através de extensas revisões da literatura, parte observada na revisão estruturada concretizada no Capítulo 4 desta tese. Sendo assim, inicialmente, utilizou-se os fatores condicionantes elencados a seguir. Ressalta-se que o fator condicionante de Precipitação Pluviométrica, com evidências de uso frequente de acordo a revisão estruturada realizada, é dispensado deste estudo de avaliação de áreas suscetíveis a inundações em função do entendimento de que a intensidade de precipitação, atribuída a um período de retorno, tem melhor emprego em um mapeamento

de risco, visto a probabilidade de ocorrência associada. Os fatores condicionantes selecionados são elencados a seguir:

- Altimetria: o mapa temático de altimetria da BH-SMT foi elaborado a partir do Modelo de Elevação Digital (*Digital Elevation Model* – DEM), obtido através do Banco de Dados Geomorfométricos do Brasil – TOPODATA, com escala de 1:250.000;
- Inclinação: o mapa temático de inclinação se baseia no DEM e no mapa temático de altitude, com resolução de 30 metros;
- Orientação das vertentes: a direção da inclinação da superfície do terreno fundamenta-se a partir do DEM e da carta de inclinação, com resolução de 30 metros;
- Curvatura: a curvatura da superfície terrestre é obtida a partir do DEM e das cartas de inclinação e orientação das vertentes, apresentando resolução de 30 metros;
- Distância interfluvial: a confecção desta carta é baseada no mapa hidrográfico do Estado de São Paulo, realizado pelo IBGE (1982) com escala de 1:50.000;
- TWI: a confecção dessa carta fundamenta-se no DEM e na carta de inclinação realizada *a priori* da BH-SMT, utilizando-se da Equação (1), conforme demonstrada no Capítulo 3. Os mapas empregados apresentam resolução de 30 metros.
- Densidade de drenagem: a carta de densidade de drenagem baseia-se na carta hidrográfica vetorizada da BH-SMT e no DEM, com resolução de 30 metros;
- Solo: a carta foi elaborada a partir do mapa temático de tipos do solo do Estado de São Paulo, elaborado em 2017, com escala de 1:250.000 (ROSSI, 2017);
- Grupos hidrológicos do solo (*Soil Hydrological Groups* – SHG): indica a taxa de infiltração de água. Os grupos hidrológicos do solo são classificados em quatro grupos: A, B, C e D. Os solos do grupo A compreendem aqueles com baixo potencial de escoamento e alta taxa de infiltração uniforme quando completamente molhados, consistindo, principalmente, de areias ou

cascalhos, ambos profundos e excessivamente drenados. Solos do grupo A apresentam taxa mínima de infiltração: $> 7,62$ mm/h. Os solos classificados no grupo B demonstram moderada taxa de infiltração quando completamente molhados, constituindo-se, sobretudo, de solos moderadamente profundos a profundos, moderadamente a bem drenados, com textura moderadamente fina a moderadamente grossa; Apresentando taxa mínima de infiltração de 3,81 a 7,62 mm/h, solos do grupo C demonstram baixa taxa de infiltração quando completamente molhados, com camadas que dificultam o movimento da água através das camadas superiores para as inferiores, ou com textura moderadamente fina e baixa taxa de infiltração; Taxa mínima de infiltração: 1,27 a 3,80 mm/h. Os solos do grupo D possuem alto potencial de escoamento, tendo uma taxa de infiltração muito baixa quando completamente molhados, são caracterizados, especialmente, por solos argilosos com alto potencial de expansão. Pertencem a este grupo: solos com grande permanência de lençol freático elevado, solos com argila dura ou camadas de argila próxima da superfície e solos expansivos agindo como materiais impermeabilizantes próximos da superfície; Taxa mínima de infiltração: $< 1,27$ mm/h (SARTORI; LOMBARDI NETO; GENOVEZ, 2005). A carta foi baseada de acordo com o mapeamento do tipo de solo do Estado de São Paulo, elaborado em 2017, com escala de 1:250.000 (ROSSI, 2017);

- Embasamento geológico: a obtenção da carta de embasamento geológico realizou-se através do mapeamento realizado pelo IPT, no ano de 1981, com escala de 1:500.000;
- Cobertura da terra e uso do solo: a construção do mapa de cobertura da terra e uso do solo tem por base as imagens do Satélite Sentinel-2A (S2A), com resolução de até 10 metros. As imagens foram obtidas através do banco de dados do Google Earth Engine. O S2A é um Satélite lançado com a missão de capturar imagem multiespectral por meio do sensor *Multispectral Imager* – MSI de alta resolução e ampla faixa, com uma frequência global de revisita de 5 dias (DRUSCH *et al.*, 2012). O S2A apresenta 13 bandas espectrais, fornecendo dados adequados para avaliar o estado e a mudança da vegetação, da cobertura do solo e de água (ESA, 2022). A ferramenta

utilizada para confecção do mapa temático de cobertura da terra e uso do solo no QGIS foi o *Semi-Automatic Classification Plugin* (CONGEDO, 2013). A validação contou com dados levantados em campo durante visitas técnicas realizadas na BH-SMT, para identificação e nomeação das classes de cobertura da terra e uso do solo. Ao todo, foram cinco classes geradas: área urbanizada, lavoura, pastagem, vegetação e corpos hídricos.

Os fatores condicionantes são demonstrados por meio de cartas, as quais serão realizadas no Sistema de Coordenadas Geográficas e Datum: *World Global Sytem* – 1984. As coordenadas são alocadas entre as latitudes 46°52'30" e 48°22'51,6" ao sul do Equador e longitudes 22°29'45,6" e 23°50'45,6" a oeste de *Greenwich*.

6.3 Mapeamento Via AHP-TOPSIS-2N Modificado

A aplicação inédita do modelo Multicritério, o AHP-TOPSIS-2N modificado, teve como objetivo, em um primeiro momento, verificar sua eficiência e aplicabilidade e, na sequência, comparar os resultados gerados com o do modelo baseado em ML (SVM).

Neste estudo, o método de mapeamento de áreas suscetíveis a inundações por meio de análise Multicritério AHP-TOPSIS-2N modificado consiste, inicialmente, na combinação da ferramenta SIG através do *software* QGIS. O modelo considerou como critérios de entrada os 11 (onze) fatores condicionantes, os quais foram ponderados via AHP. Os pesos são atribuídos para cada fator condicionante, respectivamente, a dimensão de maior peso aos aspectos que proporcionem uma maior suscetibilidade a inundações. A validação da ponderação é verificada por meio da Razão de Consistência (RC), conforme mostra a Equação (13).

Validada a ponderação dos critérios, aplicou-se aplica o TOPSIS para realizar a ordenação final dos resultados. O 2N modificado que compõe a nomenclatura faz relação as duas normalizações aplicadas conforme Equação (15), que normaliza os critérios sem proporcionalidade e Equação (16), a qual é modificada em relação a equação que considera a proporcionalidade empregada originalmente pelo método. A modificação da equação que considera a proporcionalidade é justificada em função dos melhores resultados apresentados.

Ressalta-se que a aplicação de duas normalizações gera dois resultados distintos, com a tendência de que um deles apresente maior eficiência. Os resultados são validados por meio do histórico de inundações.

6.4 Mapeamento Via SVM

O modelo SVM, após treinamento supervisionado, permite prever dados por classificação. Neste estudo, o SVM é utilizado para classificar áreas de inundações e não inundações, com base em treinamento utilizando-se do histórico de inundações. A aplicação do SVM foi realizada por meio do QGIS, especificamente, pelo *plugin* Dzetsaka (KARASIAK, 2016), versão 3.70, lançada no ano de 2021.

O treinamento foi executado por meio da participação aleatória dos dados inventariados de inundações (NAIMI; ARAÚJO, 2016). As porcentagens dos históricos de inundação e não inundação utilizadas no mapeamento são de 70% para treinamento e de 30% para validação.

Os parâmetros utilizados para treinamento e classificação são:

- Parâmetro de regularização: $C = 10,0$ (flexibiliza as margens de separação, quanto maior o valor, mais rígida é a margem);
- *kernel*: *Radial Basis Function*;
- *Gamma*: $2,0$ (pondera a distância euclidiana quadrática entre duas amostras, permitindo mais flexibilidade ao modelo).

O treinamento e a classificação são realizados de maneira individual para cada fator condicionante, utilizando-se das classes 0 para não inundação e 1 para inundação. O resultado gerado de cada fator condicionante gera um arquivo de extensão “*.rst” em que o *pixel* apresenta valor binário, ou seja, inundação ou não inundação.

Classificados todos os fatores condicionantes, é realizada a somatória dos valores dos *pixels* classificados para cada coordenada geográfica. Na sequência, é aplicada a Equação (16) normalizando de maneira correlacionada. O resultado é um mapa de suscetibilidade a inundação, no qual a faixa de valores gerados nos *pixels* são divididos em cinco categorias de iguais dimensões: - Muito baixa; - Baixa; - Moderada; - Alta; - Muito alta suscetibilidade.

6.5 Mapeamento Via Método Híbrido AHP – SVM

Com o intuito de verificar a eficiência de um modelo híbrido que combine a análise Multicritério e ML, o estudo ainda propôs aplicação do AHP na ponderação dos fatores condicionantes classificados via SVM.

O roteiro consiste em classificar cada fator condicionante individualmente por meio do SVM, na sequência, pondera-se o resultado via AHP, e, realiza-se a somatória do resultado gerado. Por fim, normaliza-se o resultado de maneira correlacionada, através da Equação (16). O mapa gerado é categorizado em 5 classes de suscetibilidade: - Muito baixa; - Baixa; - Moderada; - Alta; - Muito alta suscetibilidade.

6.6 Validação dos Resultados Obtidos

A forma proposta para interpretar a eficiência e validar os resultados gerados é por meio da verificação da área sob a curva (*Area Under the Curve* – AUC), a qual é gerada através de Curvas de Características de Operação do Receptor (*Receiver Operating Characteristic* – ROC) (SCHUMANN *et al.*, 2014). A curva ROC é um método com base na teoria de detecção de sinais para visualizar, organizar e selecionar classificadores com base em seu desempenho, traçando valores falsos (não inundação) e positivos (inundações). Sendo assim, a curva ROC permite que o AUC calcule previsões de acertos gerados, variando respostas entre 0 a 1, em que 1 representa 100% de acerto.

A análise de sensibilidade dos fatores condicionantes se realizou através da adoção do teste de *Jackknife*, em que a porcentagem de diminuição relativa (*Percentage of Relative Decrease* – PRD) da AUC avalia a contribuição dos fatores (PARK, 2015), conforme Equação (24).

$$PRD_{fc} = 100 \times \frac{[AUC_{all} - AUC_{fc}]}{AUC_{all}} \quad (24)$$

Onde: AUC_{all} o valor AUC total computado do modelo, PRD_{fc} e AUC_{fc} são, respectivamente, o PRD e valor AUC do modelo em que se remove o fator condicionante analisado.

7. RESULTADOS E DISCUSSÃO

7.1 Inventário do Histórico de Inundações

O inventário do histórico de inundações na BH-SMT ocorreu por meio de três locais distintos. O primeiro foi o levantamento de dados através do banco de dados do IPMet, na sequência se deu por intermédio do catálogo DataGEO e, por fim, os dados de inundações foram inventariados em campo. O resultado obtido pelo banco de dados IPMet gerou 82 pontos de inundações. O catálogo DataGEO resultou em 28 pontos de inundações. No catálogo DataGEO a consideração foi realizada através de pontos coletados por intermédio de polígonos gerados do mapeamento de risco a inundações fornecidos pelo catálogo.

Devido ao tamanho extenso da área que compreende a BH-SMT, a pesquisa técnica em campo foi realizada em quatro etapas. As visitas procuraram levantar locais sobre o histórico de inundações e evidenciar por meio das condições morfométricas locais, com o intuito de validar os dados obtidos. Os dados de inundações foram georreferenciados utilizando-se um equipamento receptor GPS marca Garmin, modelo Etrex-10.

As visitas técnicas foram realizadas em 20 de setembro, 1, 5 e 6 de outubro de 2019, inventariando 81 pontos de inundações. As visitas técnicas além de inventariar pontos de inundações procuraram levantar aspectos de cobertura da terra e uso do solo. Alguns dos dados observados podem ser vistos nas Figura 20, Figura 21, Figura 22 e Figura 23.



Figura 20 - Ponto de inundação na área urbana do município de Piedade (20/09/2019).



Figura 21 - Ponto de inundação na área urbana do município de Porto Feliz (01/10/2019).




Figura 22 - Ponto de inundação na área urbana do município de Laranjal Paulista (05/10/2019).



Figura 23 - Ponto de inundação na área de várzea da represa de Barra Bonita, município de Anhembí (06/10/2019).

No total, 191 pontos de inundações foram inventariados na BH-SMT. Utilizando-se das coordenadas dos pontos foi confeccionada uma carta, conforme Figura 24.




Figura 24 - Mapa temático de inventário de inundações na BH-SMT.

Os 191 pontos de não inundações foram selecionados de maneira aleatória e foram validadas através das análises morfométricas realizadas em campo. As coordenadas dos pontos inventariados estão dispostas no Anexo B.

7.2 Fatores Condicionantes

7.2.1 Altimetria

A altimetria é relacionada inversamente entre maior altitude e menores susceptibilidades a inundações. Com informações do Banco de Dados Geomorfométricos do

Brasil – TOPODATA, obteve-se o mapa de elevação digital (*Digital Elevation Model - DEM*) que corresponde a área da BH-SMT. A partir do DEM, gerou-se um mapa temático de classificação em relação a altitude pelo QGIS, como pode ser observado na Figura 25.




Figura 25 - Mapa temático de altimetria da BH-SMT.

A BH-SMT é composta predominantemente pela Depressão Periférica Paulista, que é classificada como parte média e relativamente parte baixa da bacia. A bacia conta ainda com o Planalto Atlântico na região caracterizada como parte alta da bacia. A altitude da Depressão Periférica Paulista varia entre 400 a 700 m, enquanto o Planalto Atlântico apresenta quase sempre altitudes acima de 700 m.

Através da Figura 25, verifica-se altitudes mais elevadas, além do Planalto Atlântico, no trecho da Cuesta Basáltica (Serra de Botucatu), e ainda em um ponto considerado isolado na Depressão Periférica Paulista em que se encontra o Morro de

Ipanema. As altitudes mais baixas quase sempre são definidas pelos corpos hídricos, reafirmando a maior suscetibilidade atrelada a locais com altitudes mais baixas.

7.2.2 Inclinação

A inclinação tem correlação direta com inundações, visto que exerce influência na infiltração. Devido às velocidades de percolação que possam ser impostas pelas inclinações presentes na superfície do terreno, o escoamento superficial pode aumentar, tendendo a acumular águas de precipitações pluviométricas em pontos de altitudes mais baixas. A carta de inclinação se baseou no DEM e no mapa temático de altimetria da BH-SMT, como verificado na Figura 26.




Figura 26 - Mapa temático de inclinação da BH-SMT.

Com base na análise da Figura 26, é possível correlacionar as declividades mais íngremes com as maiores altitudes, permitindo inferir que as áreas mais baixas da região que

compõe o Planalto Atlântico, a Cuesta Basáltica e o Morro de Ipanema tendem a receber a água de escoamentos superficiais oriunda de precipitações pluviométricas, apresentando maior suscetibilidade a inundações.

7.2.3 Orientação das Vertentes

Estabelecida como direção da inclinação máxima da superfície do terreno, as categorias são definidas pela orientação da inclinação em relação aos pontos cardeais. Além disso, é possível obter a categoria em que nenhuma direção é apontada, nesse caso considera-se um terreno plano. A carta de orientação das vertentes da BH-SMT foi realizada através do DEM e da carta de inclinação anteriormente geradas no QGIS, e pode ser observada na Figura 27.




Figura 27 - Mapa temático de orientação das vertentes da BH-SMT.

A maior suscetibilidade a inundações relacionada à orientação das vertentes pode ser considerada em função da categoria plana e da convergência das orientações para um ponto. Por meio do mapa é possível verificar que existe uma tendência que as inclinações apontem as altitudes inferiores nas localidades que existam corpos hídricos.

7.2.4 Curvatura

A curvatura consiste em três categorias: superfície côncava, convexa e plana. É um fator condicionante de escoamento superficial e apresenta-se como um fator correlacionado diretamente com a vulnerabilidade de áreas inundáveis, visto que áreas côncavas tendem a concentrar os escoamentos oriundos de precipitações. A construção da carta de curvatura da BH-SMT foi realizada a partir do DEM e das cartas de inclinação e orientação das vertentes, conforme Figura 28. O resultado demonstra um equilíbrio entre superfícies convexas e côncavas, apresentando ainda poucos pontos em que a superfície se apresenta plana.




Figura 28 - Mapa temático de curvatura da BH-SMT.

7.2.5 Hidrografia e Distância Interfluvial

A hidrografia demonstra relativa importância na suscetibilidade a inundações, observado que corpos hídricos que evidenciem fluxos apresentam-se como as principais vias de descargas de precipitações e inundações. Outro ponto é que áreas de várzeas tendem a ser suscetíveis a inundações. A confecção desta carta baseou-se no mapa hidrográfico do Estado de São Paulo, realizado pelo IBGE no ano de 1982, com escala de 1:50.000. A vetorização ocorreu para área que compreende a BH-SMT, resultando na carta hidrográfica da BH-SMT vetorizada na Figura 29.




Figura 29 - Carta hídrica da BH-SMT.

Através da carta hídrica relacionada ao tipo de solo é possível inferir que a densidade de corpos d'água é inversamente proporcional a porosidade do solo e ao tipo de rocha, ou seja, quanto mais poroso o solo e a rocha forem, menor é a densidade hidrográfica. Exemplo de solos porosos são solos arenosos oriundos do arenito, que correspondem a parte

média e baixa da BH-SMT, local onde há uma menor concentração de corpos hídricos. O mapa temático de distância interfluvial, realizado por meio da carta hidrográfica, pode ser visualizado na Figura 30.




Figura 30 - Mapa temático de distância interfluvial da BH-SMT.

O resultado obtido evidencia que a BH-SMT é formada por privilegiada quantidade de corpos hídricos, demonstrando a distância máxima entre dois corpos hídricos de cerca de 1.800 metros. Por meio do mapa de distância interfluvial relacionando ao mapa geológico é possível ainda a verificação das áreas de recargas dos lençóis freáticos, como a Depressão Periférica Paulista, composta em sua maioria por rochas sedimentares como o arenito.

7.2.6 Índice de Umidade Topográfica

O Índice de Umidade Topográfica (*Topographic Wetness Index – TWI*) indica as variações espaciais de umidade em bacias hidrográficas. De maneira sucinta, o TWI exibe a

quantidade de acúmulo de água em qualquer pixel da área da bacia hidrográfica. Deste modo, quanto maior o valor de TWI, maior a suscetibilidade a inundação. O mapa temático TWI, apresentado na Figura 31, foi baseado na Equação (1), indicada no Capítulo 2, no DEM e na carta de inclinação da BH-SMT.




Figura 31 - Mapa temático TWI da BH-SMT.

O mapa gerado aponta valores maiores de TWI em localidades de altitudes mais baixas e próximas aos corpos hídricos, validando a maior suscetibilidade desses critérios apontados anteriormente.

7.2.7 Densidade de Drenagem

A densidade de drenagem verifica a capacidade de áreas em drenar possíveis precipitações e, consequentemente, inundações. Quanto maior o valor da densidade de

drenagem menor é a suscetibilidade a inundação. A carta de densidade de drenagem foi embasada na carta hidrográfica vetorizada e no DEM da BH-SMT. O mapa temático de densidade de drenagem é o ilustrado conforme Figura 32.




Figura 32 - Mapa temático de densidade de drenagem da BH-SMT.

O mapa gerado revela que corpos hídricos com grandes vazões são responsáveis, em grande parte, por servir de sistema de drenagem das precipitações geradas. Localidades que não apresentam tais características tendem a maior suscetibilidade a inundações.

7.2.8 Solos

O mapa temático do tipo de solo ilustra as ordens de solos que compõem a BH-SMT. As ordens de solos trazem intrinsecamente características físicas e químicas, como granulometria, composição e profundidade de camada de solo, as quais influenciam na permeabilidade, absorção e acúmulo da água subterrânea. Devido a essas características,

esse fator condicionante se mostra de grande importância no mapeamento de suscetibilidade a inundações. A carta de solos da BH-SMT é observada na Figura 33.




Figura 33 - Mapa temático de solos da BH-SMT.

A suscetibilidade atribuída ao solo relacionada a granulometria influencia diretamente na infiltração. Em solos arenosos a taxa de infiltração se apresenta maior, em função da porosidade existente, minimizando a suscetibilidade a inundações.

Em solos argilosos, em função do número de vazios menores e ainda do mineral que pode compô-lo (o qual pode realizar interação com a molécula de água, como exemplo, as argilas bentoníticas) podem impermeabilizar o meio. Essas camadas praticamente impermeáveis podem representar maiores suscetibilidades a inundações.

Solos que demonstrem maior evolução pedológica, como o Latossolos, apresentam camadas de solos maiores. Quanto maior a camada de solo, maior é a capacidade de

armazenamento da água proveniente da infiltração, trazendo como características desses solos uma menor suscetibilidade a inundações.

7.2.9 Grupos Hidrológicos do Solo

A carta de taxa de infiltração da BH-SMT foi realizada de acordo com o mapeamento do tipo de solo do Estado de São Paulo (ROSSI, 2017), conforme Figura 34.




Figura 34 - Mapa temático de SHG da BH-SMT.

A categorização dos solos em Grupos Hidrológicos do Solo (*Soil Hydrological Groups* - SHG) indica a qualidade do solo em relação à taxa de infiltração que ele apresenta. Conforme referido no Capítulo 5, os solos são usualmente classificados em quatro grupos: A, B, C e D. Os solos do grupo A têm o potencial de escoamento mínimo, enquanto os solos

do grupo D têm o potencial de escoamento máximo. Quanto menor a infiltração maior é a suscetibilidade a inundações.

7.2.10 Embasamento Geológico

O embasamento geológico tem influência nos processos hidrológicos, visto que alguns tipos de rocha permitem o armazenamento de água devido a porosidade apresentada. Nessas rochas, a altura da camada pode determinar o volume de água passível de acumulação. Além da porosidade, o embasamento geológico pode apresentar fraturamento, que também pode interferir quanto ao regime hidrológico.

O mapa temático de embasamento geológico pode ser observado na Figura 35.




Figura 35 - Mapa temático de embasamento geológico da BH-SMT.

Era	Períodos	Sigla	Litoestratigrafia	Fraturas	Porosidade
Cenozoico	Quaternário	Q1c	Depósitos elúvio-coluvionares	Não fraturada	Moderada (15 a 30%)
	Neogeno	Q2a	Areia, Cascalho	Não fraturada	Alta (> 30%)
Mesozoico/Cenozoico	Cretáceo/Paleogeno	K2Eit	Arenito, Arenito conglomerático	Não fraturada	Moderada (15 a 30%)
Mesozoico	Cretáceo	K2_lambda_i	Glimmerito, Fenito, Dunito, Nefelina Sienito, Gabro, Peridotito, Piroxenito, Sienogranito, Serpentinito, Carbonatito	Intensamente fraturada	Baixa (0 a 15%)
		K2m	Arenito	Não fraturada	Alta (> 30%)
		K2yp	Arenito, Argilito arenoso	Pouco a moderadamente fraturada	Alta (> 30%)
	Jurássico/Cretáceo	J3K1bt	Arenito	Pouco a moderadamente fraturada	Variável (0 a > 30%)
		K1_delta_sg	Basalto	Intensamente fraturada	Baixa (0 a 15%)
	Jurássico	P3T1p	Arenito e Folhelho	Pouco a moderadamente fraturada	Alta (> 30%)
Paleozoico/Mesozoico	Permiano/Triássico	P3T1c	Arenito, Siltito	Pouco a moderadamente fraturada	Alta (> 30%)
Paleozoico	Permiano	P1tt	Siltito	Não fraturada	Variável (0 a > 30%)
		P23sa	Argilito, Folhelho, Siltito	Não fraturada	Alta (> 30%)
		P2i	Folhelho	Não fraturada	Variável (0 a > 30%)
		P3t	Siltito argiloso	Pouco a moderadamente fraturada	Alta (> 30%)
	Carbonífero/Permiano	C2P1i	Arenito, Folhelho, Diamictito e Rocha Pelítica Ritímica	Não fraturada	Alta (> 30%)
Neoproterozoico	Ediacarano	NP3e_gamma_2ca	Granito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3p_gamma_1lib	Granodiorito, Monzogranito, Quartzo-Monzonito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3p_gamma_1iv	Biotita monzogranito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3p_gamma_1tp	Monzogranito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3p_gamma_2lpd	Granito, Granodiorito, Monzogranito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3p_gamma_2Spd	Biotita monzogranito, Granodiorito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3p_gamma_2Ssl	Biotita monzogranito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3p_gamma_3Asb	Riolito, Monzogranito, Sienogranito	Pouco a moderadamente fraturada	Baixa (0 a 15%)
		NP3p_gamma_po	Granito	Pouco a moderadamente fraturada	Baixa (0 a 15%)
		NP3p_gamma_pr	Granito, Granodiorito, Monzogranito	Pouco a moderadamente fraturada	Baixa (0 a 15%)
		NP3p_gamma_te	Sienogranito	Pouco a moderadamente fraturada	Baixa (0 a 15%)
		NP3s_gamma_1lsr	Granodiorito, Biotita monzogranito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3s_gamma_2l	Granito, Granodiorito, Monzogranito, Sienogranito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3s_gamma_2Iso	Granito, Granodiorito, Monzogranito, Sienogranito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3s_gamma_3Aca	Monzogranito, Monzonito, Sienomonzogranito	Pouco a moderadamente fraturada	Baixa (0 a 15%)
		NP3s_gamma_3Ait	Granito, Monzogranito, Sienogranito	Pouco a moderadamente fraturada	Baixa (0 a 15%)
		NP3s_gamma_3Asf	Granito, Monzogranito, Sienogranito	Pouco a moderadamente fraturada	Baixa (0 a 15%)
		NP3s_gamma_3Atn	Biotita granito	Pouco a moderadamente fraturada	Baixa (0 a 15%)
		NP3srpi	Filito, Metabasito, Metaconglomerado, Metabrecha	Pouco a moderadamente fraturada	Moderada (15 a 30%)
	Criogeniano/Ediacarano	NP3s_gamma_1lit	Granodiorito, Granito	Zonas de cisalhamento	Baixa (0 a 15%)
		NP3srbt	Metarenito, Ortoanfibolito, Rocha vulcânica piroclástica, Metarcóseo, Rocha metapelítica, Metagrauvaca feldspática	Pouco a moderadamente fraturada	Baixa (0 a 15%)
		NP3srer	Metarenito, Metaritmio, Rocha metapelítica	Pouco a moderadamente fraturada	Moderada (15 a 30%)
		NP3srpc	Calcifilito, Metacalcário dolomito	Intensamente fraturada	Baixa (0 a 15%)
		NP3srpv	Rocha metavulcânica, Rocha vulcânica piroclástica	Intensamente fraturada	Baixa (0 a 15%)
		NPvm	Paragnaisse, Biotita gnaiss, Xisto Migmatito estromático, Albita anatexito, Tonalito gnaiss, Granito gnaiss	Intensamente fraturada	Baixa (0 a 15%)
Mesoproterozoico	Toniano/Criogeniano/Ediacarano	NPvog		Intensamente fraturada	Baixa (0 a 15%)
	Toniano	NPexm	Mica xisto, Quartzo Xisto	Intensamente fraturada	Baixa (0 a 15%)
	Calymniano/Ectasiano	MP2si	Quartzito, Metapelito, Mica xisto	Pouco a moderadamente fraturada	Variável (0 a > 30%)
	Calymniano	MP1vot	Metasiltito, Filito, Metaconglomerado, Metarenito	Intensamente fraturada	Baixa (0 a 15%)
		MP1vox	Xisto, Biotita xisto, Muscovita biotita xisto	Intensamente fraturada	Baixa (0 a 15%)

Figura 35 - Mapa temático de embasamento geológico da BH-SMT (continuação).

As rochas são divididas em três classes: metamórficas; ígneas; e, sedimentares. As rochas sedimentares como arenito (parte média e baixa da BH-SMT) apresentam porosidade, fornecendo menor suscetibilidade a inundações. As rochas granitóides sem fraturamento

tendem a ser mais impermeáveis, consequentemente mais suscetível a inundação. As rochas granitóides são verificadas na parte alta do BH-SMT, local em que se encontra o Planalto Atlântico.

7.2.11 Cobertura da Terra e Uso do Solo

O uso do solo tem um papel significativo na velocidade de escoamento, interceptação e infiltração. O mapa de cobertura da terra e uso do solo é essencial para a determinação de áreas suscetíveis a inundações, visto que alguns tipos de ocupações tendem a impermeabilizar a infiltração de água do solo. A carta de cobertura da terra e uso do solo pode ser observada na Figura 36.




Figura 36 - Mapa temático de cobertura da terra e uso do solo da BH-SMT.

Realizou-se o mapa de cobertura da terra e uso do solo através de imagens do Satélite S-2A com resolução de 10 metros, obtidas no banco de dados do Google Earth Engine e pela ferramenta *Semi-Automatic Classification Plugin* disponibilizada no software QGIS. Com intuito de direcionar a identificação e nomeação das classes de cobertura da terra e uso do solo e validar o resultado obtido foram realizadas visitas técnicas na BH-SMT.

A classificação elaborada foi fundamentada no método *Maximum Likelihood*. A avaliação da qualidade do mapa de cobertura da terra e uso do solo gerado foi realizado pela *Kappa Hat Classification* e *Overall Accuracy*, o sistema de avaliação é fornecido também através do *Semi-Automatic Classification Plugin*. O resultado apresentado foi de 91.80% de *Overall accuracy* e *Kappa hat classification* de 0.8816.

As classes assumidas foram: área urbanizada, lavoura, pastagem, vegetação e corpo hídrico. A classe vegetação considerou a vegetação nativa remanescente (VNR) e lavoura permanente. A análise da Figura 36 permite constatar que a BH-SMT é composta de 331,21 km² (2,80%) de área urbanizada, 4.390,24 km² (37,11%) de lavoura, 3.501,42 km² (29,61%) de pastagem, 3.376,42 km² (28,54%) de vegetação e 229,18 km² (1,94%) de corpos hídricos.

7.3 Mapeamento de Áreas Suscetíveis a Inundações

7.3.1 Análise AHP-TOPSIS-2N

O método de mapeamento de áreas suscetíveis a inundações por meio de análise Multicritério AHP-TOPSIS-2N modificado foi aplicado conforme roteiro demonstrado no Capítulo 6. A nomenclatura utilizada na análise AHP-TOPSIS-2N modificado para os fatores condicionantes e descritas na Tabela 10.

Tabela 10 - Nomenclatura dos fatores condicionantes.

Fator Condicionante	Nomenclaturas
Altimetria	A
Curvatura	C
Densidade de drenagem	DD
Distância interfluvial	DI
Embasamento geológico	G
Inclinação	I
Orientação das vertentes	OV
SHG	SHG
Solo	S
TWI	TWI
Cobertura da terra e uso do solo	CTUS

A estrutura hierárquica do AHP aplicada ao mapeamento de áreas suscetíveis a inundações mostra na primeira camada o objetivo, na segunda os critérios e na última camada as alternativas geradas, conforme apresentado na Figura 37.




Figura 37 - Estrutura hierárquica AHP aplicada no mapeamento de áreas suscetíveis a inundações.

Inicialmente, pondera-se os fatores condicionantes por meio da Matriz de Julgamento, em que os pesos entre dois fatores condicionantes são atribuídos por meio da Escala Fundamental (Tabela 1). A Matriz de Julgamento é dada pela Tabela 11.

Tabela 11 - Matriz de Julgamento - AHP-TOPISIS-2N modificado.

	A	C	DD	DI	G	I	OV	SHG	S	TWI	CTUS
A	1,000	1,820	2,730	1,000	8,088	1,191	8,555	1,000	0,450	3,121	0,450
C	0,549	1,000	1,191	0,366	7,678	0,952	7,963	0,549	0,471	1,250	0,471
DD	0,366	0,840	1,000	0,367	7,341	0,500	7,642	0,367	0,378	1,250	0,378
DI	1,000	2,732	2,725	1,000	8,088	0,667	8,321	0,980	0,569	2,435	0,569
G	0,124	0,130	0,136	0,124	1,000	0,135	0,909	0,135	0,143	0,135	0,124
I	0,840	1,050	2,000	1,499	7,413	1,000	3,800	0,952	0,391	2,500	0,391
OV	0,117	0,126	0,131	0,120	1,100	0,263	1,000	0,117	0,112	0,153	0,112
SHG	1,000	1,820	2,725	1,020	7,413	1,050	8,555	1,000	0,450	2,898	0,450
S	2,222	2,125	2,647	1,756	7,000	2,555	8,889	2,222	1,000	3,452	1,000
TWI	0,320	0,800	0,800	0,411	7,413	0,400	6,521	0,345	0,290	1,000	0,124
CTUS	2,222	2,125	2,647	1,756	8,095	2,555	8,889	2,222	1,000	3,452	1,000

Formulada a Matriz de Julgamento, definiu-se o W_i com base na Equação (9), com valores normalizados por meio da Equação (10). Os valores dos W_i normalizados são observados na Tabela 12. O peso de cada critério pode ser obtido pela média dos W_i normalizados (respectiva linha de cada fator condicionante).

Tabela 12 - Matriz dos pesos normalizados - AHP-TOPISIS-2N modificado.

	A	C	DD	DI	G	I	OV	SHG	S	TWI	CTUS
A	0,102	0,125	0,146	0,106	0,115	0,106	0,120	0,101	0,086	0,144	0,089
C	0,056	0,069	0,064	0,039	0,109	0,084	0,112	0,056	0,090	0,058	0,093
DD	0,038	0,058	0,053	0,039	0,104	0,044	0,108	0,037	0,072	0,058	0,075
DI	0,102	0,188	0,145	0,106	0,115	0,059	0,117	0,099	0,108	0,112	0,112
G	0,013	0,009	0,007	0,013	0,014	0,012	0,013	0,014	0,027	0,006	0,024
I	0,086	0,072	0,107	0,159	0,105	0,089	0,053	0,096	0,074	0,115	0,077
OV	0,012	0,009	0,007	0,013	0,016	0,023	0,014	0,012	0,021	0,007	0,022
SHG	0,102	0,125	0,145	0,108	0,105	0,093	0,120	0,101	0,086	0,134	0,089
S	0,228	0,146	0,141	0,186	0,099	0,227	0,125	0,225	0,190	0,159	0,197
TWI	0,033	0,055	0,043	0,044	0,105	0,035	0,092	0,035	0,055	0,046	0,024
CTUS	0,228	0,146	0,141	0,186	0,115	0,227	0,125	0,225	0,190	0,159	0,197

A porcentagem da ponderação dos fatores condicionantes é exibida na Tabela 13.

Tabela 13 - Pesos dos fatores condicionantes - AHP-TOPISIS-2N modificado.

Fatores Condicionantes	Peso
Altimetria	11,27%
Curvatura	7,53%
Densidade de drenagem	6,22%
Distância interfluvial	11,50%
Embasamento geológico	1,39%
Inclinação	9,41%
Orientação das vertentes	1,42%
SHG	10,99%
Solo	17,49%
TWI	5,15%
Cobertura da terra e uso do solo	17,63%

Determinados os pesos de cada fator condicionante, encontra-se o $\lambda_{m\acute{a}x}$, conforme a Equação (11). Na sequência, verifica-se o IC por meio da Equação (12) e o IR através da Tabela 2. Os valores obtidos são elencados a seguir:

- $\lambda_{m\acute{a}x} = 11,438$
- IC = 0,044
- IR = 1,51

O valor de RC máxima definida como aceitável é de 0,1 (SAATY, 1994). Equacionando o RC por meio da Equação (13), o valor obtido foi de RC = 0,029, demonstrando que os pesos atribuídos para os fatores condicionantes estão dentro do preconizado pelo método AHP.

Definidos os pesos de cada fator condicionante, aplica-se a metodologia TOPSIS, dispondo os fatores condicionantes através da Matriz de Decisão, conforme Equação (25).

$$D = \begin{matrix} Pixel_i \\ \downarrow \\ Pixel_n \end{matrix} \begin{bmatrix} A & \dots & UOS \\ 393 & \dots & 5 \\ \vdots & \dots & \vdots \\ 1.301 & \dots & 1 \end{bmatrix} \quad (25)$$

Na aplicação do método AHP-TOPSIS-2N modificado, os fatores condicionantes qualitativos são reclassificados em classes de suscetibilidade a inundações variando de 1 a 5, em que 5 demonstra maior suscetibilidade, a reclassificação é demonstrada na Tabela 14.

Tabela 14 - Reclassificação dos fatores condicionantes qualitativos.

Fator condicionante		Classe	Classe reclassificada
Curvatura	Côncavo		3
	Plano		2
	Convexo		1
Embasamento Geológico	Porosidade Alta / Pouco a moderadamente fraturada		1
	Porosidade Alta / Não fraturada		2
	Porosidade moderada / Pouco a moderadamente fraturada		2
	Porosidade moderada / Não fraturada		3
	Porosidade variável / Pouco a moderadamente fraturada		4
	Porosidade baixa / Pouco a moderadamente fraturada		5
	Porosidade baixa / Intensamente fraturada		5
	Porosidade baixa / Zona de cisalhamento		5
Cobertura da terra e uso do solo	Área Urbanizada		4
	Lavoura		2
	Pastagem		3
	Vegetação		1
	Corpo Hídrico		5
SHG	A		1
	B		2
	C		3
	D		5
	Área Urbanizada		4
	Corpo Hídrico		5
Solo	Argissolos		5
	Cambissolos		5
	Chernossolos		5
	Gleissolos		3
	Latossolos		3
	Luvissolos		4
	Neossolos		2
	Nitossolos		3
	Planossolos		1
	Área Urbanizada		4
	Corpo Hídrico		5

A reclassificação foi baseada na revisão estruturada do Capítulo 4, em especial, nos estudos de Tehrany *et al.* (2014), Mahmoud e Gan (2018A) e Mahmoud e Gan (2018B).

Conforme definido no roteiro metodológico, são aplicadas duas normalizações nos fatores condicionantes (formato “*.rst”) por meio da calculadora *raster*, disponível no QGIS, a normalização que desconsidera a proporcionalidade (Equação (15)) e a normalização que considera a proporcionalidade (Equação (16)). A aplicação das normalizações propostas gera dois arquivos distintos (formato “*.rst”) para cada fator condicionante.

Com base nos fatores condicionantes normalizados são aplicados os pesos atribuídos pelo método AHP (Tabela 13), conforme a Equação (18). O valor de A^+ é definido nesse estudo como mais suscetível a inundação e A^- menos suscetível a inundações. Os critérios ponderados p_j^+ e p_j^- que compõem, respectivamente, a alternativa ideal (mais suscetível a inundação) e não ideal (menos suscetível a inundação) são definidos conforme verificação da suscetibilidade a inundação que os valores quantitativos e qualitativos que os fatores condicionantes apresentam, conforme as Equações (19) e (20).

Encontrados os valores de A^+ e de A^- , a distância euclidiana é calculada para cada solução, de acordo com as Equações (21) e (22), respectivamente. Por fim, ξ é calculado por meio da Equação (23) para os dois resultados gerados em função das normalizações aplicadas.

Os resultados obtidos são observados por meio da Figura 38, que apresenta o mapeamento de áreas suscetíveis às inundações da BH-SMT aplicando a normalização sem proporcionalidade, e, através da Figura 39, que demonstra o mapeamento de áreas suscetíveis a inundações da BH-SMT aplicando a normalização com proporcionalidade.

Por meio dos mapas de áreas suscetíveis a inundações gerados é possível observar que o mapa obtido através da normalização sem proporcionalidade apresenta áreas com predominância de suscetibilidade alta. Sendo assim, infere-se que em uma análise prévia, relacionando aos pontos inventariados de inundações e não inundações e os mapas com as características hidrogeomorfológicas, o mapeamento com aplicação da normalização não correlacionada fornece o pior resultado.

As classes geradas nos mapas de suscetibilidade a inundações utilizaram-se de quantis regulares, exceto a classe de suscetibilidade muito alta, que agrega os valores que contemplam as áreas dos corpos hídricos considerados com maiores vazões, a parte média do Rio Tietê e o Rio Sorocaba.




Figura 38 - Mapa de suscetibilidade a inundações da BH-SMT - análise Multicritério AHP-TOPSIS-2N modificado: normalização sem proporcionalidade.

O mapa da Figura 38 (normalização sem correlação) indica que as áreas correspondentes aos corpos hídricos de maiores vazões, como o Rio Tietê e o Rio Sorocaba, apresentam cerca de 3,12% da área total classificada com muito alta suscetibilidade. Cerca de 65,74% das áreas são classificadas com alta suscetibilidade, essas se localizam em grande parte em locais que os solos apresentam taxa de infiltração entre 1,27 a 3,80 mm/h (SHG = C). As áreas com altitudes relativamente acima da média, em partes, são classificadas com suscetibilidade moderada 30,71%. Em altitudes acima da média, próximas as maiores altitudes e em áreas com uso classificado como vegetação, apresentam baixa suscetibilidade

(0,42% da área total). E, as áreas que apresentam as maiores altitudes, cerca de 0,01% são classificadas como muito baixa suscetibilidade a inundações.

O mapa de suscetibilidade de áreas suscetíveis a inundações (Figura 39) obtido por meio da normalização correlacionada, quando relacionando os pontos inventariados de inundações e não inundações e os mapas com as características hidrogeomorfológicas.




Figura 39 - Mapa de suscetibilidade a inundações da BH-SMT - análise Multicritério AHP-TOPSIS-2N modificado: normalização com proporcionalidade.

O mapa gerado expõe 4,02% de suas áreas classificadas com muito alta suscetibilidade, classe que está distribuída em locais próximos aos corpos hídricos e em áreas com o uso do solo classificado como urbanizado. As áreas classificadas com alta suscetibilidade (32,74%) estão em grande parte vinculadas aos Argissolos e ao grupo

hidrológico do solo, classificado como “C”. As áreas classificadas como suscetibilidade moderada compreendem a maior parcela de participação, cerca de 38,09% da área total da BH-SMT, podendo ser associadas à cobertura da terra e uso do solo classificada como lavoura. Na classificação geral, 21,48% das áreas classificam-se com baixa suscetibilidade e podem ser relacionadas à cobertura da terra e uso do solo de vegetação e em partes aos Latossolos. E, 3,67% do mapa da BH-SMT são categorizados com muito baixa suscetibilidade a inundações, áreas que apontam relações aos fatores condicionantes com as maiores altitudes da bacia e com inclinações mais íngremes.

7.3.2 Análise SVM

O *plugin* Dzetsaka foi desenvolvido com intuito de classificar imagens obtidas por sensoriamento remoto, com uso mais comum na classificação de cobertura da terra e uso do solo. Neste estudo, o Dzetsaka foi empregado para mapear áreas suscetíveis a inundações.

O mapeamento é realizado através de treinamento supervisionado do SVM, por meio de 70% do inventário dos pontos inundáveis e não inundáveis atribuídos aleatoriamente. Cada fator condicionante de suscetibilidade foi classificado individualmente. Os resultados obtidos da classificação foram somados com a calculadora *raster* e, na sequência, o mapa gerado foi normalizado de maneira correlacionada.

O custo computacional é proporcional à resolução do fator condicionante classificado, quanto maior resolução, maior é o custo. O tempo apresentado para a classificação via SVM varia de 10 a 15 minutos.

O resultado indica consistência aceitável em comparação aos fatores condicionantes e ao histórico de inundações.

O mapeamento fornece áreas suscetíveis a inundações que revelam que 2,89% da BH-SMT apresenta muito alta suscetibilidade, áreas que estão alocadas próximas aos corpos hídricos, como a parte média do Rio Tietê e o Rio Sorocaba. A classificação de suscetibilidade alta é a segunda maior categoria: 28,23% das áreas da BH-SMT. Em boa parte, o SVM classifica essas áreas vinculando-as com as proximidades aos corpos hídricos e as altitudes mais baixas. A classe de suscetibilidade moderada corresponde a 36,45% das áreas. Através do mapa gerado é possível relacionar essa classe à cobertura da terra e uso do solo de áreas urbanizadas de médio e baixo adensamento e lavouras. O resultado obtido pelo SVM indica que 24,47% das áreas apresentam baixa suscetibilidade, associando os fatores condicionantes é possível verificar que parte da classe está em áreas de altitudes acima da

média e cobertura da terra e uso do solo classificados como vegetação. Por fim, 7,96% das áreas da BH-SMT são categorizadas como muito baixa suscetibilidade a inundações, essas áreas correspondem a maiores altitudes, inclinações mais íngremes e cobertura da terra e uso do solo classificados como vegetação. O resultado obtido é demonstrado na Figura 40.




Figura 40 - Mapa de suscetibilidade a inundações da BH-SMT - análise SVM.

7.3.3 Análise AHP-SVM

A análise híbrida AHP-SVM parte do princípio em ponderar os fatores condicionantes reclassificados via SVM, através dos pesos obtidos pelo AHP, conforme demonstrado na Tabela 13. A ponderação e a somatória final se realizam por meio da

calculadora *raster*, fornecendo o mapa de suscetibilidade a inundações como observado na Figura 41.




Figura 41 - Mapa de suscetibilidade a inundações da BH-SMT - análise SVM-AHP.

O modelo híbrido AHP-SVM contabiliza que apenas 3,04% das áreas da BH-SMT são de muito alta suscetibilidade, assim como nos outros resultados obtidos. Essas áreas dentro da bacia quase sempre são próximas aos corpos hídricos. A classe alta suscetibilidade corresponde a 29,00% do total. Relacionando-a aos fatores condicionantes observa-se que a maioria dessa classe se encontra em áreas de cobertura da terra e uso do solo de pastagem localizada na parte média até a parte baixa da BH-SMT. A maior classe gerada é a suscetibilidade moderada, apresentando-se em 40,55% da bacia, a classe quase sempre se relaciona ao fator condicionante de cobertura da terra e uso do solo, especificamente à classe

lavou, localizada em partes na região da BH-SMT considerada alta. O modelo híbrido indica que 24,59% das áreas da bacia são de baixa suscetibilidade, a classe apresentando vínculo, em partes, ao SHG “A”. E, relacionando-se às maiores altitudes, principalmente, a parte considerada alta da bacia, a classe muito baixa suscetibilidade a inundações se apresenta em 3,32% das áreas que compõem a BH-SMT.

7.4 Validação dos Mapas de Áreas Suscetíveis a Inundações

Com o intuito de validar as classes assumidas dos mapas gerados para cada respectivo modelo se obteve uma Função de Distribuição de Probabilidade (FDP) dos valores que os pontos inventariados de inundações e não inundações, comparando as curvas FDP com as classes de suscetibilidade a inundações assumidas, conforme Figura 42.




Figura 42 - Validação das classes em função do inventário de inundações - (a) AHP-TOPSIS-2N Não Correlacionada; (b) AHP-TOPSIS-2N Correlacionada; (c) SVM; (d) AHP-SVM.

As classes são consideradas com intervalos iguais, exceto a classe de muito alta suscetibilidade que tenta abranger os principais corpos hídricos (parte média do Rio Tietê e Rio Sorocaba). A classe de muito alta suscetibilidade se apresenta predominante na região desses corpos hídricos, característica verificada em todos os mapas gerados. A validação das

classes considerou todos os pontos inventariados. O resultado demonstra que para o método AHP-TOPSIS-2N modificado gerado pela normalização não correlacionada a adoção de classes com intervalos iguais não gera a possibilidade de uma classificação consistente, o que valida o resultado como sendo o menos eficiente em comparação ao mapa gerado pela normalização correlacionada.

A análise aponta que o melhor resultado obtido é do modelo SVM, seguido pelo modelo AHP-SVM. Entre os modelos SVM e AHP-SVM, o primeiro fornece melhores valores estatísticos, com média de 0,368 e 0,186 para os pontos inventariados de inundação e não inundação, respectivamente, e, menor dispersão de dados, com desvio padrão para os pontos de inundações de 0,086, e desvio padrão de 0,084 para os pontos de não inundações.

Todos os modelos aplicados no mapeamento de suscetibilidade a inundações tiveram como métrica de avaliação a Área Sob a Curva (*Area Under the Curve* – AUC), obtido por meio de Curvas de Características de Operação do Receptor (*Receiver Operating Characteristic* – ROC). A avaliação da eficiência dos mapas gerados pela AUC permite uma análise do desempenho geral de cada modelo assumido neste estudo (ARORA *et al.*, 2021A; KHOSRAVI *et al.*, 2019A). A avaliação considerou, aleatoriamente, 30% dos dados inventariados para validação dos mapas.

As construções das curvas ROC dos modelos de mapeamento de inundações compara e classifica o mapa gerado com os dados inventariados. A avaliação considera os critérios de Definitivamente Positivo (DP) quando o ponto inventariado de inundação coincide com a classe de muito alta suscetibilidade a inundações; Provavelmente Positivo (PP) nas ocasiões em que o ponto de inventário de inundação coincide com a classe de alta suscetibilidade; Eventualmente Positivo (EP), quando o ponto inventariado de inundação coincide com 50% do intervalo que compõe a classe de suscetibilidade moderada mais próxima a classe alta; Definitivamente Negativo (DN) nas situações em que o ponto inventariado de não inundação coincide com a classe de muito baixa suscetibilidade a inundações; Provavelmente Negativo (PN) para o ponto de inventário de não inundação coincidindo com a classe de baixa suscetibilidade; E Eventualmente Negativo (EN) quando o ponto inventariado de não inundação coincide com a metade do intervalo que compõem a classe de suscetibilidade moderada mais próxima a classe baixa.

A acurácia define a precisão com que o modelo foi executado durante a validação dos dados. Os valores dessa métrica variam entre 0 e 1, o valor mais alto indica maior precisão e vice-versa. A acurácia máxima foi observada para o AHP-TOPSIS-2N

correlacionada (92,98%), seguido pelo AHP-SVM com nível de precisão de 89,47%, enquanto a menor acurácia foi identificada no caso do modelo AHP-TOPSIS-2N não correlacionada com valores de acurácia de 60,53%, conforme Tabela 15.

Tabela 15 - Métricas de validação dos modelos de mapeamento de áreas suscetíveis a inundações.

	AHP-TOPSIS-2N Não Correlacionada	AHP-TOPSIS-2N Correlacionada	SVM	AHP-SVM
Número de Casos (30%)	114	114	114	114
Número de Casos Corretos	69	106	97	102
Acurácia	60,53%	92,98%	85,09%	89,47%
Sensibilidade	100%	85,96%	96,49%	89,47%
Especificidade	21,05%	100%	73,68%	89,47%
Caso de Falsos Positivos	0	8	2	6
Caso de Falsos Negativos	45	0	15	6
AUC	0,853	0,944	0,930	0,962

A sensibilidade foi calculada dividindo o número de previsões positivas verdadeiras (inundação) pelo total de valores positivos (susceptibilidade a inundação). A maior sensibilidade foi registrada para o modelo para AHP-TOPSIS-2N não correlacionada (100%), seguidos do SVM (96,49%), AHP-SVM (89,47%) e TOPSIS-2N correlacionada (85,96%). Porém, quando considerado somente o valor de sensibilidade, pode-se gerar equívocos na avaliação do desempenho do modelo como, por exemplo, é o referido modelo AHP-TOPSIS-2N não correlacionada, que demonstra sensibilidade igual a 100%, mas, analisando o resultado do modelo, verifica-se que o mapa gerado considera que aproximadamente 70% de toda a BH-SMT apresenta áreas com muito alta e alta susceptibilidade a inundações. Considerando que a sensibilidade é a verificação dos pontos positivos de inundações em relação às classes alta ou muito alta susceptibilidade a inundações, é de se esperar valores de resultados altos. Deste modo, uma análise do resultado mais adequada deve considerar além da sensibilidade a especificidade.

A especificidade é calculada dividindo o número total de previsões negativas verdadeiras (não inundação) pelas contagens negativas totais (não propenso a inundação). A especificidade também pode se referir à precisão do modelo, porém, assim como no caso da sensibilidade, a análise deve ser realizada em conjunto (sensibilidade e especificidade). A melhor especificidade verificada foi do modelo AHP-TOPSIS-2N correlacionada (100%), seguidos do modelo AHP-SVM (89,47%), SVM (73,68%) e AHP-TOPSIS-2N não correlacionada (21,05%).

A AUC é denotada pelo cálculo da área abaixo da curva formada ao se plotar um gráfico assumindo os valores da ordenada em função da sensibilidade e, os valores da abscissa em função da especificidade, em que a área pode ser fornecida de maneira adimensional ou em porcentagem variando de 0 a 100%, sendo os melhores resultados mais próximos de 100%. O modelo com melhor desempenho é o AHP-SVM com AUC = 96,2%, seguido pelos modelos AHP-TOPSIS-2N correlacionada (AUC=94,4%), SVM (AUC=93,0%) e AHP-TOPSIS-2N não correlacionada (AUC=85,3%), como observado na Figura 43.




Figura 43 - AUC de validação dos modelos quanto à taxa de predição de mapeamento de suscetibilidade a inundações.

A análise de sensibilidade dos fatores condicionantes é aplicada apenas ao modelo SVM, sendo possível verificar a influência que cada parâmetro assume dentro do modelo SVM para mapeamento de áreas suscetíveis a inundações. A análise considerou o teste de *Jackknife*, onde a AUC gerada para cada fator condicionante recebe a diminuição relativa de porcentagem (CHOUBIN *et al.*, 2019), como apresentado na Equação (24).

A escolha dos parâmetros de fatores condicionantes apropriados é fundamental na modelagem da suscetibilidade a inundações (ARORA *et al.*, 2021A; KHOSRAVI *et al.*, 2019A; LEE *et al.*, 2017). A escolha dos fatores condicionantes se fundamentou na revisão bibliométrica (Capítulo 4). A análise de sensibilidade considerou os 11 fatores

condicionantes utilizados nos modelos SVM e AHP-TOPSIS-2N modificado aplicados no mapeamento de áreas suscetíveis a inundações da BH-SMT.

A influência de cada fator condicionante obtida no modelo SVM pode ser comparada com a ponderação utilizada nos modelos AHP-TOPSIS-2N modificado e AHP-SVM, conforme demonstra a Figura 44.




Figura 44 - Sensibilidade dos fatores condicionantes - comparativo entre os modelos.

A análise de sensibilidade dos fatores condicionantes utilizados no modelo SVM aponta maior importância para a cobertura da terra e uso do solo (11,97%), seguido pelo tipo de solo (10,07%) e SHG (9,83%). Vale ressaltar que cada localidade pode apresentar relevâncias diferentes para os mesmos conjuntos, como observados nos estudos analisados na revisão bibliométrica (Capítulo 4).

Comparando a influência assumida para o modelo SVM em comparação ao peso obtido pelo modelo AHP, revela-se pouca similaridade entre a ponderação realizada pelo AHP e a influência obtida pelo SVM. Os fatores condicionantes com influência similares são curvatura, inclinação e SHG. Em ambas as análises, o fator de maior influência é o de cobertura da terra e uso do solo (17,63% - AHP e 11,97% - SVM). Fundamentado nos valores obtidos pelo AUC para os modelos com base na análise Multicritério em comparação ao modelo baseado em ML (SVM), é plausível inferir que a ponderação adequada dos fatores

condicionantes, assumindo estudos aprofundados da área do mapeamento e criteriosas considerações de especialistas, podem resultar em mapas mais eficientes.

7.5 Discussão

7.5.1 Visão Geral do Método

A inundação é um sistema complexo que envolve variáveis diversificadas. No mapeamento de áreas suscetíveis a inundações, os fatores condicionantes são considerados as variáveis de maior relevância. Um aspecto importante é a verificação de que localidades distintas podem apresentar composições diferentes de fatores condicionantes ou pesos diferentes para um mesmo fator condicionante. Sendo assim, a determinação dos fatores condicionantes deve ser avaliada para cada localidade. Do mesmo modo, a escolha da ponderação dos fatores condicionantes também deve seguir os critérios analisados para a respectiva modelagem.

Exemplificando, ao analisar estudos que foram aplicados em áreas de clima desérticos (EL-MAGD; AMER; EMBABY, 2020; ABUZIED *et al.*, 2016; AL-JUAIDI; NASSAR; AL-JUAIDI, 2018; EL-HADDAD *et al.*, 2021), por vezes, mesmo os estudos incorporando o fator condicionante do tipo do solo, a influência verificada é baixa em comparação a influência desse mesmo fator neste estudo. Esse fato pode ser atribuído a variabilidade do próprio fator condicionante, nesse caso, ao apresentar apenas um único tipo de solo, a variável se apresenta como uma constante do sistema. Sendo assim, permite-se concluir que a aplicação de variáveis com baixa variabilidade ou de constantes em modelagem similares a aplicada neste estudo é passível de desconsideração na formulação da modelagem, podendo gerar ganhos no custo computacional, sem perda de eficiência do resultado final.

Dentre os fatores condicionantes empregados neste estudo, a cobertura da terra e o uso do solo se destacou como a variável de maior influência nas modelagens executadas. Outros fatores condicionantes significativos são o tipo de solo e SHG, os quais demonstram relevância nesta pesquisa, visto que a influência atribuída a eles possa representar, em partes, a impermeabilização do solo ou insuficiência na taxa de infiltração (SHG), o que pode caracterizar o acúmulo de água na superfície em eventos de precipitações pluviométricas. A evidência pode ser validada em função do inventário de inundação.

O sucesso de um modelo de mapeamento a propensão a um evento natural depende direta ou indiretamente dos fatores condicionantes, de um método para treinamento (casos de modelos baseados em ML com aprendizado supervisionado) e validação (DANO, 2019; BUI, 2020; DAS; GUPTA, 2021). Deste modo, o inventário de históricos indicando os pontos de inundações e não inundações, deve ser considerado também como um fator relevante na modelagem. A importância da obtenção de dados consistentes pode garantir o sucesso ou o fracasso do mapeamento de áreas suscetíveis a inundações, principalmente, em modelos que apresentem aprendizado supervisionado, como o SVM.

Verifica-se eficiência com certa paridade nos modelos avaliados neste estudo, apresentando uma leve vantagem o modelo híbrido AHP-SVM ($AUC = 0,962$). A eficiência obtida independente do modelo empregado, se fundamentado em Multicritério, em ML ou ainda híbrido, está diretamente relacionada aos dados de entrada, como os fatores condicionantes e o inventário de inundações. Destaca-se, dentre os modelos avaliados, o SVM ($AUC = 0,930$), o qual possibilita uma aplicação simplificada em comparação aos modelos Multicritério, devido ao fato de análises baseadas em modelos Multicritérios considerarem uma ponderação prévia, que por vezes, necessitam de acuradas opiniões de um ou mais especialistas. Isso faz ainda que, em comparação aos modelos com base em Multicritério, proporcione o modelo SVM a eliminação da subjetividade, minimizando erros que possam ser gerados em funções de opiniões não precisas. O modelo SVM proporciona ainda fácil integração a outros modelos, como observado no modelo AHP-SVM aplicado neste estudo, permitindo gerar resultados mais precisos.

Os modelos empregados para mapeamento de suscetibilidade a inundações podem ter avanço em seus empregos, com aplicabilidade em mapeamento de eventos correlacionados aos aspectos hidrogeomorfológicos como, por exemplo, suscetibilidade a escorregamento de encostas, suscetibilidade a erosão e demais eventos relacionados.

O resultado gerado pelo presente estudo serve ainda de base para mapeamento de perigo, se existir a quantificação das perdas relacionadas à ocorrência do evento de inundação e, mapeamento de risco, se correlacionar a probabilidade de ocorrência do evento de precipitação pluviométrica, aplicados neste estudo, por exemplo, período de retorno de precipitação pluviométrica (probabilidade de ocorrência).

7.5.2 Implicações Práticas

A inundação é o evento natural que mais atinge a população, causando prejuízos diversos para a sociedade (MALIK *et al.*, 2021; PHAM *et al.*, 2021B; WANG *et al.*, 2021). Os impactos negativos estão relacionados a vários aspectos, sendo os mais evidenciados as questões financeiras, sociais, tecnológicas e ambientais (MARCELINO; NUNES; KOBİYAMA, 2006; GUHA-SAPIR *et al.*, 2012; CRED, 2022). Conforme revisão realizada no Capítulo 4, os impactos negativos mais referenciados na literatura são o financeiro e o social, vinculados com danos gerados em infraestruturas existentes e perdas de bens e, consequentemente, com impactos sociais que refletem imediatamente na qualidade de vida da população atingida direta ou indiretamente.

Neste estudo, o mapeamento de melhor resultado (AHP-SVM) verificou que a maior parte das áreas que demonstram suscetibilidade alta e muito alta de inundações na BH-SMT são atualmente destinadas a atividades agropecuárias e cuja cobertura da terra é caracterizada como pastagens, seguido por áreas de lavoura e urbanizada. Em uma eventual inundação nas áreas de pastagem e lavoura podem resultar, principalmente, em impactos financeiros negativos, devido à baixa ou perda total de produtividade. Nesses casos, os impactos são sentidos diretamente na população local com perdas financeiras significativas e, indiretamente, na sociedade por meio do aumento de preços em função da demanda de oferta e procura dos produtos alimentícios impactados. Em áreas urbanizadas, a ocorrência de uma eventual inundação pode acarretar perdas financeiras, tecnológicas e ambientais. Algumas das perdas podem ser atribuídas aos danos em infraestrutura, danos em edificações e aumento de poluição em corpos hídricos urbanos, causando alterações de biomas. Independente da área mencionada, os prejuízos gerados refletem na diminuição de qualidade de vida (impacto social).

Visto a relevância do assunto, no Brasil, as questões de ocupação de áreas suscetíveis a inundações são pautadas na legislação federal desde 1979, por meio da Lei de nº 6.766 de 1979, que direciona o planejamento urbano, parcelamento e uso do solo. No Art. 3º estabelece que somente será admitido o parcelamento do solo para fins urbanos em terrenos alagadiços e sujeitos a inundações, antes de tomadas as providências para assegurar o escoamento das águas. E, mais recentemente, através da Lei nº 10.257 de 2001, que constitui diretrizes gerais da política urbana e, Lei nº 12.340 de 2010, que dispõe sobre a transferência de recursos da União a locais atingidos por desastres, determinam que as áreas

suscetíveis a inundações devem ser mapeadas. Pautadas nas leis citadas, criou-se a Política Nacional de Proteção e Defesa Civil (PNPDEC), instituída pela Lei nº 12.608 de 2012, estabelecendo que além do mapeamento das áreas suscetíveis a inundações, essas áreas devem estar definidas na Lei que institui o Plano Diretor Municipal. Assim, o mapeamento de áreas suscetíveis a inundações é fundamentado por lei, responsabilizando os municípios pela execução do levantamento das áreas propensas a inundações.

Contudo, mesmo as leis instituindo a obrigatoriedade do mapeamento de áreas suscetíveis a inundações para ordenamento e parcelamento do solo, observa-se que a aplicação é falha ou até mesmo inexistente. A comprovação disso é que dos 5.570 municípios brasileiros, apenas 531 apresentam cartas de suscetibilidade a movimentos gravitacionais de massa e inundações no banco de dados do Serviço Geológico Brasileiro (CPRM, 2022). Outro ponto constatado é a falta de políticas públicas para remediações de áreas já urbanizadas que são afetadas por inundações. Sendo assim, é essencial que haja a verificação do cumprimento das legislações existentes e, ainda, a necessidade da criação de leis que definam diretrizes de remediações de áreas afetadas.

São inúmeros os estudos que se debruçam em indicar, comprovar, exemplificar e oferecer alternativas sobre as mudanças climáticas e, suas incontáveis implicações, presentes em todo o mundo, interligando a atuação humana desordenada como fonte impulsionadora das transformações a longo prazo nos padrões de temperatura e clima do globo terrestre e, consequentemente, alterando os fenômenos naturais (SILVA *et al.*, 2007; PARMESAN; YOHE, 2003; OLABI *et al.*, 2022).

Importante aspecto é que a ocorrência do evento de inundações na natureza faz parte do ciclo hidrológico natural do meio. E, o levantamento e a conservação dessas áreas devem ser considerados pelos órgãos públicos.

Com isso, a necessidade de identificar áreas em situações vulneráveis, sejam elas relacionadas à ocupação humana ou à conservação do ecossistema. A identificação serve de fundamento para a aplicação de políticas públicas com o intuito de minimizar os riscos envolvidos.

A mudança do meio é dinâmica, dessa maneira, é imprescindível que mapeamentos como o apresentado neste estudo sejam atualizados continuamente.

Dentre os vários tipos de soluções de engenharia ligados às tentativas de mitigar ou eliminar problemas de alagamento, dentre elas Engenharia Hidráulica e Engenharia Hidrológica, o principal produto gerado neste projeto (mapa de áreas suscetíveis a

inundações) é uma solução ligada ao contexto da Engenharia Ambiental, com potencial de colaborar no planejamento da organização territorial da BH-SMT principalmente nos seguintes eixos:

Indicar áreas onde a expansão urbana deve ser evitada e intensamente monitorada, com o intuito de evitar ocupações irregulares, pois certamente haverá problemas de perdas econômicas e até mesmo de vidas, devido a inundações.

- Apontar áreas onde a expansão de malhas rodoviárias deve ser evitada;
- Conservar áreas naturais em que o evento de inundações demonstre ser uma variável importante para manutenção da vida local;
- Em projetos de restauração florestal, nas áreas sujeitas a alagamento, sugerir escolha de espécies vegetais tolerantes a períodos de alagamento para plantio;
- Em atividades pecuárias, evitar construir instalações para abrigo de animais (bois, porcos, cabras, ovelhas, aves, dentre outros) a fim de evitar prejuízos em termos de perdas econômicas e de vidas animais.

Ou seja, possui amplo potencial de ser incorporado ou considerado quando da formulação ou revisão de instrumentos de políticas ambientais tais como Planos Diretores e Zoneamento Ecológico-Econômico.

7.5.3 Implicações Futuras

Considerando a abrangência e constante atualização de estudos e aplicabilidades plausíveis, bem como os recortes e limites que permeiam toda pesquisa acadêmica, este estudo também se deparou com caminhos e temas interessantes com os quais não foi possível e oportuno seguir ou se aprofundar. Assim sendo, aproveitamos o espaço final da tese para compartilhar sugestões e inquietações que surgiram no caminhar do estudo e que podem motivar futuros pesquisadores da área. A seguir, estão listados esses assuntos e temas relacionados à sequência natural deste trabalho:

- Mapeamento de perigo da BH-SMT, de maneira a identificar e quantificar os possíveis impactos, provendo com melhor eficiência a gestão pública desses locais;

- Mapeamento de risco da BH-SMT, com intuito de associar as áreas suscetíveis a inundações com a probabilidade de ocorrência do evento. O resultado pode elencar as prioridades para eventuais ações de mitigações;
- Aplicação prática de ferramentas para minimização de inundações, demonstrando as principais ferramentas para minimização de inundações, a aplicabilidade e os custos envolvidos;
- Mapeamento de eventos hidrogeofísicos da BH-SMT, como deslizamentos de terra, erosão e subsidência. Esses levantamentos podem contribuir para informatizar ainda mais os municípios que compõem a BH-SMT;
- Atualização do mapeamento de suscetibilidade a inundações da BH-SMT, com prazo máximo para atualização obedecendo a Lei nº 10.257 de 2001 que estabelece o período de 10 anos para revisão dos Planos Diretores municipais. Porém, a consideração da alteração dinâmica do meio de ser o ponto de referência como critério de atualizações. Sendo assim, intervalos menores devem ser considerados.

A necessidade de atualização de mapas e simulações de modelagem se justificam principalmente por dois aspectos, o primeiro se caracteriza em função do fator condicionante eleito como mais sensível na modelagem (cobertura da terra) ser dinâmico, ou seja, está sempre mudando em função de mudanças tecnológicas, econômicas, demográficas, dentre outras. Por outro lado, ainda que o fator pluviométrico não tenha sido contemplado na presente modelagem por razões já explicadas, há de se considerar a realidade atual sobre mudanças climáticas, onde as características sobretudo das chuvas já são bem diferentes e tendem a mudar ainda mais.

Mapeamentos complementares, em escalas espaciais mais detalhadas nos pontos identificados como muito alta e alta suscetibilidade, certamente irão ajudar a indicar, com mais detalhes, locais mais específicos conforme o nível de vulnerabilidade a inundações.

8. CONSIDERAÇÕES FINAIS

Diversas premissas têm mérito para motivar e justificar uma pesquisa científica. Naturalmente, aquelas que se propõem a compreender, orientar e até prevenir desastres, conseqüentemente, buscando evitar ou minimizar prejuízos humanos, ambientais e financeiros, fortalecem ainda mais a laboriosa, porém, distinta trajetória de contribuição para o conhecimento na área em estudo e a possibilidade de subsidiar seguramente decisões que atingem a vida de milhares de pessoas. Trata-se do relevante processo de unir elementos teóricos, estudos anteriores e o constante avanço tecnológico para aplicá-los ao cotidiano da população.

Deste modo, estimulado pelo impacto que o fenômeno das inundações provoca ano a ano no Brasil e no Mundo, sendo registrado como o evento geofísico e relacionado ao clima que mais ocorre em nosso planeta, conforme informações de 2021 no Banco de Dados de Desastres Internacionais (EM-DAT), este trabalho identificou no mapeamento de áreas suscetíveis a inundações uma direção para prognosticar eventos próximos e, principalmente, fundamentar ações conscientes e planejadas para impedir desastres futuros.

Assim sendo, esta pesquisa aplicou os modelos AHP-TOPSIS-2N modificado, SVM e o modelo híbrido AHP-SVM para mapeamento de áreas suscetíveis a inundações. Para a validação, foi realizada a aplicação em um estudo de caso na Bacia Hidrográfica do Rio Sorocaba e Médio Tietê (BH-SMT), que além da localização oportuna, destaca-se por sua extensão, localização e adensamento demográfico ao ser composta por 34 municípios de São Paulo, o estado mais populoso e a maior economia do Brasil, totalizando uma população estimada de 2.298.550 habitantes (IBGE, 2022).

Com o objetivo de servir de suporte teórico e direcionar este estudo, realizou-se uma revisão estruturada, através da qual se constatou a autenticidade e necessidade do trabalho proposto, visto que apenas dois estudos referentes a mapeamento de áreas suscetíveis a inundações foram aplicados no Brasil (OLIVEIRA CAMPOS; PAZ, 2020; SANTOS; PINHEIRO; JUNIOR, 2021), todavia, com abordagem sem similaridade com este estudo. A revisão estruturada embasa ainda o emprego de maneira inédita do modelo AHP-TOPSIS-2N modificado aplicado ao mapeamento de áreas suscetíveis a inundações.

Dentre os resultados alcançados nesta tese, os fatores condicionantes são evidenciados ao registrarem elevada influência no mapeamento e oferecerem ampla possibilidade de reflexão, indicando a importância e pertinência na caracterização de áreas

suscetíveis a inundação. Ao definir e estudar cada fator condicionante que iria compor o mapeamento, a pesquisa não apenas fortalece sua acuidade e eficiência, como permite que o resultado ofereça mais do que pontos de atenção. O mapeamento permite um diagnóstico aprofundado dos causadores, intensificadores e ou influenciadores das inundações.

A influência de cada fator condicionante é verificada por meio da Razão de Consistência nos modelos ponderados pelo AHP e pelo teste de *Jackknife* aplicado ao modelo SVM. A análise aponta a cobertura da terra e uso do solo como o fator condicionante de maior influência de suscetibilidade ao evento de inundação. Portanto, além de alertar e caracterizar essas áreas, o resultado indica a magnitude da ação humana diante de fenômenos e desastres ambientais ao ocasionar, por exemplo, a impermeabilização do solo com suas atividades.

Durante as visitas técnicas em campo, grande quantidade dos pontos de inundações inventariados pertinentes à cobertura da terra e uso do solo tem relação direta com áreas urbanizadas, o que demonstra a ausência ou insuficiência de infraestrutura de drenagens pluviais. Logo, essa apuração expande e denuncia a urgência em discutir as políticas públicas referentes ao planejamento social e urbano dos municípios, estados e países, reforçando, ainda, o contínuo e ensurdecido alerta de ambientalistas e estudiosos da área sobre as consequências diretas da ação humana diante dos desastres vivenciados não apenas no Brasil, mas em todo o planeta (SILVA *et al.*, 2007; PARMESAN; YOHE, 2003; OLABI *et al.*, 2022).

Considerando, portanto, o objetivo e desejo de que o resultado desta pesquisa tenha aplicabilidade prática na tomada de decisões de órgãos públicos e instituições das mais diversas instâncias cabíveis, era essencial que o modelo proposto fosse simples e eficaz, satisfatoriamente, exatamente como ele se apresentou, afastando-se em partes da necessidade de dedução humana, mesmo com o uso de aspectos multidisciplinares e, aproximando-se de uma realidade contextualizada, visto que o mapeamento sugerido é fundamentado em informações históricas de inundações e em fatores condicionantes topográficos, hidrológicos, geológicos e antropológicos.

Por meio da AUC, verificou-se a eficiência dos modelos aplicados no mapeamento de suscetibilidade a inundações. O modelo híbrido AHP-SVM apresentou o melhor resultado, com $AUC = 0,962$. Os modelos AHP-TOPSIS-2N modificado aplicando a normalização correlacionada juntamente com o modelo SVM demonstraram alta eficiência, com taxa de predição de áreas suscetíveis a inundações de AUC superior a 90%. Dentre os

modelos avaliados, o SVM possibilita fácil aplicação, permitindo a minimização de erros em função da eliminação da subjetividade. O modelo se mostra também de fácil hibridização, conforme observado pelo AHP-SVM. Ambas as vantagens podem influenciar em respostas mais consistentes.

O mapeamento de áreas suscetíveis a inundações da Bacia Hidrográfica do Rio Sorocaba e Médio Tietê pelo modelo híbrido AHP-SVM apontou que 24,09% das áreas que compõem a bacia apresentam suscetibilidade alta e 3,32% suscetibilidade muito alta, ou seja, quase um terço de todo o território da BH-SMT, convive com riscos elevados de lidar com inundações, isso é algo em torno de 3.250 km². Ao observarmos as localizações desses pontos, reconhece-se que, em sua maioria, são áreas situadas em altitudes mais baixas, próximas a corpos hídricos. Esses fatores condicionantes são relacionados aos aspectos hidrogeomorfológicos sendo correlacionados, em parte, com a existência natural do evento de inundações. Já os pontos de muito alta e alta suscetibilidade a inundações são relacionados aos fatores de impermeabilização dos solos, principalmente, em áreas urbanizadas, corrobora com a hipótese sobre a extensão da ação humana diante do fenômeno de inundações.

De imediato, esse resultado nos confere duas ponderações importantes para a tomada de decisão. A primeira é utilizar como ferramenta científica de gestão pública capaz de fornecer prognósticos para aplicação de políticas públicas de remediação em áreas já urbanizadas e conservação de áreas de vegetação em que o evento de inundação corresponde ao ciclo natural. Desse modo, o mapeamento permite considerar o contexto atual dessas localidades e buscar intervenções que possam ser capazes de evitar ou minimizar as inundações e todo prejuízo humano e econômico e, prever a preservação ambiental.

A segunda reflexão, é o planejamento em áreas não urbanizadas, o qual o resultado deve ser utilizado como base para direcionando do ordenamento territorial, em outras palavras, utilizar-se dos dados e das características desses espaços levantados pelo mapeamento para a confecção de políticas públicas futuras com propriedade para que a ação humana não intensifique mudanças climáticas e a suscetibilidade de inundações em outras áreas.

REFERÊNCIAS BIBLIOGRÁFICAS

ABEDI, R. *et al.* Flash-flood susceptibility mapping based on XGBoost, random forest and boosted regression trees. **Geocarto International**, 2021.

ABUZIED, S. *et al.* Geospatial risk assessment of flash floods in Nuweiba area, Egypt. **Journal of Arid Environments**, v. 133, p. 54–72, 2016.

ADNAN, M. S. G. *et al.* The use of watershed geomorphic data in flash flood susceptibility zoning: a case study of the Karnaphuli and Sangu river basins of Bangladesh. **Natural Hazards**, v. 99, n. 1, p. 425–448, 2019.

AHMADLOU, M. *et al.* Flood susceptibility assessment using integration of adaptive network-based fuzzy inference system (ANFIS) and biogeography-based optimization (BBO) and BAT algorithms (BA). **Geocarto International**, v. 34, n. 11, p. 1252–1272, 2019.

AHMADLOU, M. *et al.* Flood susceptibility mapping and assessment using a novel deep learning model combining multilayer perceptron and autoencoder neural networks. **Journal of Flood Risk Management**, v. 14, n. 1, 2021.

AHMED, A.; HEWA, G.; ALRAJHI, A. Flood susceptibility mapping using a geomorphometric approach in South Australian basins. **Natural Hazards**, v. 106, n. 1, p. 629–653, 2021.

AITSI-SELMi, A. *et al.* The Sendai framework for disaster risk reduction: Renewing the global commitment to people's resilience, health, and well-being. **International journal of disaster risk science**, v. 6, n. 2, p. 164–176, 2015.

AL-ABADI, A. M. Mapping flood susceptibility in an arid region of southern Iraq using ensemble machine learning classifiers: a comparative study. **Arabian Journal of Geosciences**, v. 11, n. 9, 2018.

ALI, S. A. *et al.* GIS-based comparative assessment of flood susceptibility mapping using hybrid multi-criteria decision-making approach, naïve Bayes tree, bivariate statistics and logistic regression: A case of Topľa basin, Slovakia. **Ecological Indicators**, v. 117, 2020.

AL-JUAIDI, A. E. M.; NASSAR, A. M.; AL-JUAIDI, O. E. M. Evaluation of flood susceptibility mapping using logistic regression and GIS conditioning factors. **Arabian Journal of Geosciences**, v. 11, n. 24, 2018.

ANDREOLA, R. **Support Vector Machines na classificação de imagens hiperespectrais**. 2009.

APRILIA, R.; HIDAYAH, E.; JUNITA K, D. **Frequency ratio application for mapping flood susceptibility in Welang Watershed, East Java**. Em: IOP Conference Series: Earth and Environmental Science. 2021.

ARABAMERI, A. *et al.* Modeling spatial flood using novel ensemble artificial intelligence approaches in northern Iran. **Remote Sensing**, v. 12, n. 20, p. 1–30, 2020.

ARAGÃO, M. B.; DE COLETIVIDADE, A. N. Dicionário Geológico-Geromorfológico. Antônio Teixeira Guerra. Rio de Janeiro: IBGE, 1993. 446 p. ISBN 85-240-0458-4. **Cad. Saúde Públ**, v. 10, n. 2, p. 269–271, 1994.

ARORA, A. *et al.* Optimization of state-of-the-art fuzzy-metaheuristic ANFIS-based machine learning models for flood susceptibility prediction mapping in the Middle Ganga Plain, India. **Science of the Total Environment**, v. 750, 2021A.

ARORA, A. *et al.* Spatial flood susceptibility prediction in Middle Ganga Plain: comparison of frequency ratio and Shannon's entropy models. **Geocarto International**, v. 36, n. 18, p. 2085–2116, 2021B.

AVAND, M.; MORADI, H. R.; LASBOYEE, M. R. Spatial prediction of future flood risk: An approach to the effects of climate change. **Geosciences (Switzerland)**, v. 11, n. 1, p. 1–20, 2021A.

AVAND, M.; MORADI, H.; LASBOYEE, M. R. Spatial modeling of flood probability using geo-environmental variables and machine learning models, case study: Tajan watershed, Iran. **Advances in Space Research**, v. 67, n. 10, p. 3169–3186, 2021B.

AZAREH, A. *et al.* Incorporating multi-criteria decision-making and fuzzy-value functions for flood susceptibility assessment. **Geocarto International**, v. 36, n. 20, p. 2345–2365, 2021.

BEVEN, K. J.; KIRKBY, M. J. A physically based, variable contributing area model of basin hydrology/Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. **Hydrological sciences journal**, v. 24, n. 1, p. 43–69, 1979.

BISHOP, C. M.; NASRABADI, N. M. **Pattern recognition and machine learning**. Springer, 2006. v. 4

BITAR, O. Y. Cartas de suscetibilidade a movimentos gravitacionais de massa e inundações-1: 25.000: nota técnica explicativa. **IPT; CPRM**, 2014.

BOUAMRANE, A. *et al.* A comparison of the analytical hierarchy process and the fuzzy logic approach for flood susceptibility mapping in a semi-arid ungauged basin (Biskra basin: Algeria). **International Journal of River Basin Management**, v. 20, n. 2, p. 203–213, 2020.

BRAUD, I. *et al.* A method to use proxy data of runoff-related impacts for the evaluation of a model mapping intense storm runoff hazard: Application to the railway context. **Natural Hazards and Earth System Sciences**, v. 20, n. 4, p. 947–966, 2020.

BRESSER-PEREIRA, L. C. **O conceito histórico de desenvolvimento econômico revisitado**. 2022.

BUI, Q.-T. *et al.* Verification of novel integrations of swarm intelligence algorithms into deep learning neural network for flood susceptibility mapping. **Journal of Hydrology**, v. 581, 2020.

BURGES, C. J. A tutorial on support vector machines for pattern recognition. **Data mining and knowledge discovery**, v. 2, n. 2, p. 121–167, 1998.

CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução à ciência da geoinformação**. 2001.

CAO, Y. *et al.* Flash flood susceptibility assessment based on geodetector, certainty factor, and logistic regression analyses in Fujian province, China. **ISPRS International Journal of Geo-Information**, v. 9, n. 12, 2020.

CEMADEN, Centro Nacional de Monitoramento e Alertas de Desastres Naturais. Inundação – **CEMADEN**. 2019. Disponível em: <<https://www.cemaden.gov.br/inundacao/>>. Acesso em: 6 dez. 2019.

CHAKRABORTTY, R. *et al.* Flash-flood hazard susceptibility mapping in Kangsabati River Basin, India. **Geocarto International**, 2021.

CHEN, W. *et al.* Modeling flood susceptibility using data-driven approaches of naïve Bayes tree, alternating decision tree, and random forest methods. **Science of the Total Environment**, v. 701, 2020.

CHOU, T.-Y. *et al.* Swarm-based optimizer for convolutional neural network: An application for flood susceptibility mapping. **Transactions in GIS**, v. 25, n. 2, p. 1009–1026, 2021.

CHOUBIN, B. *et al.* An ensemble prediction of flood susceptibility using multivariate discriminant analysis, classification and regression trees, and support vector machines. **Science of the Total Environment**, v. 651, p. 2087–2096, 2019.

CHOWDHURI, I.; PAL, S. C.; CHAKRABORTTY, R. Flood susceptibility mapping by ensemble evidential belief function and binomial logistic regression model on river basin of eastern India. **Advances in Space Research**, v. 65, n. 5, p. 1466–1489, 2020.

CONGEDO, L. Semi-automatic classification plugin for QGIS. **Sapienza Univ**, v. 1, p. 25, 2013.

COSTACHE, R. *et al.* Flash-flood susceptibility assessment using multi-criteria decision making and machine learning supported by remote sensing and GIS techniques. **Remote Sensing**, v. 12, n. 1, 2020A.

COSTACHE, R. *et al.* New neural fuzzy-based machine learning ensemble for enhancing the prediction accuracy of flood susceptibility mapping. **Hydrological Sciences Journal**, v. 65, n. 16, p. 2816–2837, 2020B.

COSTACHE, R.; NGO, P. T. T.; BUI, D. T. Novel ensembles of deep learning neural network and statistical learning for flash-flood susceptibility mapping. **Water (Switzerland)**, v. 12, n. 6, 2020.

COSTACHE, R.; TIEN BUI, D. Identification of areas prone to flash-flood phenomena using multiple-criteria decision-making, bivariate statistics, machine learning and their ensembles. **Science of the Total Environment**, v. 712, 2020.

COSTACHE, R. *et al.* Detection of areas prone to flood risk using state-of-the-art machine learning models. **Geomatics, Natural Hazards and Risk**, v. 12, n. 1, p. 1488–1507, 2021.

CPRM, Serviço Geológico do Brasil. **Cartas de Suscetibilidade a Movimentos Gravitacionais de Massa e Inundações**. 2022. Disponível em: <<http://www.cprm.gov.br/publique/Gestao-Territorial/Prevencao-de-Desastres-Naturais/Cartas-de-Suscetibilidade-a-Movimentos-Gravitacionais-de-Massa-e-Inundacoes-5379.html>>. Acesso em: 12 maio. 2022.

CRED, Centre for Research on the Epidemiology of Disasters. **Disasters in numbers - 2021**. 2022. Disponível em: <https://www.emdat.be/publications?field_publication_type_tid=All&field_publication_published=asc&field_publication_year=desc>. Acesso em: 23 maio. 2022.

DA COSTA, A. F. *et al.* Incentivo a Participação Popular e ao Empoderamento da Sociedade Civil: Observatório do CBH-SMT. **Revista Guarã**, n. 6, 2016.

DAHRI, N.; ABIDA, H. Monte Carlo simulation-aided analytical hierarchy process (AHP) for flood susceptibility mapping in Gabes Basin (southeastern Tunisia). **Environmental Earth Sciences**, v. 76, n. 7, 2017.

DANO, U. L. *et al.* Flood susceptibility mapping using GIS-based analytic network process: A case study of Perlis, Malaysia. **Water (Switzerland)**, v. 11, n. 3, 2019.

DA PONTE, Silvana Cristina Silva; DA SILVA OLIVEIRA, Lucas; ZACARDI, Diego Maia. Variação temporal de larvas de peixes de um lago de inundação como subsídio à gestão ambiental. **Journal of Applied Hydro-Environment and Climate**, v. 1, n. 1, p. 1-13, 2019.

DARABI, H. *et al.* Development of a novel hybrid multi-boosting neural network model for spatial prediction of urban flood. **Geocarto International**, 2021A.

DARABI, H. *et al.* A hybridized model based on neural network and swarm intelligence-grey wolf algorithm for spatial prediction of urban flood-inundation. **Journal of Hydrology**, v. 603, 2021B.

DAS, S. Geospatial mapping of flood susceptibility and hydro-geomorphic response to the floods in Ulhas basin, India. **Remote Sensing Applications: Society and Environment**, v. 14, p. 60–74, 2019.

DAS, S. Flood susceptibility mapping of the Western Ghat coastal belt using multi-source geospatial data and analytical hierarchy process (AHP). **Remote Sensing Applications: Society and Environment**, v. 20, 2020.

DAS, S.; GUPTA, A. Multi-criteria decision based geospatial mapping of flood susceptibility and temporal hydro-geomorphic changes in the Subarnarekha basin, India. **Geoscience Frontiers**, v. 12, n. 5, 2021.

DAS, S.; SCARINGI, G. River flooding in a changing climate: rainfall-discharge trends, controlling factors, and susceptibility mapping for the Mahi catchment, Western India. **Natural Hazards**, v. 109, n. 3, p. 2439–2459, 2021.

DATAGEO. **DataGEO - Sistema Ambiental Paulista**. 2019. Disponível em: <<http://datageo.ambiente.sp.gov.br/>>. Acesso em: 9 dez. 2019.

DE LIMA, J. B. **Pesquisa qualitativa e qualidade na produção científica em administração de empresas**. 1999.

DE SOUZA, L. P.; GOMES, C. F. S.; DE BARROS, A. P. Implementation of new hybrid AHP–TOPSIS-2N method in sorting and prioritizing of an it CAPEX project portfolio. **International Journal of Information Technology & Decision Making**, v. 17, n. 04, p. 977–1005, 2018.

DHAMODARAN, S.; ALLWYN RAJA, C. Prediction of weather condition using probability function. **International Journal of Applied Engineering Research**, v. 10, n. 4, p. 10665–10670, 2015.

DIAS, D. F.; TRENTIN, R.; DE SOUZA ROBAINA, L. E. Análise e zoneamento geoambiental do município de Rosário do Sul-RS: potencialidades e suscetibilidades. **Revista Geografar**, v. 14, n. 1, p. 70–87, 2019.

DILLEY, M. **Natural disaster hotspots: a global risk analysis**. World Bank Publications, v. 5, 2005.

DING, L. *et al.* A survey of remote sensing and geographic information system applications for flash floods. **Remote Sensing**, v. 13, n. 9, 2021.

DODANGEH, E. *et al.* Integrated machine learning methods with resampling algorithms for flood susceptibility prediction. **Science of the Total Environment**, v. 705, 2020A.

DODANGEH, E. *et al.* Novel hybrid intelligence models for flood-susceptibility prediction: Meta optimization of the GMDH and SVR models with the genetic algorithm and harmony search. **Journal of Hydrology**, v. 590, 2020B.

DOMAKINIS, C. *et al.* Flood susceptibility mapping in erythropotamos river basin with the aid of remote sensing and GIS. **Acta Universitatis Carolinae, Geographica**, v. 55, n. 2, p. 149–164, 2020.

DRUSCH, M. *et al.* Sentinel-2: ESA's optical high-resolution mission for GMES operational services. **Remote Sensing of Environment**, v. 120, p. 25–36, 2012.

EL-HADDAD, B. A. *et al.* Flood susceptibility prediction using four machine learning techniques and comparison of their performance at Wadi Qena Basin, Egypt. **Natural Hazards**, v. 105, n. 1, p. 83–114, 2021.

EL-MAGD, S. A.; AMER, R. A.; EMBABY, A. Multi-criteria decision-making for the analysis of flash floods: A case study of Awlad Toq-Sherq, Southeast Sohag, Egypt. **Journal of African Earth Sciences**, v. 162, 2020.

EM-DAT, The International Disaster Database. **Classification Disaster | EM-DAT**. 2022. Disponível em: <<https://www.emdat.be/classification>>. Acesso em: 22 jun. 2022.

ESA, The European Space Agency. **Sentinel-2**. 2022. Disponível em: <<https://sentinel.esa.int/web/sentinel/missions/sentinel-2>>. Acesso em: 23 jun. 2022.

ESFANDIARI, M. *et al.* Flood hazard risk mapping using a pseudo supervised random forest. **Remote Sensing**, v. 12, n. 19, p. 1–23, 2020A.

ESFANDIARI, M. *et al.* **Flood mapping using random forest and identifying the essential conditioning factors; A case study in fredericton, New Brunswick, Canada**. Em: ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2020B.

FANG, Z. *et al.* Predicting flood susceptibility using LSTM neural networks. **Journal of Hydrology**, v. 594, 2021.

FEIZIZADEH, B.; GHESHLAGHI, H. A.; BUI, D. T. An integrated approach of GIS and hybrid intelligence techniques applied for flood risk modeling. **Journal of Environmental Planning and Management**, v. 64, n. 3, p. 485–516, 2021.

FERREIRA, L. **RJ: moradora de Guaratiba diz que água ficou na altura de seus ombros**. 2019. Disponível em: <<https://noticias.r7.com/rio-de-janeiro/rj-moradora-de-guaratiba-diz-que-agua-ficou-na-altura-de-seus-ombros-10042019>>. Acesso em: 10 abr. 2019.

FITZ, P. R. **Geoprocessamento sem complicação**. Oficina de textos, 2018.

FLORENZANO, T. G. **Iniciação em sensoriamento remoto**. Oficina de Textos, 2007.

FROMENT, R.; BELOW, R. **Disaster year in review 2019**. 2020.

G1. **Forte chuva isola cidades, provoca alagamentos e desabamentos e deixa 12 mortos na Grande SP**. 2019. Disponível em: <<https://g1.globo.com/sp/sao-paulo/noticia/2019/03/11/forte-chuva-isola-areas-na-grande-sao-paulo-e-causa-alagamentos.ghtml>>. Acesso em: 10 abr. 2019.

GITTLEMAN, M. *et al.* Estimating stormwater runoff for community gardens in New York City. **Urban ecosystems**, v. 20, n. 1, p. 129–139, 2017.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. MIT press, 2016.

GOUMRASA, A. *et al.* Flood hazard susceptibility assessment in Chiffa wadi watershed and along the first section of Algeria North–South highway using GIS and AHP method. **Applied Geomatics**, v. 13, n. 4, p. 565–585, 2021.

GUDIYANGADA NACHAPPA, T. *et al.* Flood susceptibility mapping with machine learning, multi-criteria decision analysis and ensemble using Dempster Shafer Theory. **Journal of Hydrology**, v. 590, 2020.

GUDIYANGADA NACHAPPA, T.; MEENA, S. R. A novel per pixel and object-based ensemble approach for flood susceptibility mapping. **Geomatics, Natural Hazards and Risk**, v. 11, n. 1, p. 2147–2175, 2020.

GUHA-SAPIR, D. *et al.* **Annual disaster statistical review 2011: the numbers and trends**. 2012.

HA, H. *et al.* Flash flood susceptibility prediction mapping for a road network using hybrid machine learning models. **Natural Hazards**, v. 109, n. 1, p. 1247–1270, 2021.

HADIPOUR, V.; VAFAIE, F.; DEILAMI, K. Coastal flooding risk assessment using a GIS-based spatial multi-criteria decision analysis approach. **Water (Switzerland)**, v. 12, n. 9, 2020.

HAGHIZADEH, A. *et al.* Forecasting flood-prone areas using Shannon's entropy model. **Journal of Earth System Science**, v. 126, n. 3, 2017.

HAMMAMI, S. *et al.* Application of the GIS based multi-criteria decision analysis and analytical hierarchy process (AHP) in the flood susceptibility mapping (Tunisia). **Arabian Journal of Geosciences**, v. 12, n. 21, 2019.

HANG, H. T. *et al.* Application of Shannon's Entropy model and GIS in flash flood forecasting along national Highway-6, Hoa Binh province, Vietnam. **International Journal of GEOMATE**, v. 21, n. 87, p. 50–57, 2021.

HARLEY, P.; SAMANTA, S. Modeling of inland flood vulnerability zones through remote sensing and GIS techniques in the highland region of Papua New Guinea. **Applied Geomatics**, v. 10, n. 2, p. 159–171, 2018.

HAYKIN, S.; NETWORK, N. A comprehensive foundation. **Neural networks**, v. 2, n. 2004, p. 41, 2004.

HEARST, M. A. *et al.* Support vector machines. **IEEE Intelligent Systems and Their Applications**, v. 13, n. 4, p. 18–28, 1998.

HERBRICH, R. **Learning kernel classifiers: theory and algorithms**. MIT press, 2001.

HONG, H. *et al.* Flood susceptibility assessment in Hengfeng area coupling adaptive neuro-fuzzy inference system with genetic algorithm and differential evolution. **Science of the Total Environment**, v. 621, p. 1124–1141, 2018A.

HONG, H. *et al.* Application of fuzzy weight of evidence and data mining techniques in construction of flood susceptibility map of Poyang County, China. **Science of the Total Environment**, v. 625, p. 575–588, 2018B.

HOSSAIN, M. E. *et al.* **Neuro-fuzzy (NF)-based adaptive flood warning system for Bangladesh**. 2014 International Conference on Informatics, Electronics & Vision (ICIEV). IEEE, 2014.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: theory and applications. **Neurocomputing**, v. 70, n. 1–3, p. 489–501, 2006.

IBGE, Instituto Brasileiro de Geografia e Estatística. **Cidades e Estados | IBGE**. 2022. Disponível em: <<https://www.ibge.gov.br/cidades-e-estados/>>. Acesso em: 23 jun. 2022.

INVEST SP. **Setores de Negócios - São Paulo**. 2022. Disponível em: <<https://www.investe.sp.gov.br/setores-de-negocios/>>. Acesso em: 22 jun. 2022.

IPMET, Instituto de Pesquisas Meteorológicas. **IPMet | Banco de Desastres Naturais**. 2019. Disponível em: <<https://www.ipmetradar.com.br/2desastres.php>>. Acesso em: 9 dez. 2019.

IPT, Instituto de Pesquisas Tecnológicas. **Mapeamento de riscos em encostas e margens de rios**, 2007.

IPT, Instituto de Pesquisas Tecnológicas. Relatório Técnico N. 80 401- 205 - **Atualização do relatório de situação dos recursos hídricos 1995 da bacia do Sorocaba e Médio Tietê (relatório zero) como subsídio à elaboração do plano de bacia**. 2005. Disponível em: <<https://sigrh.sp.gov.br/public/uploads/documents/6930/volume-1-texto.pdf>>. Acesso em: 22 jun. 2022.

IRAWAN, L. Y. *et al.* **Combination of machine learning model (LR-FR) for flash flood susceptibility assessment in Dawuan Sub watershed Mojokerto Regency, East Java**. Em: IOP CONFERENCE SERIES: EARTH AND ENVIRONMENTAL SCIENCE. 2021.

ISLAM, S.; TAHIR, M.; PARVEEN, S. GIS-based flood susceptibility mapping of the lower Bagmati basin in Bihar, using Shannon's entropy model. **Modeling Earth Systems and Environment**, 2021.

JANIZADEH, S. *et al.* Prediction success of machine learning methods for flash flood susceptibility mapping in the Tafresh watershed, Iran. **Sustainability (Switzerland)**, v. 11, n. 19, 2019.

JANIZADEH, S. *et al.* Novel Bayesian Additive Regression Tree Methodology for Flood Susceptibility Modeling. **Water Resources Management**, v. 35, n. 13, p. 4621–4646, 2021.

JULIÃO, R. P. *et al.* **Guia metodológico para a produção de cartografia municipal de risco e para a criação de sistemas de informação geográfica (SIG) de base municipal.** Autoridade Nacional de Proteção Civil, 2009.

KALANTAR, B. *et al.* Deep neural network utilizing remote sensing datasets for flood hazard susceptibility mapping in Brisbane, Australia. **Remote Sensing**, v. 13, n. 13, 2021.

KAMAL, E. *et al.* Contribution of frequency ratio model for flood susceptibility risk analysis: Case of oued toudgha catchment (southern flank of central high atlas, Tinghir-Morocco). **Disaster Advances**, v. 13, n. 8, p. 1–10, 2020.

KANANI-SADAT, Y. *et al.* A new approach to flood susceptibility assessment in data-scarce and ungauged regions based on GIS-based hybrid multi criteria decision-making method. **Journal of Hydrology**, v. 572, p. 17–31, 2019.

KARASIAK, N. Dzetsaka Qgis classification plugin. **Zenodo**, 2016.

KHOSRAVI, K. *et al.* A GIS-based flood susceptibility assessment and its mapping in Iran: a comparison between frequency ratio and weights-of-evidence bivariate statistical models with multi-criteria decision-making technique. **Natural Hazards**, v. 83, n. 2, p. 947–987, 2016A.

KHOSRAVI, K. *et al.* Flash flood susceptibility analysis and its mapping using different bivariate models in Iran: a comparison between Shannon's entropy, statistical index, and weighting factor models. **Environmental Monitoring and Assessment**, v. 188, n. 12, 2016B.

KHOSRAVI, K. *et al.* A comparative assessment of decision trees algorithms for flash flood susceptibility modeling at Haraz watershed, northern Iran. **Science of the Total Environment**, v. 627, p. 744–755, 2018.

KHOSRAVI, K. *et al.* Flood susceptibility mapping at Ningdu catchment, China using bivariate and data mining techniques. **Extreme Hydrology and Climate Variability: Monitoring, Modelling, Adaptation and Mitigation**. p. 419–434, 2019A.

KHOSRAVI, K. *et al.* A comparative assessment of flood susceptibility modeling using Multi-Criteria Decision-Making Analysis and Machine Learning Methods. **Journal of Hydrology**, v. 573, p. 311–323, 2019B.

KHOSRAVI, K. *et al.* Convolutional neural network approach for spatial prediction of flood hazard at national scale of Iran. **Journal of Hydrology**, v. 591, 2020.

KJELDSSEN, T. R. *et al.* Documentary evidence of past floods in Europe and their utility in flood frequency estimation. **Journal of Hydrology**, v. 517, p. 963–973, 2014.

KOTTEK, M. *et al.* **World map of the Köppen-Geiger climate classification updated.** 2006.

LAWAL, D. U. *et al.* group-based decision support for flood hazard forecasting: A geospatial technology-based group analytic hierarchy process approach. **Research Journal of Applied Sciences, Engineering and Technology**, v. 7, n. 23, p. 4838–4850, 2014.

LEE, S. *et al.* Spatial prediction of flood susceptibility using random-forest and boosted-tree models in Seoul metropolitan city, Korea. **Geomatics, Natural Hazards and Risk**, v. 8, n. 2, p. 1185–1203, 2017.

LEE, S. *et al.* Spatial assessment of urban flood susceptibility using data mining and geographic information system (GIS) tools. **Sustainability (Switzerland)**, v. 10, n. 3, 2018.

LI, X. *et al.* Flood risk assessment of global watersheds based on multiple machine learning models. **Water (Switzerland)**, v. 11, n. 8, 2019.

LIUZZO, L.; SAMMARTANO, V.; FRENI, G. Comparison between Different Distributed Methods for Flood Susceptibility Mapping. **Water Resources Management**, v. 33, n. 9, p. 3155–3173, 2019.

LORENA, A. C.; CARVALHO, A. C. P. DE L. F. **Introdução a máquinas de vetores suporte (Support Vector Machines)**. 2003.

LORENA, A. C.; CARVALHO, A. C. Uma introdução a support vector machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43–67, 2007.

LUU, C. *et al.* GIS-based ensemble computational models for flood susceptibility prediction in the Quang Binh Province, Vietnam. **Journal of Hydrology**, v. 599, 2021A.

LUU, C. *et al.* Flood-prone area mapping using machine learning techniques: a case study of Quang Binh province, Vietnam. **Natural Hazards**, v. 108, n. 3, p. 3229–3251, 2021B.

MAHMOUD, S. H.; GAN, T. Y. Multi-criteria approach to develop flood susceptibility maps in arid regions of Middle East. **Journal of Cleaner Production**, v. 196, p. 216–229, 2018A.

MAHMOUD, S. H.; GAN, T. Y. Urbanization and climate change implications in flood risk management: Developing an efficient decision support system for flood susceptibility mapping. **Science of the Total Environment**, v. 636, p. 152–167, 2018B.

MALEKINEZHAD, H. *et al.* Application of entropy weighting method for urban flood hazard mapping. **Acta Geophysica**, v. 69, n. 3, p. 841–854, 2021.

MALIK, S. *et al.* GIS-based statistical model for the prediction of flood hazard susceptibility. **Environment, Development and Sustainability**, v. 23, n. 11, p. 16713–16743, 2021.

MALIK, S.; PAL, S. C. Potential flood frequency analysis and susceptibility mapping using CMIP5 of MIROC5 and HEC-RAS model: a case study of lower Dwarkeswar River, Eastern India. **SN Applied Sciences**, v. 3, n. 1, 2021.

MARANDOLA JR, E.; HOGAN, D. J. Vulnerabilidades e riscos: entre Geografia e Demografia. **Anais**, p. 1–25, 2016.

MARCELINO, E. V.; NUNES, L. H.; KOBIYAMA, M. Banco de dados de desastres naturais: análise de dados globais e regionais/Natural disaster databases: global and regional analysis. **Caminhos de Geografia**, v. 7, n. 19, 2006.

MARCONI, M. *et al.* A rapid method for flood susceptibility mapping in two districts of Phatthalung Province (Thailand): present and projected conditions for 2050. **Natural Hazards**, v. 81, n. 1, p. 329–346, 2016.

MARIANO, E. B.; SOBREIRO, V. A.; DO NASCIMENTO REBELATTO, D. A. Human development and data envelopment analysis: A structured literature review. **Omega**, v. 54, p. 33–49, 2015.

MASOUMI, Z. Flood susceptibility assessment for ungauged sites in urban areas using spatial modeling. **Journal of Flood Risk Management**, v. 15, n. 1, 2021.

MENDONÇA, F.; LEITÃO, S. A. M. Riscos e vulnerabilidade socioambiental urbana: uma perspectiva a partir dos recursos hídricos. **GeoTextos**, v. 4, 2008.

MIRZAEI, S. *et al.* Flood susceptibility assessment using extreme gradient boosting (EGB), Iran. **Earth Science Informatics**, v. 14, n. 1, p. 51–67, 2021.

MITCHELL, T. M. **Machine learning**. McGraw-hill New York, v. 1, 1997.

MOHAMMADI, A. *et al.* Flood detection and susceptibility mapping using sentinel-1 time series, alternating decision trees, and bag-adtree models. **Complexity**, v. 2020, 2020.

MSABI, M. M.; MAKONYO, M. Flood susceptibility mapping using GIS and multi-criteria decision analysis: A case of Dodoma region, central Tanzania. **Remote Sensing Applications: Society and Environment**, v. 21, 2021.

MUDASHIRU, R. B.; SABTU, N.; ABUSTAN, I. Quantitative and semi-quantitative methods in flood hazard/susceptibility mapping: a review. **Arabian Journal of Geosciences**, v. 14, n. 11, 2021.

MUHAMAD, N. *et al.* (The needs of disaster susceptibility map as an input in land use management: A case study of Universiti kebangsaan Malaysia). **Sains Malaysiana**, v. 48, n. 1, p. 33–43, 2019.

MUKHERJEE, F.; SINGH, D. Detecting flood prone areas in Harris County: a GIS based analysis. **GeoJournal**, v. 85, n. 3, p. 647–663, 2020.

NAIMI, B.; ARAÚJO, M. B. sdm: a reproducible and extensible R platform for species distribution modelling. **Ecography**, v. 39, n. 4, p. 368–375, 2016.

NARIMANI, R. *et al.* Application of a novel hybrid method for flood susceptibility mapping with satellite images: A case study of seoul, korea. **Remote Sensing**, v. 13, n. 14, 2021.

NASCIMENTO, M. C. **Contribuição metodológica para seleção de indicadores de vulnerabilidade socioambiental por meio das geotecnologias à Região Metropolitana de Maceió.** 2016.

NATARAJAN, L. *et al.* Flood Susceptibility Analysis in Chennai Corporation Using Frequency Ratio Model. **Journal of the Indian Society of Remote Sensing**, v. 49, n. 7, p. 1533–1543, 2021.

NGO, P.-T. T. *et al.* A novel hybrid quantum-PSO and credal decision tree ensemble for tropical cyclone induced flash flood susceptibility mapping with geospatial data. **Journal of Hydrology**, v. 596, 2021.

NHU, V.-H. *et al.* A new hybrid firefly-pso optimized random subspace tree intelligence for torrential rainfall-induced flash flood susceptible mapping. **Remote Sensing**, v. 12, n. 17, 2020.

OLABI, A. G. *et al.* Assessment of the pre-combustion carbon capture contribution into sustainable development goals SDGs using novel indicators. **Renewable and Sustainable Energy Reviews**, v. 153, p. 111710, 2022.

OLIVEIRA CAMPOS, P. C.; PAZ, I. Spatial diagnosis of rain gauges' distribution and flood impacts: Case study in Itaperuna, Rio de Janeiro-Brazil. **Water (Switzerland)**, v. 12, n. 4, 2020.

ONU BRASIL, Organização das Nações Unidas - Brasil. **Indicadores Brasileiros para os Objetivos de Desenvolvimento Sustentável.** 2022. Disponível em: <<https://odsbrasil.gov.br/>>. Acesso em: 4 jul. 2022.

OTERO, P. **Atlas sócio ambiental—um retrato da bacia hidrográfica dos Rios Sorocaba e Médio Tietê.** São Paulo, v. 5, 2009.

PANAHI, M. *et al.* Flood spatial prediction modeling using a hybrid of meta-optimization and support vector regression modeling. **Catena**, v. 199, 2021A.

PANAHI, M. *et al.* Deep learning neural networks for spatially explicit prediction of flash flood probability. **Geoscience Frontiers**, v. 12, n. 3, 2021B.

PANDEY, M. *et al.* Flood Susceptibility Modeling in a Subtropical Humid Low-Relief Alluvial Plain Environment: Application of Novel Ensemble Machine Learning Approach. **Frontiers in Earth Science**, v. 9, 2021.

PARK, N.-W. Using maximum entropy modeling for landslide susceptibility mapping with multiple geoenvironmental data sets. **Environmental Earth Sciences**, v. 73, n. 3, p. 937–949, 2015.

PARMESAN, Camille; YOHE, Gary. A globally coherent fingerprint of climate change impacts across natural systems. **Nature**, v. 421, n. 6918, p. 37-42, 2003.

PHAM, B. T. *et al.* GIS based hybrid computational approaches for flash flood susceptibility assessment. **Water (Switzerland)**, v. 12, n. 3, 2020A.

PHAM, B. T. *et al.* A comparative study of kernel logistic regression, radial basis function classifier, multinomial naive bayes, and logistic model tree for flash flood susceptibility mapping. **Water (Switzerland)**, v. 12, n. 1, 2020B.

PHAM, B. T. *et al.* Flood risk assessment using hybrid artificial intelligence models integrated with multi-criteria decision analysis in Quang Nam Province, Vietnam. **Journal of Hydrology**, v. 592, 2021A.

PHAM, B. T. *et al.* Can deep learning algorithms outperform benchmark machine learning algorithms in flood susceptibility modeling? **Journal of Hydrology**, v. 592, 2021B.

PHAM, B. T. *et al.* Improved flood susceptibility mapping using a best first decision tree integrated with ensemble learning techniques. **Geoscience Frontiers**, v. 12, n. 3, 2021C.

PHAM, B. T. *et al.* Flood risk assessment using deep learning integrated with multi-criteria decision analysis. **Knowledge-Based Systems**, v. 219, 2021D.

PINTO, C. S. **Curso Básico de Mecânica dos Solos**. Oficina de Textos, 2016.

POURGHASEMI, H. R. *et al.* Multi-hazard probability assessment and mapping in Iran. **Science of the Total Environment**, v. 692, p. 556–571, 2019.

POURGHASEMI, H. R. *et al.* An assessment of metaheuristic approaches for flood assessment. **Journal of Hydrology**, v. 582, 2020.

POURGHASEMI, H. R.; BEHESHTIRAD, M. Assessment of a data-driven evidential belief function model and GIS for groundwater potential mapping in the Koohrang Watershed, Iran. **Geocarto International**, v. 30, n. 6, p. 662–685, 2015.

PRADHAN, B. Flood susceptible mapping and risk area delineation using logistic regression, GIS and remote sensing. **Journal of Spatial Hydrology**, v. 9, n. 2, p. 1–18, 2009.

PRADHAN, B.; YOUSSEF, A. M. A 100-year maximum flood susceptibility mapping using integrated hydrological and hydrodynamic models: Kelantan River Corridor, Malaysia. **Journal of Flood Risk Management**, v. 4, n. 3, p. 189–202, 2011.

PRASAD, P. *et al.* Novel ensemble machine learning models in flood susceptibility mapping. **Geocarto International**, 2021.

QGIS, Org. **Geographic Information System. QGIS Association**. 2022.

RAHMAN, M. *et al.* Flood Susceptibility Assessment in Bangladesh Using Machine Learning and Multi-criteria Decision Analysis. **Earth Systems and Environment**, v. 3, n. 3, p. 585–601, 2019.

RAHMAN, M. *et al.* Location-allocation modeling for emergency evacuation planning with GIS and remote sensing: A case study of Northeast Bangladesh. **Geoscience Frontiers**, v. 12, n. 3, 2021.

RAHMATI, O.; POURGHASEMI, H. R.; ZEINIVAND, H. Flood susceptibility mapping using frequency ratio and weights-of-evidence models in the Golastan Province, Iran. **Geocarto International**, v. 31, n. 1, p. 42–70, 2016.

RAHMATI, O.; POURGHASEMI, H. R. Identification of Critical Flood Prone Areas in Data-Scarce and Ungauged Regions: A Comparison of Three Data Mining Models. **Water Resources Management**, v. 31, n. 5, p. 1473–1487, 2017.

RAHMATI, O. *et al.* Development of novel hybridized models for urban flood susceptibility mapping. **Scientific Reports**, v. 10, n. 1, 2020.

RAMOS, C. **Perigos naturais devidos a causas meteorológicas: o caso das cheias e inundações**. 2013.

RAZAVI TERMEH, S. V. *et al.* Flood susceptibility mapping using novel ensembles of adaptive neuro fuzzy inference system and metaheuristic algorithms. **Science of the Total Environment**, v. 615, p. 438–451, 2018.

REBELLATO, Luciana; CUNHA, Cátia Nunes da. Efeito do "fluxo sazonal mínimo da inundação" sobre a composição e estrutura de um campo inundável no Pantanal de Poconé, MT, Brasil. **Acta Botanica Brasilica**, v. 19, p. 789-799, 2005.

ROSSI, M. **Mapa pedológico do estado de São Paulo: revisado e ampliado**. São Paulo: Instituto Florestal, 2017. E-book, 2017.

ROY, B.; VINCKE, P. Multicriteria analysis: survey and new directions. **European journal of operational research**, v. 8, n. 3, p. 207–218, 1981.

RUSSELL, S.; NORVIG, P. Artificial intelligence: A modern approach prentice-hall. **Englewood cliffs**, 1995.

SAATY, T. L. **Fundamentals of decision making and priority theory with the analytic hierarchy process**. RWS publications, 1994.

SACHDEVA, S.; BHATIA, T.; VERMA, A. K. **Flood susceptibility mapping using GIS-based support vector machine and particle swarm optimization: A case study in Uttarakhand (India)**. Em: 8TH International Conference on Computing, Communications and Networking Technologies, ICCCNT 2017. 2017.

SAHANA, M.; PATEL, P. P. A comparison of frequency ratio and fuzzy logic models for flood susceptibility assessment of the lower Kosi River Basin in India. **Environmental Earth Sciences**, v. 78, n. 10, 2019.

SAMANTA, R. K. *et al.* Flood susceptibility mapping using geospatial frequency ratio technique: a case study of Subarnarekha River Basin, India. **Modeling Earth Systems and Environment**, v. 4, n. 1, p. 395–408, 2018.

SAMELA, C.; MANFREDA, S.; TROY, T. J. Dataset of 100-year flood susceptibility maps for the continental U.S. derived with a geomorphic method. **Data in Brief**, v. 12, p. 203–207, 2017.

SANTOS, E. D. S.; PINHEIRO, H. S. K.; GALLO JUNIOR, H. Height Above the Nearest Drainage to Predict Flooding Areas in São Luiz do Paraitinga, São Paulo. **Floresta e Ambiente**, v. 28, n. 2, p. 1–10, 2021.

SARTORI, A.; LOMBARDI NETO, F.; GENOVEZ, A. M. Classificação hidrológica de solos brasileiros para a estimativa da chuva excedente com o método do Serviço de Conservação do Solo dos Estados Unidos Parte 1: Classificação. **Revista Brasileira de Recursos Hídricos**, v. 10, n. 4, p. 05–18, 2005.

SCHUMANN, G.-P. *et al.* ROC-based calibration of flood inundation models. **Hydrological Processes**, v. 28, n. 22, p. 5495–5502, 2014.

SEMOLINI, R. **Support Vector Machines, inferência transdutiva e o problema de classificação**. Campinas, SP, 2002.

SEPEHRI, M. *et al.* Integration of interval rough AHP and fuzzy logic for assessment of flood prone areas at the regional scale. **Acta Geophysica**, v. 68, n. 2, p. 477–493, 2020.

SHAFAPOUR TEHRANY, M. *et al.* GIS-based spatial prediction of flood prone areas using standalone frequency ratio, logistic regression, weight of evidence and their ensemble techniques. **Geomatics, Natural Hazards and Risk**, v. 8, n. 2, p. 1538–1561, 2017.

SHAFAPOUR TEHRANY, M. *et al.* Evaluating the application of the statistical index method in flood susceptibility mapping and its comparison with frequency ratio and logistic regression methods. **Geomatics, Natural Hazards and Risk**, v. 10, n. 1, p. 79–101, 2019.

SHAFIZADEH-MOGHADAM, H. *et al.* Novel forecasting approaches using combination of machine learning and statistical models for flood susceptibility mapping. **Journal of Environmental Management**, v. 217, p. 1–11, 2018.

SHAHABI, H. *et al.* Flood detection and susceptibility mapping using Sentinel-1 remote sensing data and a machine learning approach: Hybrid intelligence of bagging ensemble based on K-Nearest Neighbor classifier. **Remote Sensing**, v. 12, n. 2, 2020.

SHAHABI, H. *et al.* Flash flood susceptibility mapping using a novel deep learning model based on deep belief network, back propagation and genetic algorithm. **Geoscience Frontiers**, v. 12, n. 3, 2021.

SHAHIRI TABARESTANI, E.; AFZALIMEHR, H. Artificial neural network and multi-criteria decision-making models for flood simulation in GIS: Mazandaran Province, Iran.

Stochastic Environmental Research and Risk Assessment, v. 35, n. 12, p. 2439–2457, 2021.

SHEIKH, V.; KORNEJADY, A.; OWNEGH, M. Application of the coupled TOPSIS–Mahalanobis distance for multi-hazard-based management of the target districts of the Golestan Province, Iran. **Natural Hazards**, v. 96, n. 3, p. 1335–1365, 2019.

SHIRZADI, A. *et al.* A novel ensemble learning based on Bayesian Belief Network coupled with an extreme learning machine for flash flood susceptibility mapping. **Engineering Applications of Artificial Intelligence**, v. 96, 2020.

SIAHKAMARI, S. *et al.* Spatial prediction of flood-susceptible areas using frequency ratio and maximum entropy models. **Geocarto International**, v. 33, n. 9, p. 927–941, 2018.

SILVA, Alexandre Marco da *et al.* Historical land-cover/use in different slope and riparian buffer zones in watersheds of the state of São Paulo, Brazil. **Scientia Agricola**, v. 64, p. 325–335, 2007.

SMOLA, A. J. *et al.* **Advances in large margin classifiers**. MIT press, 2000.

SOUISSI, D. *et al.* GIS-based MCDM–AHP modeling for flood susceptibility mapping of arid areas, southeastern Tunisia. **Geocarto International**, v. 35, n. 9, p. 991–1017, 2020.

SOZER, B. *et al.* **Preliminary investigations on flood susceptibility mapping in Ankara (Turkey) using modified analytical hierarchy process (M-AHP)**. Em: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives. 2018.

SPAUTZ, D. **Tragédia de 2008: Itajaí teve 85% do território submerso**. 2008. Disponível em: <<https://www.nsctotal.com.br/noticias/tragedia-de-2008-itajai-teve-85-do-territorio-submerso>>. Acesso em: 10 abr. 2019.

SPRINTHALL, R. C. **Basic statistical analysis**. Allyn & Bacon, 2003.

STAMELLOU, E. *et al.* A gis-cellular automata-based model for coupling urban sprawl and flood susceptibility assessment. **Hydrology**, v. 8, n. 4, 2021.

STATHOPOULOS, N. *et al.* Introducing flood susceptibility index using remote-sensing data and geographic information systems: Empirical analysis in sperchios River Basin, Greece. Em: **Remote Sensing of Hydrometeorological Hazards**. p. 381–400, 2017.

STAVROPOULOS, S. *et al.* Mitigating flash floods with the use of new technologies: A Multi-criteria decision analysis to map flood susceptibility for Zakynthos Island, Greece. **Journal of Urban and Regional Analysis**, v. 12, n. 2, p. 233–248, 2020.

SUPPAWIMUT, W. Gis-based flood susceptibility mapping using statistical index and weighting factor models. **Environment and Natural Resources Journal**, v. 19, n. 6, p. 481–493, 2021.

SWAIN, K. C.; SINGHA, C.; NAYAK, L. Flood susceptibility mapping through the GIS-AHP technique using the cloud. **ISPRS International Journal of Geo-Information**, v. 9, n. 12, 2020.

TALUKDAR, S. *et al.* Flood susceptibility modeling in Teesta River basin, Bangladesh using novel ensembles of bagging algorithms. **Stochastic Environmental Research and Risk Assessment**, v. 34, n. 12, p. 2277–2300, 2020.

TANG, X. *et al.* Flood susceptibility assessment based on a novel random Naïve Bayes method: A comparison between different factor discretization methods. **Catena**, v. 190, 2020.

TANG, Z.; YI, S.; XIAO, Y. A probabilistic GIS-OWA approach for flood susceptibility assessment. Em: **International Conference on Geoinformatics**, v. 2017- August, 2017.

TEHRANY, M. S.; PRADHAN, B.; JEBUR, M. N. Spatial prediction of flood susceptible areas using rule based decision tree (DT) and a novel ensemble bivariate and multivariate statistical models in GIS. **Journal of Hydrology**, v. 504, p. 69–79, 2013.

TEHRANY, M. SH.; JONES, S. **Evaluating the variations in the flood susceptibility maps accuracies due to the alterations in the type and extent of the flood inventory.** Em: INTERNATIONAL ARCHIVES OF THE PHOTOGRAMMETRY, REMOTE SENSING AND SPATIAL INFORMATION SCIENCES - ISPRS ARCHIVES. 2013.

TEHRANY, M. S. *et al.* Flood susceptibility mapping using integrated bivariate and multivariate statistical models. **Environmental Earth Sciences**, v. 72, n. 10, p. 4001–4015, 2014.

TEHRANY, M. S.; PRADHAN, B.; JEBUR, M. N. Flood susceptibility mapping using a novel ensemble weights-of-evidence and support vector machine models in GIS. **Journal of Hydrology**, v. 512, p. 332–343, 2014.

TEHRANY, M. S. *et al.* Flood susceptibility assessment using GIS-based support vector machine model with different kernel types. **Catena**, v. 125, p. 91–101, 2015.

TEHRANY, M. S.; PRADHAN, B.; JEBUR, M. N. Flood susceptibility analysis and its verification using a novel ensemble support vector machine and frequency ratio method. **Stochastic Environmental Research and Risk Assessment**, v. 29, n. 4, p. 1149–1165, 2015.

TEHRANY, M. S.; KUMAR, L. The application of a Dempster–Shafer-based evidential belief function in flood susceptibility mapping and comparison with frequency ratio and logistic regression methods. **Environmental Earth Sciences**, v. 77, n. 13, 2018.

TEHRANY, M. S.; JONES, S.; SHABANI, F. Identifying the essential flood conditioning factors for flood prone area mapping using machine learning techniques. **Catena**, v. 175, p. 174–192, 2019.

TEHRANY, M. S.; KUMAR, L.; SHABANI, F. A novel GIS-based ensemble technique for flood susceptibility mapping using evidential belief function and support vector machine: Brisbane, Australia. **PeerJ**, v. 2019, n. 10, 2019.

TELLA, A.; BALOGUN, A.-L. Ensemble fuzzy MCDM for spatial assessment of flood susceptibility in Ibadan, Nigeria. **Natural Hazards**, v. 104, n. 3, p. 2277–2306, 2020.

TIEN BUI, D. *et al.* Hybrid artificial intelligence approach based on neural fuzzy inference model and metaheuristic optimization for flood susceptibility modeling in a high-frequency tropical cyclone area using GIS. **Journal of Hydrology**, v. 540, p. 317–330, 2016.

TIEN BUI, D.; HOANG, N.-D. A Bayesian framework based on a Gaussian mixture model and radial-basis-function Fisher discriminant analysis (BayGmmKda V1.1) for spatial prediction of floods. **Geoscientific Model Development**, v. 10, n. 9, p. 3391–3409, 2017.

TIEN BUI, D. *et al.* New hybrids of ANFIS with several optimization algorithms for flood susceptibility modeling. **Water (Switzerland)**, v. 10, n. 9, 2018.

TIEN BUI, D. *et al.* Flash flood susceptibility modeling using an optimized fuzzy rule based feature selection technique and tree based ensemble methods. **Science of the Total Environment**, v. 668, p. 1038–1054, 2019A.

TIEN BUI, D. *et al.* A novel hybrid approach based on a swarm intelligence optimized extreme learning machine for flash flood susceptibility mapping. **Catena**, v. 179, p. 184–196, 2019B.

TIEN BUI, D. *et al.* Flood spatial modeling in Northern Iran using remote sensing and GIS: A comparison between evidential belief functions and its ensemble with a multivariate logistic regression model. **Remote Sensing**, v. 11, n. 13, 2019C.

TIEN BUI, D. *et al.* A new intelligence approach based on GIS-based Multivariate Adaptive Regression Splines and metaheuristic optimization for predicting flash flood susceptible areas at high-frequency tropical typhoon area. **Journal of Hydrology**, v. 575, p. 314–326, 2019D.

TIEN BUI, D. *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, 2020.

TIRYAKI, M.; KARACA, O. Flood susceptibility mapping using GIS and multicriteria decision analysis: Saricay-Çanakkale (Turkey). **Arabian Journal of Geosciences**, v. 11, n. 14, 2018.

TOWFIQUL ISLAM, A. R. M. *et al.* Flood susceptibility modelling using advanced ensemble machine learning models. **Geoscience Frontiers**, v. 12, n. 3, 2021.

TZENG, G.-H.; HUANG, J.-J. **Multiple attribute decision making: methods and applications**. CRC press, 2011.

ULLAH, N.; CHOUDHURY, P. **Flood forecasting in river system using ANFIS**. AIP Conference Proceedings. American Institute of Physics, 2010.

UNOPS, U. N. O. FOR P. 2020 **Annual Statistical Report on United Nations Procurement: Sustainable Procurement Supplement**. UNOPS Copenhagen, 2021.

VAFAKHAH, M. *et al.* Comparing performance of random forest and adaptive neuro-fuzzy inference system data mining models for flood susceptibility mapping. **Arabian Journal of Geosciences**, v. 13, n. 11, 2020.

VAIDYA, O. S.; KUMAR, S. Analytic hierarchy process: An overview of applications. **European Journal of Operational Research**, v. 169, n. 1, p. 1–29, 2006.

VERGARA, S. C.; PECL, A. Escolhas metodológicas em estudos organizacionais. **Organizações & Sociedade**, v. 10, p. 13–26, 2003.

VIEIRA, E. T.; DOS SANTOS, M. J. Desenvolvimento econômico regional—uma revisão histórica e teórica. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 8, n. 2, 2012.

VOJTEK, M.; VOJTEKOVÁ, J. Flood susceptibility mapping on a national scale in Slovakia using the analytical hierarchy process. **Water (Switzerland)**, v. 11, n. 2, 2019.

VOJTEK, M. *et al.* Comparison of multi-criteria-analytical hierarchy process and machine learning-boosted tree models for regional flood susceptibility mapping: a case study from Slovakia. **Geomatics, Natural Hazards and Risk**, v. 12, n. 1, p. 1153–1180, 2021.

VON ZUBEN, I.-P. F. J.; VERONEZE, R. Máquinas de vetores-suporte. **Departamento de Computação Aplicada, Faculdade de Engenharia Elétrica e de Computação, Unicamp**, 2013.

WALLEMACQ, P.; DE ALMEIDA, M. M. Flash floods. Sharing of field experience-Kerala. **Prevention Web**, v. 53, 2018.

WANG, Y. *et al.* Flood susceptibility mapping in Dingnan County (China) using adaptive neuro-fuzzy inference system with biogeography based optimization and imperialistic competitive algorithm. **Journal of Environmental Management**, v. 247, p. 712–729, 2019A.

WANG, Y. *et al.* A hybrid GIS multi-criteria decision-making method for flood susceptibility mapping at Shangyou, China. **Remote Sensing**, v. 11, n. 1, 2019B.

WANG, Y. *et al.* Flood susceptibility mapping using convolutional neural network frameworks. **Journal of Hydrology**, v. 582, 2020.

WANG, Y. *et al.* Flood susceptibility mapping by integrating frequency ratio and index of entropy with multilayer perceptron and classification and regression tree. **Journal of Environmental Management**, v. 289, 2021.

WUBALEM, A. *et al.* Comparison of statistical and analytical hierarchy process methods on flood susceptibility mapping: In a case study of the Lake Tana sub-basin in northwestern Ethiopia. **Open Geosciences**, v. 13, n. 1, p. 1668–1688, 2021.

YANAR, T.; KOCAMAN, S.; GOKCEOGLU, C. Use of Mamdani fuzzy algorithm for multi-hazard susceptibility assessment in a developing urban settlement (Mamak, Ankara, Turkey). **ISPRS International Journal of Geo-Information**, v. 9, n. 2, 2020.

YARIYAN, P. *et al.* Flood susceptibility mapping using an improved analytic network process with statistical models. **Geomatics, Natural Hazards and Risk**, v. 11, n. 1, p. 2282–2314, 2020.

YEGANEH, N.; SABRI, S. Flood vulnerability assessment in Iskandar Malaysia using multi-criteria evaluation and fuzzy logic. **Research Journal of Applied Sciences, Engineering and Technology**, v. 8, n. 16, p. 1794–1806, 2014.

YOUSEFI, S. *et al.* Assessing the susceptibility of schools to flood events in Iran. **Scientific Reports**, v. 10, n. 1, 2020.

YOUSSEF, A. M.; PRADHAN, B.; SEFRY, S. A. Flash flood susceptibility assessment in Jeddah city (Kingdom of Saudi Arabia) using bivariate and multivariate statistical models. **Environmental Earth Sciences**, v. 75, n. 1, p. 1–16, 2016.

ZHAO, G. *et al.* Mapping flood susceptibility in mountainous areas on a national scale in China. **Science of the Total Environment**, v. 615, p. 1133–1142, 2018.

ZHAO, G. *et al.* Assessment of urban flood susceptibility using semi-supervised machine learning model. **Science of the Total Environment**, v. 659, p. 940–949, 2019.

ZHAO, G. *et al.* Urban flood susceptibility assessment based on convolutional neural networks. **Journal of Hydrology**, v. 590, 2020.

ANEXO A

O Anexo A traz uma revisão sucinta dos artigos e trabalhos analisados no Capítulo 4, conforme demonstrado na Tabela 16.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada.

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Pradhan (2009)	Através de um modelo estatístico baseado em SIG, a pesquisa mapeou áreas suscetíveis a inundações na bacia do rio Kelantan, Malásia. Para auxiliar o método foi criado um banco de dados com históricos de áreas inundadas. Obteve-se resultados que apresentaram escala de 1:25.000, o que é compatível com escalas de mapeamentos de riscos. O modelo apresentou desempenho razoável com acurácia de 85%.
1	Pradhan e Youssef (2011)	O mapeamento de suscetibilidade a inundações foi realizado na bacia do rio Kelantan, Malásia. Com auxílio de ferramentas SIG e dados de sensoriamento remoto, o estudo obteve resultado de áreas suscetíveis a inundações para precipitações com períodos de retorno de 100 anos.
1	Tehrany, Pradhan, Jebur (2013)	A pesquisa comparou os desempenhos de predição de duas abordagens diferentes, os métodos estatísticos de <i>Decision Tree</i> (DT) e a combinação de <i>Frequency Ration</i> (FR) e <i>Logistic Regression</i> (LR) para mapear a suscetibilidade a inundações em Kelantan, Malásia. Os resultados mostraram que a acurácia do método DT e o método integrado de FR e LR foi de 87% e 90% para a taxa de sucesso e 82% e 83% para a taxa de predição, respectivamente.
1	Tehrany e Jones (2013)	O estudo examinou o impacto de diferentes formatos e extensões de dados do inventário de cheias no mapa de suscetibilidade, através de um evento extremo de inundação em Brisbane, Austrália, no ano de 2011. Polígonos aleatórios de 1000, 700, 500, 300, 100 e 50 foram selecionados e o mapeamento de suscetibilidade foi realizado usando cada grupo de pontos aleatórios por meio de <i>Logistic Regression</i> (LR). Os resultados apontaram taxas de predição medidas para os mapas de suscetibilidade produzidos por polígonos de 1000, 700, 500, 300, 100 e 50 pontos aleatórios foram de 63%, 76%, 88%, 80%, 74%, 71% e 65%, respectivamente.
1	Lawal et al. (2014)	Um mapeamento por meio do <i>Analytical Hierarchy Process</i> (AHP) baseado em GIS foi realizado para prever as prováveis áreas inundáveis. O resultado demonstrou que a classificação dada pelo mapeamento gerou um grau elevado de correlação em relação ao real.
1	Tehrany et al. (2014)	O estudo combinou a análise de probabilidade bivariada e regressão logística multivariada para produzir mapas de suscetibilidade a inundações na cidade de Busan, Coreia do Sul. Os resultados demonstraram acurácia para a taxa de sucesso de 92,7% e para a taxa de predição de 82,3%.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Tehrany, Pradhan, Jebur (2014)	Neste trabalho, o modelo de <i>Weight of Evidence</i> (WOfE) foi usado para classificar os fatores condicionantes nas inundações por meio de <i>Bivariate Statistical Analysis</i> (BSA). E através do SVM assumindo quatro tipo de funções <i>kernel</i> para mapear áreas suscetíveis a inundações em Terengganu, Malásia. Os resultados apresentaram taxa de sucesso de 94,48% (WOfE) e 95,67% (SVM-função <i>kernel</i> de base radial (RBF)).
1	Yeganeh e Sabri (2014)	O estudo utilizou-se dos métodos baseados em MCDM, em dados de Sistema de Informação Geográfica (SIG), para mapear a suscetibilidade a inundações em Iskandar, Malásia. O mapa de suscetibilidade final indica que cerca de 658 km ² de 1.614 km ² dentro da região apresentam alto nível de suscetibilidade a inundação.
1	Dhamodaran e Allwyn Raja (2015)	Nesse artigo, modelos estatísticos foram utilizados para avaliar o impacto de classes de cada fator condicionante na inundação. Esses fatores condicionantes foram inseridos no modelo SVM. O método proposto se mostrou eficiente, podendo ajudar pesquisadores e governos locais em estratégias de mitigação de inundações.
1	Tehrany <i>et al.</i> (2015)	Quatro tipos funções <i>kernel</i> , <i>Linear</i> (LN), <i>Polynomial</i> (PL), <i>Radial Basis Function</i> (RBF) e <i>Sigmoide</i> (SG) foram utilizados para verificar a robustez do modelo SVM aplicado no mapeamento de áreas suscetíveis a inundações em Terengganu, Malásia. Os resultados apontaram que para o SVM-LN, SVM-PL, SVM-RBF e SVM-SG as taxas de predição foram 84,63%, 83,92%, 84,97% e 81,88%, respectivamente.
2	Tehrany, Pradhan, Jebur (2015)	A pesquisa propôs um novo método integrando SVM e FR para produzir modelagem espacial na avaliação de suscetibilidade a inundações. Os resultados de validação para o método SVM-FR mostraram 88,71 e 85,21% para taxa de sucesso e taxa de predição, respectivamente.
1	Abuzied <i>et al.</i> (2016)	Por meio de uma abordagem integrada de dados geoespaciais e ferramentas de sensoriamento remoto aliados ao <i>ArcHydro tool</i> e ao Serviço de Conservação do Solo, mapeou-se áreas suscetíveis a inundação em Nuwieba, Egito. Através do mapeamento de suscetibilidade foi possível gerar uma carta de risco de inundações repentinas, o que demonstrou ser uma ferramenta de mitigação de inundações.
1	Khosravi <i>et al.</i> (2016B)	O estudo mapeou a suscetibilidade a inundações na Bacia Hidrográfica de Haraz, Irã, por diferentes métodos estatísticos bivariados, incluindo a <i>Shannon's Entropy</i> (SE), o <i>Statistical Index</i> (SI) e o Fator de Ponderação (Wf). Os resultados mostraram que o melhor modelo para estimar a suscetibilidade a inundações com as taxas de previsão de 99,71% foi o SI.
1	Khosravi <i>et al.</i> (2016A)	O estudo mapeou a suscetibilidade a inundações na Bacia Hidrográfica de Haraz, Irã, usando quatro modelos, a FR, WOfE, AHP e modelo conjunto FR-AHP. Os resultados mostraram que o modelo FR teve a maior taxa de predição (96,57%).

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Marconi <i>et al.</i> (2016)	O estudo aplica uma análise de LR nos distritos de Khao Chai Son e Mueang Phatthalung, Tailândia. Os resultados mostraram uma correlação espacial positiva entre a precipitação de monções do nordeste e inundações.
1	Rahmati, Pourghasemi, Zeinivand (2016)	O estudo aplicou modelos de FR e WOfE para mapeamento de suscetibilidade a inundações na província de Golestan, Irã. Os resultados indicaram que os modelos FR (76,47%) e WOfE (74,74%) tiveram resultados razoáveis.
1	Tien Bui <i>et al.</i> (2016)	O artigo propôs uma abordagem baseada no <i>Adaptive Neuro Fuzzy Inference System</i> (ANFIS) e <i>metaheuristic algorithms</i> para modelagem de suscetibilidade a inundações em Tuon Dong, Vietnã. Os resultados demonstram que o modelo MONF é uma ferramenta alternativa no mapeamento de suscetibilidade a inundações.
1	Youssef, Pradhan, Sefry (2016)	O estudo se utiliza dos modelos FR e LR para a geração de mapas de suscetibilidade a inundações para a região de Jeddah, Arábia Saudita. Os resultados da avaliação da acurácia mostraram uma taxa de sucesso de 90,4 e 91,6% e uma taxa de predição de 89,6 e 91,3% para os modelos FR e o modelo conjunto FR- LR.
1	Dahri e Abida (2017)	O estudo mapeou áreas suscetíveis de inundação na Bacia de Gabes, Tunísia, considerando o AHP e SIG associado a uma função de pesos pelo método estatístico de Monte Carlo. O resultado demonstrou intervalos de confiança MC-AHP de 95%, através dos resultados ainda foi possível analisar o risco associado com base em uma precipitação extrema que ocorreu em junho de 2014.
2	Haghizadeh <i>et al.</i> (2017)	A pesquisa propôs um modelo na determinação do potencial de inundação através do modelo de SE. Os resultados geraram um mapa de suscetibilidade a inundação com acurácia do modelo de 73,5% para a área de estudo.
1	Lee <i>et al.</i> (2017)	Os modelos de RF e <i>boosted-tree</i> em um ambiente de SIG são utilizados neste estudo para mapear a suscetibilidade a inundações em Seul, Coréia do Sul. O resultado apontou que o modelo de RF apresentou acurácias de validação melhores (78,78%).
1	Rahmati e Pourghasemi (2017)	O estudo aplicou modelos de <i>Evidential Belief Function</i> (EBF), RF e <i>Boosted Regression Trees</i> (BRT) para mapear áreas suscetíveis a inundações na região de Galikesh, Irã. Os resultados mostraram que os modelos de EBF (78,67%) e de BRT (78,22%) tiveram melhor desempenho do que o modelo de FR (73,33%)
1	Sachdeva, Bhatia, Verma (2017)	Este artigo utilizou o Particle Swarm Optimization (PSO) aplicado ao SVM para avaliação de suscetibilidade a inundações no distrito de Chamoli, Índia. O resultado demonstrou que 1.832,3 km ² são áreas suscetíveis a inundações. O modelo demonstrou uma taxa de predição de 96,55%.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Samela, Manfreda, Troy (2017)	O artigo apresentou um conjunto de mapeamento de suscetibilidade a inundações de 100 anos, para o país Estados Unidos da América, através desse conjunto um método baseado na geomorfometria classificou a hemodinâmica das áreas propensas a inundações. O resultado atingiu um mapeamento de nível continental com resolução de 30m.
1	Shafapour Tehrany <i>et al.</i> (2017)	A pesquisa avaliou o desempenho dos métodos de FR, LR e WOfE no mapeamento de suscetibilidade a inundações na China. Além disso, utilizou os métodos conjuntos de WOfE/LR e FR/LR. Os resultados indicaram que o método conjunto de WOfE-LR apresentou melhor resultado, com taxa de predição de 90,36%.
1	Stathopoulos <i>et al.</i> (2017)	O estudo utilizou-se de dados SIG e ferramentas dispostas no QGIS, nomeado <i>Flood Susceptibility Index</i> (FSI) para mapear suscetibilidade a inundações na Bacia Hidrográfica de Sperchios, Grécia. Os resultados demonstraram que o FSI apresenta uma acurácia de 96,5%.
1	Tang e Xiao (2017)	O estudo aplicou um método baseado no conjunto SIG e <i>Ordered Weighted Averaging</i> (OWA), denominado GIS-OWA para mapear áreas suscetíveis a inundações em Hubei, China. Os resultados demonstraram que os mapeamentos gerados foram consistentes.
1	Tien Bui e Hoang (2017)	Neste estudo, um modelo probabilístico, denominado BayGmmKda, é proposto para avaliação da suscetibilidade a inundações em uma área de estudo em Tuong Duong, Vietnã. Os resultados dos experimentos mostraram que a estrutura híbrida proposta é superior a outros modelos de benchmark, incluindo o ANFIS e o SVM.
1	Al-Abadi (2018)	Este estudo examinou a eficácia de três classificadores, RF, <i>Rotation Forest</i> (RTF) e <i>AdaBoost</i> , na avaliação da suscetibilidade a inundações em uma região árida do sul do Iraque. Os resultados revelaram que o classificador <i>AdaBoost</i> foi o melhor em termos de medidas estatísticas.
1	Al-Juaidi, Nassar, Al-Juaidi (2018)	O artigo investigou a aplicação do modelo de LR para o mapeamento de suscetibilidade a inundações nas áreas do sul da Faixa de Gaza. O resultado mostrou que os mapeamentos tiveram uma taxa de predição de 81%.
1	Harley e Samanta (2018)	A pesquisa avaliou a utilidade do sensoriamento remoto e a MCDM para o mapeamento de suscetibilidade a inundações em Western Highlands, Papua-Nova Guiné. O estudo conseguiu mapear de maneira eficiente áreas mais vulneráveis a inundações.
1	Hong <i>et al.</i> (2018A)	O artigo avaliou a suscetibilidade a inundações utilizando técnicas SIG e ANFIS acoplado aos modelos <i>Differential Evolution</i> (DE) e de <i>Genetic Algorithm</i> (GA) para modelagem espacial de inundação. Os resultados mostraram que o ANFIS-DE obteve as melhores taxas de predição (85,2%).

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Hong <i>et al.</i> (2018B)	O estudo propõe uma nova abordagem para a construção de um mapa de suscetibilidade a cheias em Poyang, China. Sendo assim, foram implementados os métodos de WOfE aliado a Lógica Fuzzy e SVM. O melhor resultado para taxa de predição obtida foi para o método SVM-WOfE (98,65%).
1	Khosravi <i>et al.</i> (2018)	O estudo testou quatro métodos baseados em modelos de aprendizado de máquina, <i>Logistic Model Trees</i> (LMT), <i>Reduced Error Pruning Trees</i> (REPT), <i>Naïve Bayes Trees</i> (NBT) e <i>Alternating Decision Trees</i> (ADT) para mapeamento de suscetibilidade a inundações repentinas na bacia hidrográfica de Haraz, Irã. Os resultados mostram que o modelo ADT possui a maior capacidade de previsão para avaliação de suscetibilidade a inundações repentinas, seguido pelo NBT, o LMT e o REPT.
1	Lee <i>et al.</i> (2018)	Por meio do SIG e modelos de FR e LR, o estudo analisou as relações entre áreas de inundação e fatores hidrológicos relacionados para mapear a suscetibilidade regional à inundação da área metropolitana de Seul, Coreia do Sul. Os resultados de validação para os modelos FR e LR mostraram 79,61% e 79,05% de precisão, respectivamente.
1	Mahmoud e Gan (2018A)	O estudo aplicou MCDM para identificar zonas de suscetibilidade a inundações na província de Riyadh, Arábia Saudita. Os resultados apontaram os principais fatores que contribuem para a suscetibilidade a inundações são o escoamento superficial, o acúmulo de fluxo, o tipo de solo, a elevação, a distância até a rede de drenagem, a densidade de drenagem, o uso da terra, a inclinação e a geologia.
1	Mahmoud e Gan (2018B)	O estudo propôs um sistema de apoio à decisão SIG para delinear zonas de suscetibilidade a inundações nas províncias de El-Beheira e Alexandria, Egito. Como resultado para a província de El-Beheira, 9,2%, 17,9%, 32,3%, 28,3% e 12,3% de sua área são categorizados como muito alta, alta, moderada, baixa e muito baixa suscetibilidade a inundações, respectivamente. Na província de Alexandria, 15,9%, 33,5%, 41%, 8,8% e 0,8% de sua área são categorizados como muito alta, alta, moderada, baixa e muito baixa suscetibilidade a inundações, respectivamente.
1	Samanta <i>et al.</i> (2018)	O estudo aplica FR para mapear áreas suscetíveis a inundações em bacia hidrográfica de Subarnarekha, Índia. A taxa de predição do modelo foi de 81,20%.
1	Razavi Termeh <i>et al.</i> (2018)	O estudo mapeou a suscetibilidade de inundação em Jahrom Township, Irã, usando uma combinação de ANFIS com diferentes algoritmos <i>Ant Colony Optimization</i> (ACO), GA e <i>Particle Swarm Optimization</i> (PSO), onde comparou-se as precisões. O resultado atesta que o modelo ANFIS-PSO teve a maior acurácia (94,5%).

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Tien Bui <i>et al.</i> (2018)	O estudo avaliou três modelos híbridos de otimização de inteligência artificial, ambos aliados ao ANFIS no mapeamento de suscetibilidade na bacia hidrográfica de Haraz, Irã. São eles, <i>Cultural Algorithms</i> (CA), <i>Bees Algorithm</i> (BA) e <i>Invasive Weed Optimization</i> (IWO). O resultado apontou que o método com a melhor taxa de predição é ANFIS-BA (94,4%).
1	Shafizadeh-Moghadam <i>et al.</i> (2018)	Nesta pesquisa, oito modelos individuais de aprendizado de máquina e modelos estatísticos são implementados e comparados. As análises de mapeamento de áreas suscetíveis a inundação aplicada em Haraz, Irã, mostraram que o método de <i>BRT</i> apresentou o melhor resultado, com taxa de predição de 97,5%.
1	Siahkamari <i>et al.</i> (2018)	Este estudo aplicou modelos de FR e <i>Maximum Entropy</i> (MaxEnt) para o mapeamento de suscetibilidade a inundações na bacia hidrográfica de Madarsoo, Irã. A taxa de predição para a FR e MaxEnt foram de 74,3% e 92,6%, respectivamente.
1	Sozer <i>et al.</i> (2018)	A abordagem proposta baseia-se no <i>Modified Analytic Hierarchy Process</i> (M-AHP) para mapear áreas de suscetibilidade em Ancara, Turquia. O método mostrou-se eficaz para avaliar e classificar a importância dos fatores condicionantes.
1	Tehrany e Kumar (2018)	O estudo mapeou áreas suscetíveis a inundações em Brisbane, Austrália, através da <i>Dempester Shafer Theory</i> (DST). O DST demonstrou vantagens em relação a outros métodos estatísticos em função de sua capacidade de avaliar a contribuição dos fatores condicionantes. Os resultados demonstraram taxa de predição de 82,60%. Por se tratar de um método estatístico pode ainda se mostrar um método útil para análise de risco.
1	Tiryaki e Karaca (2018)	A AMCDM foi usada com a ajuda de SIG para determinar possíveis áreas de inundação em Çanakkale, Turquia. O mapeamento resultante descreve a área de estudo sendo dividida em cinco classes, de muito baixa suscetibilidade a suscetibilidade muito alta. De acordo com esses resultados, 13,9% da área de estudo tem alta suscetibilidade, enquanto 14,2% têm suscetibilidade muito alta.
1	Zhao <i>et al.</i> (2018)	O artigo procurou mapear a suscetibilidade a inundações em escala nacional, em uma área de terrenos montanhosos que cobrem cerca de metade da China, para isso foi utilizado o modelo de RF. Os resultados obtidos confirmam que o modelo de RF pode identificar a suscetibilidade a inundação com precisão satisfatória de grandes áreas.
1	Adnan <i>et al.</i> (2019)	O estudo aplicado nas bacias hidrográficas dos rios Karnaphuli e Sangu, Bangladesch baseou-se nas combinações de parâmetros morfométricos para avaliar a suscetibilidade a inundações. O resultado demonstrou que mais de 80% da área total dos 16 subdistritos que compõe as bacias foram determinados como tendo uma suscetibilidade a inundações de nível "alto" a "muito alto"

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Ahmadlou <i>et al.</i> (2019)	Nesta pesquisa, os métodos <i>Biogeography-Based Optimization</i> (BBO) e <i>BAT algorithms</i> (BA) acoplados a o ANFIS foram utilizados para mapear suscetibilidade a inundações em Golestan, Irã. Os resultados indicaram que o ANFIS-BBO teve a maior precisão em comparação com os modelos ANFIS e ANFIS-BA.
1	Choubin <i>et al.</i> (2019)	O estudo empregou dois algoritmos para análise de suscetibilidade a inundações: a <i>Multivariate Discriminant Analysis</i> (MDA), <i>Classification e Regression Trees</i> (CART), incorporadas com um algoritmo amplamente utilizado, o SVM. Os resultados indicaram que o modelo MDA teve a maior precisão preditiva (89%). A análise de sensibilidade mostrou que os fatores condicionantes de inclinação, densidade de drenagem e distância interfluvial foram os fatores mais importantes no mapeamento de suscetibilidade a inundações.
1	Dano <i>et al.</i> (2019)	O estudo utilizou uma abordagem integrada que combina as variáveis derivadas do SIG, do <i>Analytic Network Process</i> (ANP) e do sensoriamento remoto para a avaliação e mapeamento da suscetibilidade a inundações em Perlis, Malásia. O estudo encontrou zonas com suscetibilidades a inundações muito altas e altas, cobrindo 38,4% e 19,0%, respectivamente.
1	Das (2019)	Por meio do método AHP o estudo mapeou áreas suscetíveis a inundações na bacia hidrográfica de Ulhas, Índia. A precisão encontrada para o método foi de 84%.
1	Hammami <i>et al.</i> (2019)	Em Tunis, Tunísia, o mapeamento de suscetibilidade a inundações foi realizado por meio do AHP. O resultado do estudo demonstrou que 20,63% (alto) das áreas analisadas e 51,06% (muito alto).
1	Janizadeh <i>et al.</i> (2019)	Através dos modelos ADT, <i>Functional Tree</i> (FT), <i>Kernel Logistic Regression</i> (KLR), <i>Quadratic Discriminant Analysis</i> (QDA) e <i>Multi-layered Perceptron Neural Network</i> (MLP-NN) foi realizado o mapeamento de áreas suscetíveis a inundações em Tafresh, Irã. A análise dos métodos revelou que ADT foi dominante sobre os outros métodos.
1	Kanani-Sadat <i>et al.</i> (2019)	Com base nos modelos de Lógica Fuzzy e MCDM o estudo obteve desempenho de 93,8% (Fuzzy-DEMATEL ANP) nos mapas de suscetibilidade a inundações em Kurdistan, Irã.
1	Khosravi <i>et al.</i> (2019A)	A pesquisa elaborou mapas das áreas propensas a inundações, através da integração do SIG, da Lógica Fuzzy e do MCDM. Os resultados obtidos demonstraram que cerca de 85% da área analisada foi classificada como muito suscetível a inundações. Os métodos propostos apresentaram ainda altas taxas de predições.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
2	Khosravi <i>et al.</i> (2019B)	O artigo testou três técnicas de MCDM, <i>Vlse Kriterijuska Optamizacija I Komoromisno Resenje</i> (VIKOR), <i>Technique for Order Preference by Similarity to Ideal Solution</i> (TOPSIS) e <i>Simple Additive Weighting</i> (SAW) juntamente com dois métodos de aprendizado de máquina, NBT e <i>Naïve Bayes</i> (NB) para sua capacidade de modelar suscetibilidade a inundações na Bacia Ningdu, China. Os resultados demonstraram que o melhor desempenho apresentado foi do modelo NBT (98%).
1	Li <i>et al.</i> (2019)	O artigo analisou de maneira global a suscetibilidade a inundações. Com base nos modelos RF, LR, NB e <i>AdaBoostM1 Based Credal Decision Tree</i> (ABM-CDT) obteve taxas de predição acima de 95%, destacando-se o modelo RF com 99,3% de eficiência.
1	Liuzzo, Sammartano, Freni (2019)	Fundamentado em SIG e análise estatística, o estudo mapeou áreas suscetíveis a inundações com taxa de predições de FR = 81,0%, FR-LR = 83,4%, FR-SE = 82,7% e SI = 84,4%. O estudo foi aplicado em Devon Country, Inglaterra.
1	Muhamad <i>et al.</i> (2019)	Por meio de três métodos foram produzidos o mapeamento de áreas suscetíveis a escorregamentos e inundações na <i>Universiti Kebangsaan Malaysia</i> (UKM), Malásia. O mapeamento gerado demonstrou vulnerabilidade de inundação nas áreas do campus, se apresentando como uma classe de vulnerabilidade média em uma área total de 6,5 km ² , aproximadamente, quase 56% da área.
1	Pourghasemi <i>et al.</i> (2019)	O estudo aplicado na província de Lorestan, Irã, procurou mapear áreas suscetíveis a inundações e a escorregamentos através do acoplamento dos métodos <i>Step-Wise Weight Assessment Ratio Analysis</i> (SWARA), ANFIS e <i>Gray Wolf</i> (GWO). O resultado demonstrou acurácia de 84% e 80% para inundações e deslizamentos de terra, respectivamente.
1	Rahman <i>et al.</i> (2019)	A partir dos modelos de Artificial Neural Network (ANN), LR, FR e AHP a pesquisa mapeou áreas suscetíveis a inundações. O melhor resultado alcançado de predição foi através do modelo acoplado LR-FR (88,10%).
1	Sahana e Patel (2019)	Áreas propensas a inundações foram mapeadas na parte baixa da bacia hidrográfica do Rio Kosi, Índia. Os modelos empregados têm base na Lógica <i>Fuzzy</i> . Com base na análise as áreas a oeste e ao sul da região foram consideradas mais sujeitas a inundações
1	Shafapour Tehrany <i>et al.</i> (2019)	O estudo procurou mapear áreas propensas a inundações em Brisbane, Austrália. Os modelos empregados foram SI, FR e LR. As taxas de predição foram LR = 79,45%, SI 78,18% e FR = 67,33%.
2	Sheikh, Kornejady, Ownegh (2019)	A pesquisa aplicada em Golestan, Irã procurou mapear áreas suscetíveis a inundações e deslizamentos de terra. O resultado obtido pelo modelo MaxEnt foi de 88,95 e 90,3% para deslizamento de terra e inundação, respectivamente.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Tehrany, Jones, Shabani (2019)	A pesquisa teve como foco avaliar os fatores condicionantes utilizados em mapeamentos de áreas suscetíveis a inundações. Para isso, os autores utilizaram-se dos métodos DT e do SVM para mapeamento das áreas suscetíveis a inundações. Foram considerados dois conjuntos de fatores condicionantes. Como conclusão constatou-se que na avaliação dos conjuntos os fatores adicionais não garantem um melhor resultado, sendo o resultado mais influenciado pelo método de análise. Os melhores resultados de taxa de predição foram para DT e SVM de 85,52% e 88,47% (conjunto de fatores 1), respectivamente.
1	Tehrany, Kumar, Shabani (2019)	A pesquisa avaliou a eficiência do método SI e comparou seus resultados com os resultados dos métodos de FR e LR. As taxas de predição para mapeamento de suscetibilidade em Brisbane, Austrália para LR, SI e FR foram de 79,45%, 78,18% e 67,33%, respectivamente.
1	Tien Bui <i>et al.</i> (2019A)	O estudo baseou-se no algoritmo FURIA baseado na <i>Fuzzy Logic</i> , enquanto o GA foi utilizado com o objetivo de obter um conjunto ótimo de variáveis utilizadas nas avaliações de modelos de suscetibilidade a inundações em Lao Cai, Vietnã. O FURIA-GA foi combinado com os algoritmos <i>LogitBoost</i> , <i>Bagging</i> e <i>AdaBoost</i> . O desempenho do método FURIA-GA- <i>Bagging</i> teve a maior taxa de sucesso (93,37%).
1	Tien Bui <i>et al.</i> (2019A)	O estudo baseou-se no algoritmo FURIA baseado na <i>Fuzzy Logic</i> , enquanto o GA foi utilizado com o objetivo de obter um conjunto ótimo de variáveis utilizadas nas avaliações de modelos de suscetibilidade a inundações em Lao Cai, Vietnã. O FURIA-GA foi combinado com os algoritmos <i>LogitBoost</i> , <i>Bagging</i> e <i>AdaBoost</i> . O desempenho do método FURIA-GA- <i>Bagging</i> teve a maior taxa de sucesso (93,37%).
1	Tien Bui <i>et al.</i> (2019B)	O estudo propôs uma abordagem de integração dos métodos <i>Extreme Learning Machine</i> (ELM) e PSO, denominada PSO-ELM, para a previsão espacial de inundações repentinas. O resultado demonstrou eficiência do modelo proposto com desempenho de previsão de 95,4%.
1	Tien Bui <i>et al.</i> (2019C)	A pesquisa aplicou os métodos EBF e LR na região norte do Irã. A maior taxa de predição atingida foi de 94,55% para o modelo EBF.
1	Tien Bui <i>et al.</i> (2019D)	Os autores avaliaram a suscetibilidade a inundação em Lao Cai, Vietnã através dos modelos <i>Multivariate Adaptive Regression Splines</i> (MARS) e PSO. Os resultados revelaram que o modelo híbrido PSO-MARS se mostrou eficiente (90%).

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Vojtek e Vojteková (2019)	O estudo definiu as zonas de suscetibilidade a inundações para o território da Eslováquia utilizando a técnica AHP e SIG. Verificou-se que 33,1% do território da Eslováquia é caracterizado por altíssima a alta suscetibilidade a inundações. O mapa de suscetibilidade a inundações foi validado com 1513 pontos históricos de inundação mostrando concordância muito boa entre as zonas de suscetibilidade computadas e eventos históricos de inundação dos quais 70,9% foram coincidentes com níveis de suscetibilidade altos e muito altos, confirmando a eficácia da metodologia adotada. O trabalho investigou o uso de uma técnica híbrida integrando <i>Decision-Making Trial and Evaluation Laboratory</i> (DEMATEL), ANP, <i>Weighted Linear Combinations</i> (WLC) e <i>Interval Rough Numbers</i> (IRN) para avaliar o mapeamento de suscetibilidade a inundações em Shangyou, China. O resultado gerou um mapa de suscetibilidade a inundação consistente, com melhores valores de predição para o método WLC (98,8%).
1	Wang <i>et al.</i> (2019B)	Com taxa de predição máxima de 90,44% através do modelo ANFIS-ICA, o estudo conseguiu classificar 35,39% das áreas totais como altamente suscetíveis a inundações em Dingnan, China.
1	Wang <i>et al.</i> (2019A)	A fim de identificar áreas propensas a inundações, utilizou-se um modelo de <i>Weakly Labeled Support Vector Machine</i> (WELLSVM). Os resultados mostram que o WELLSVM pode utilizar melhor as informações espaciais (dados não rotulados), se mostrando aplicável e eficiente.
1	Zhao <i>et al.</i> (2019)	A suscetibilidade a inundações da bacia hidrográfica do Rio Topľa, Eslováquia foi avaliada por meio dos modelos com base em MCDM, FR, SI, NBT e LR. O resultado da avaliação destacou o modelo DEMATEL-ANP com taxa de predição de 92,2%.
1	Ali <i>et al.</i> (2020)	Os classificadores <i>Real AdaBoost</i> , <i>Random Subspace</i> , <i>MultiBoosting</i> e J48 foram aplicados na identificação de áreas propensas a inundações em Golestan, Irã. O resultado demonstrou que o modelo híbrido <i>Random Subspace</i> - J48 foi o que obteve maior taxa de sucesso (93,1%).
2	Arabameri <i>et al.</i> (2020)	Duas técnicas foram empregadas para avaliar a suscetibilidade a inundações (AHP e Lógica Fuzzy) em Biskra Basin, Argélia. O melhor resultado obtido foi de 96,61 para o modelo de Lógica Fuzzy - AHP.
1	Bouamrane <i>et al.</i> (2020)	Nesse estudo o modelo hidrológico <i>Indicator of Intense Pluvial Runoff</i> (IRIP) foi aplicado para analisar a suscetibilidade a inundações em Rouen-Le Havre, França. Os resultados mostram que o método de avaliação é robusto e relevante.
2	Braud <i>et al.</i> (2020)	

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Bui <i>et al.</i> (2020)	O estudo comparou modelos híbridos de <i>Swarm Intelligence Algorithms</i> e <i>Deep Learning Neural Network</i> . Para isso aplicou os modelos em Lai Chau, Vietnã. O resultado demonstrou que todos os modelos se apresentam robustos, destacando-se o modelo <i>Social Spider Optimization</i> (SSO) com predição de 97%.
1	Oliveira Campos e Paz (2020)	Através da <i>Fractal Analysis</i> Itaperuna, Brasil realizou-se uma investigação de mapas de suscetibilidade a inundações com base em transitórios (considerando a precipitação) e permanentes (suscetibilidade natural às cheias). A aplicação possibilitou a validação da metodologia proposta, e permitindo a aplicação em demais regiões.
1	Cao <i>et al.</i> (2020)	Fujian, China teve as áreas propensas a inundações mapeadas por meio dos modelos CF e LR. Os resultados AUC mostraram que o modelo CF-LR teve a melhor precisão em termos de taxa de sucesso (0,860) e taxa de predição (0,882).
1	Chen <i>et al.</i> (2020)	O estudo propôs a comparação de três modelos para mapeamento de áreas suscetíveis a inundações, NBT, ADT e RF. Os modelos foram aplicados em um estudo de caso em Quannan, China. Dos modelos comparados o RF obteve a melhor taxa de predição (95,1%).
1	Chowdhuri, Pal, Chakraborty (2020)	Por meio dos modelos EBF, LR aliado a ferramenta SIG, os pesquisadores mapearam a bacia hidrográfica do Rio Koiya, Índia. O resultado apontou a seguinte precisão para os modelos: 87,9%, 85,2% e 84,1% para os modelos EBF-LR, EBF e LR, respectivamente.
1	Costache e Tien Bui (2020)	Através do modelo híbrido ADT-AHP e <i>ADT-Index of Entropy</i> (IOE) o modelo avaliou a suscetibilidade da bacia hidrográfica do Rio Suha, Romênia. O resultado alcançado foi de 97,2% e 92,6% de predição para ADT-IOE e ADT-AHP, respectivamente.
1	Costache <i>et al.</i> (2020A)	O objetivo do estudo é avaliar o poder preditivo nos modelos AHP, KNN e K-Star (KS). Para isso, o estudo aplicou os modelos em um estudo de caso em Prahova, Romênia. O melhor desempenho é obtido pelo modelo de conjunto KNN-AHP.
1	Costache <i>et al.</i> (2020B)	Por meio dos modelos AHP, ANFIS, WofE e Certainty Factor (CF) a suscetibilidade a inundações foi mapeada na bacia hidrográfica do Rio Trotuş, Romênia. Os resultados mostraram que o modelo ANFIS-CF e o modelo ANFIS-WOE possuem capacidade de predição acima de 91,6%.
1	Costache, Ngo, Tien Bui (2020)	Por meio dos modelos <i>Deep Neural Networks</i> (DNN), AHP e FR foram utilizados para mapear a suscetibilidade em Prahova, Romênia. O resultado mostra que os dois modelos híbridos, DNN-AHP e DNN-FR, apresentam precisão superior a 92%.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Das (2020)	O mapeamento a suscetibilidade e risco a inundações foram realizados em na costa Western Ghat, Índia pelo modelo AHP. Os resultados demonstram que 22% da área analisada demonstra suscetibilidade muito alta.
1	Dodangeh <i>et al.</i> (2020A)	O estudo propôs novos modelos de ML para avaliação de suscetibilidade a inundações. Os modelos BRT, <i>Generalized Additive Model</i> - (GAM), MARS, <i>Radom Subsampling</i> (RS) e <i>Bootstrapping</i> (BT) foram utilizados em um estudo de caso em Ardabil, Irã. O modelo BT-GAM obteve desempenho superior, com AUC = 0,98.
1	Dodangeh <i>et al.</i> (2020B)	O estudo mapeou áreas propensas a suscetibilidade da bacia hidrográfica de Haraz-Neka, Irã. Os modelos aplicados foram <i>Support Vector Regression</i> (SVR), GA, <i>Group Method of Data Dandling</i> (GMDH) e <i>Harmony Search</i> (HS). O resultado demonstra desempenho superior do SVR em relação ao GMDH, e quando otimizados pelos algoritmos GA e HS. Ambos os modelos melhoraram seus desempenhos.
1	Domakinis <i>et al.</i> (2020)	A bacia hidrográfica de Erythrotamos, teve a suscetibilidade a inundações mapeadas por AHP. Os resultados apontaram que aproximadamente 60% de ambas as áreas cruzaram com a zona de alta suscetibilidade do mapa.
1	Abu El-Magd, Amer, Embaby (2020)	O estudo procurou mapear as áreas suscetíveis a inundações em Sohag, Egito por meio de SIG e MCDM. O resultado demonstrou que aproximadamente 5% da área total de estudo está em um risco muito alto de inundação, 10% em um risco alto e 25% em um risco moderado de inundação.
1	Esfandiari <i>et al.</i> (2020A)	Neste estudo o modelo hidrológico <i>Height Above Nearest Drainage</i> foi utilizado em conjunto com RF foi aplicado em Fredericton e Gatineau, Canadá para mapeamento de áreas suscetíveis a inundações. Os resultados confirmam que o modelo RF pode melhorar a previsão de inundação do modelo HAND
1	Esfandiari <i>et al.</i> (2020B)	Fredericton, Canadá teve a suscetibilidade a inundações mapeada através do RF. A precisão obtida foi de 895,14%.
1	Gudiyangada Nachappa e Meena (2020)	A suscetibilidade a inundação foi mapeada em <i>East Rapti Basin</i> , Nepal através dos modelos FR, AHP, EBF. Os resultados demonstraram resultados satisfatórios para todos os modelos, com taxa de predição acima de 90%.
1	Hadipour, Vafaie, Deilami (2020)	Bandar Abbas, Irã, teve suas áreas de risco mapeadas com base no AHP. Cenários foram criados para analisar os riscos. No cenário de inundação mais extremo, 14,8% das áreas inundadas foram identificadas como de alto e muito alto risco.
1	Kamal <i>et al.</i> (2020)	O modelo FR foi utilizado para produzir um mapa de suscetibilidade a inundações em Tinghir, Marrocos. O resultado demonstrou uma eficiência aceitável.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Khosravi <i>et al.</i> (2020)	A suscetibilidade a inundação foi verificada no Irã por meio do CNN. Os resultados também indicaram que aproximadamente 12% e 3% do país são altamente e altamente suscetíveis a eventos futuros de enchentes, respectivamente.
1	Mohammadi <i>et al.</i> (2020)	Os modelos <i>ADTree</i> e <i>bag-ADTree</i> foram usados para o mapeamento da suscetibilidade às inundações em Fanuj, Irã. Com base na AUC, as taxas de sucesso e predição foram 0,736 e 0,786 para o algoritmo <i>bag-ADTree</i> .
1	Mukherjee e Singh (2020)	O estudo incorporou MCDM com base em SIG para determinar áreas propensas a inundações no condado de Harris, Texas. Nesse estudo os resultados obtidos não coincidiram com dados de inundações, porém, os autores afirmam que os métodos baseados em SIG são extremamente úteis na identificação de áreas propensas a inundação.
1	Gudiyangada Nachappa <i>et al.</i> (2020)	O artigo procurou produzir o mapa de suscetibilidade de Salzburgo, Áustria através dos modelos AHP, ANP, RF, SVM e DST. O resultado demonstra que a melhor taxa de predição é através do conjunto dos modelos (89,3%).
2	Nhu <i>et al.</i> (2020)	Objetivo do estudo foi propor um modelo híbrido de <i>Hybrid Firefly-Particle Swarm Algorithm</i> (HFPS) e comparado aos modelos SVM, RF e LMT para mapear a suscetibilidade a inundações em Van Ban, Vietnã. O resultado do estudo demonstrou que o modelo proposto teve a melhor taxa de predição em comparação aos demais modelos.
1	Pham <i>et al.</i> (2020A)	O estudo propôs vários modelos híbridos a partir do DT, os modelos foram utilizados para mapear a suscetibilidade a inundações em Markazi, Irã. O resultado demonstra que o modelo com maior capacidade preditiva é o <i>AdaBoostM1 based Credal Decision Tree</i> (ABM-CDT) (95,7%).
1	Pham <i>et al.</i> (2020B)	Neste estudo os modelos <i>Kernel Logistic Regression</i> (KLR), <i>Radial Basis Function Classifier</i> (RBFC), <i>Multinomial Naïve Bayes</i> (NBM) e LMT foram utilizados para gerar mapas de suscetibilidade a inundações em Nghe Na, Vietnã. O melhor resultado obtido de predição foi para o modelo LMT (98,8%).
1	Pourghasemi <i>et al.</i> (2020)	O estudo utilizou-se de modelos híbridos combinando ANFIS com GA, DE, <i>Imperialist Competitive Algorithm</i> (ICA) e <i>Simulated Annealing</i> (SA) para mapear a suscetibilidade em Dingnan, China. O resultado obtido demonstrou maior eficiência do modelo ANFIS-GA (90,3%).
1	Rahmati <i>et al.</i> (2020)	O estudo procurou avaliar modelos híbridos no mapeamento da suscetibilidade a inundações. Os modelos bases foram o SVR, GWO e <i>Bat Optimizer</i> (Bat). Os modelos híbridos foram aplicados em Amol, Irã. Os resultados demonstraram que ambos os modelos hibridizados (<i>Wavelet-SVR-Bat</i> e <i>Wavelet-SVR-GWO</i>) apresentaram desempenho muito alto.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Sepehri <i>et al.</i> (2020)	A suscetibilidade a inundações foi mapeada em Hamadan, Irã através da ponderação dos fatores condicionantes através de Lógica Fuzzy e AHP. O resultado apontou um mapa de suscetibilidade a inundações eficiente.
1	Shahabi <i>et al.</i> (2020)	O mapeamento de suscetibilidade a inundações foi aplicado em Haraz, Irã. O estudo ainda avaliou a eficiência de modelos híbridos de <i>K-Nearest Neighbor</i> (KNN), o resultado demonstrou resultados satisfatórios.
1	Shirzadi <i>et al.</i> (2020)	O estudo propõe o mapeamento de suscetibilidade a inundações através de um modelo híbrido composto por <i>Bayesian Belief Network</i> (BBN), ELM), <i>Back Propagation</i> (BP) e GA. O estudo foi aplicado em Haraz, Irã. O resultado obtido apontou que o modelo híbrido obteve alta eficiência de predição (96,6%).
1	Souissi <i>et al.</i> (2020)	Nesse estudo a avaliação de áreas propensas a inundações foi realizada através do método AHP, o modelo foi aplicado em Gabes, Tunísia. O resultado demonstrou que 74,51% das áreas se encontram com suscetibilidade moderada a muito alta.
1	Stavropoulos <i>et al.</i> (2020)	O MCDM foi aplicado em Zakynthos Island, Grécia para mapear suscetibilidade a inundações. O resultado foi satisfatório.
1	Swain, Singha, Nayak (2020)	Através do modelo AHP o estudo mapeou a suscetibilidade a inundações em Bihar, Índia. O resultado demonstrou uma área equivalente a 40,36% da total concentrada em zonas classificadas como alta e muito alta suscetibilidade a inundações.
2	Talukdar <i>et al.</i> (2020)	A bacia hidrográfica do Rio Teesta, Bangladesh teve seu mapeamento de suscetibilidade a inundações realizado por meio dos modelos RF, M5P, <i>Decorate-REPT</i> e <i>Random Tree</i> . Para modelagem de suscetibilidade a inundações, o M5P teve desempenho superior, seguido pelo RF, <i>REPTree</i> e <i>Random Tree</i> .
1	Tang <i>et al.</i> (2020)	O modelo híbrido utilizando-se de RF e NB foi estruturado gerando o <i>Random Naïve Bayes</i> (RNB) para mapear áreas suscetíveis em Wanan, China. Os resultados deste artigo provaram que o RNB é uma abordagem viável para a avaliação da suscetibilidade a eventos naturais.
1	Tella e Balogun (2020)	O AHP e Lógica Fuzzy foram utilizados nesse estudo para mapear a suscetibilidade Ibadan, Nigéria. O mapa Fuzzy-AHP teve um alinhamento de 91% com os locais históricos de inundação.
1	Tien Bui <i>et al.</i> (2020)	Através do modelo Deep Learning Neural Network (DLNN) o estudo avaliou áreas propensas a inundações em Lao Cai, Vietnã. O modelo se mostrou eficiente atingindo uma boa taxa de preditiva (95,05%).

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Vafakhah <i>et al.</i> (2020)	O estudo comparou o desempenho dos modelos ANFIS, FR e RF para mapeamento a suscetibilidade em Gilan, Irã. Os resultados da validação dos modelos mostram que os modelos FR, ANFIS e RF tiveram 68,6, 63,9 e 71,3% de sucesso.
1	Wang <i>et al.</i> (2020)	Neste artigo, o modelo <i>Convolutional Neural Network</i> (CNN) é aplicado em Shangyou, China no intuito de mapear áreas suscetíveis a inundações. O modelo apresentou-se eficiente demonstrando taxas de predições acima de 90%.
1	Yanar, Kocaman, Gokceoglu (2020)	Ankara, Turquia, teve o mapeamento de suscetibilidade utilizando-se do modelo M-AHP. Os resultados demonstram que os mapas de avaliação da suscetibilidade a múltiplos perigos para o planejamento urbano podem ser obtidos combinando um conjunto de métodos de aprendizagem baseados em especialistas e em conjunto.
1	Yariyan <i>et al.</i> (2020)	Saqez, Irã, teve o mapeamento de suas áreas suscetíveis a inundações realizadas através dos modelos ANP, FR, EBF e OWA. O resultado obtido indica desempenho superior do modelo híbrido ANP e EBF (ANP-EBF) com 95,1% de eficiência.
1	Yousefi <i>et al.</i> (2020)	O estudo avaliou a suscetibilidade e posteriormente o risco a inundações em Chaharmahal, Irã. Os modelos empregados foram RF, BRT, MARS e NBT. O resultado apontou que para a suscetibilidade o melhor modelo foi o RF (98,9%). Para a análise de risco os resultados indicam que 492 escolas rurais e 147 escolas urbanas estão em locais de muito alto risco.
1	Zhao <i>et al.</i> (2020)	Uma abordagem baseada em CNN foi utilizada para mapear a bacia hidrográfica de Dahongmen, China. O desempenho dos modelos com base em CNN foi comparado com o SVM e RF. O resultado demonstrou melhor desempenho para os modelos com base em CNN.
1	Towfiqul Islam <i>et al.</i> (2021)	Os modelos híbridos Dagging, RS, ANN. RF e SVM foram aplicados na bacia hidrográfica do Rio Teesta, Bangladesh. O resultado demonstrou que o valor de AUC do ROC ficou acima de 0,80 para todos os modelos.
1	Abedi <i>et al.</i> (2021)	Por meio de RF, CART, BRT e <i>Extreme Gradient Boosting</i> (XGBoost) as áreas propensas a inundações da bacia hidrográfica do Rio Bâsca Chiojdului, Romênia, foram mapeadas. A maior AUC foi alcançada pelo modelo RF (0,956).
1	Ahmadlou <i>et al.</i> (2021)	A utilização de SIG e modelos híbridos baseados em MLP foram utilizados para mapear a suscetibilidade a inundações em regiões do Irã e Índia. O resultado sugeriu que o modelo autoencoder-MLP demonstra-se eficiente para aplicação nas duas localidades avaliadas.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Ahmed, Hewa, Alrajhi (2021)	Barossa Valley, Austrália, teve as áreas suscetíveis a inundações mapeadas através de modelos com base MCDM. Os resultados mostram que aproximadamente 45,7, 44,7 e 9,7% da área de estudo estão sob risco de alto, médio e baixo grau de inundação, respectivamente.
1	Aprilia e Hidayah (2021)	A suscetibilidade a inundações na bacia hidrográfica de Welang, Indonésia, foram avaliadas por meio do FR. O modelo proposto demonstrou predição satisfatória.
1	Arora <i>et al.</i> (2021A)	O estudo é uma tentativa de testar quantitativamente e comparar novos algoritmos de ML. Para isso foram comparados os modelos ANFIS, GA, DE, PSO. Os modelos foram aplicados na bacia hidrográfica do Rio Ganga, Índia. O resultado demonstrou que o modelo ANFIS-GA a melhor taxa de predição 92,4.
2	Arora <i>et al.</i> (2021B)	O estudo compara resultados da modelagem de suscetibilidade a inundações na Planície do Rio Ganga, Índia. Os modelos avaliados foram SE e FR. O resultado demonstra que a AUC para SE (0,90) foi melhor do que para FR (0,85).
1	Avand, Moradi, Ramazanzadeh Lasboyee (2021A)	Por meio de RNA e FDA foram mapeadas áreas propensas a inundações em Mazandaran, Irã. Com base nas avaliações dos modelos validados, o FDA, apresenta melhor resultado com um AUC = 0,918.
1	Avand, Moradi, Ramazanzadeh Lasboyee (2021B)	O estudo produziu mapas de suscetibilidade a inundações para a bacia hidrográfica de Tajan, Irã, usando três modelos <i>Self-Organization Map</i> (SOM), <i>Radial Basis Function Neural Network</i> (RBFNN) e MLP. O modelo RBFNN (AUC = 0,90) supera os modelos.
1	Azareh <i>et al.</i> (2021)	Os modelos DEMATEL e ANP foram aplicados em Haraz, Irã. O resultado gerou um mapa de suscetibilidade a inundações com taxa de predição de 89,1% (DEMATEL-ANP).
1	Chakraborty <i>et al.</i> (2021)	O mapeamento da suscetibilidade às inundações na bacia hidrográfica do Rio Kangsabati, Índia, por meio dos modelos ANN, DLNN e PSO. Dentre esses três modelos, o PSO apresentou o melhor desempenho com um valor de AUC de 0,942.
1	Chou <i>et al.</i> (2021)	Ha Giang, Vietnã teve o mapeamento de áreas suscetíveis a inundações realizados por meio de modelos SVM, RF, CNN, <i>Radom Subsampling</i> (RS) e <i>Galactic Swarm Optimization</i> (GSO). O resultado demonstrou eficiências para os modelos analisados, com AUC acima de 90%.
1	Costache <i>et al.</i> (2021)	Por meio dos modelos SVM, J48, ANFIS, RF, RNA e ADT, Buzau na Romênia teve suas áreas suscetíveis a inundações mapeadas. A validação dos resultados mostra que o modelo mais preciso é o RF (AUC = 0,996).

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Darabi <i>et al.</i> (2021A)	Neste estudo, um novo algoritmo híbrido para mapeamento de suscetibilidade a inundações, denominado MultiB-MLPNN foi testado em Amol, Irã. Na validação, o modelo MultiB-MLPNN apresentou-se satisfatório.
2	Darabi <i>et al.</i> (2021B)	Mazandaran, Irã, teve suas áreas suscetíveis a inundações mapeadas através dos modelos RF, J48, CART, LMT e do novo modelo híbrido proposto o Swarm Intelligence - Grey Wolf (NN-SGW). O modelo NN-SGW superou todos os modelos de referência em treinamento apontando AUC = 0,963.
1	Das e Gupta (2021)	O mapeamento da bacia hidrográfica de Subarnarekha, Índia por meio do AHP. O mapa de suscetibilidade a inundações mostrou que uma grande quantidade de áreas (38%) tem alta probabilidade de inundação. O modelo também mostrou eficiência preditiva (AUC = 0,93).
1	Das e Scaringi (2021)	A área de captação do Rio Mahi, Índia teve o mapeamento a suscetibilidade a inundações realizadas por meio de MCDM. O resultado do estudo demonstrou que uma parte significativa da área de captação permanece altamente suscetível às inundações
2	Ding <i>et al.</i> (2021)	Neste artigo, mais de 200 artigos publicados nos últimos 20 anos são resumidos e analisados. As análises realizadas foram de co-ocorrência de palavras-chave, análise de gráfico de fuso horário, análise de explosão de palavras-chave e análise de citação de literatura.
1	El-Haddad <i>et al.</i> (2021)	O estudo empregou quatro modelos BRT, <i>Flexible Discriminant Analysis</i> (FDA), MDA e <i>Generalized Linear Model</i> (GLM) para mapear a suscetibilidade a inundações na bacia hidrográfica de Wadi Qena, Egito. Os resultados mostraram que a AUC para as taxas de sucesso e predição são 0,783, 0,958, 0,816, 0,821 e 0,812, 0,856, 0,862, 0,769 para os modelos BRT, FDA, GLM e MDA, respectivamente.
1	Fang <i>et al.</i> (2021)	As áreas propensas a inundações de Shangyou, China foram mapeadas através do modelo <i>Local Spatial Sequential Long Short-Term Memory Neural Network</i> (LSS-LSTM). O resultado demonstrou boa eficiência do modelo apresentando eficiência de 96,5%.
1	Feizizadeh, Gheshlaghi, Tien Bui (2021)	O mapeamento de suscetibilidade a inundações foi realizado através dos modelos <i>Fuzzy Membership Value</i> (FMV), <i>Information Value</i> (IV), FR e IOE na bacia hidrográfica de Azarshahr Chay, Irã. Os resultados indicaram que o AUC para os modelos varia de 0,963 a 0,969, apontando o melhor modelo o FMV-IOE. Verificou-se ainda que os fatores condicionantes de maior importância para a ocorrência de inundações foram o tipo solo e cobertura da terra e uso do solo.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Goumrassa <i>et al.</i> (2021)	A bacia hidrográfica de Chifa, Argélia, teve suas áreas propensas a inundações mapeadas por meio do AHP. Os resultados indicam que 49,08% da seção total é altamente e muito altamente suscetível a inundações.
1	Ha <i>et al.</i> (2021)	Quatro modelos híbridos de ML de DecorateREPT, AdaBoostM1-REPT, Bagging-REPT e MultiBoostAB-REPT foram aplicados para desenvolver mapas de suscetibilidade de Hoa Binh, Vietnã. O modelo DCREPT apresentou o melhor desempenho de predição (99,1%).
1	Hang <i>et al.</i> (2021)	A suscetibilidade a inundações da autoestrada nacional 6 em Binh, Vietnam, foram analisadas por meio do modelo SI. O AUC do SI apontou uma eficiência de 81,1%.
1	Irawan <i>et al.</i> (2021)	Os modelos LR e FR foram aplicados no mapeamento de áreas suscetíveis a inundações na bacia hidrográfica de Dawuan, Indonésia. O resultado apontou que o modelo híbrido LR-FR apresentou valor de predição de 93%.
1	Islam, Tahir, Parveen (2021)	A bacia hidrográfica de Bihar, Índia, teve as áreas suscetíveis a inundações mapeadas por meio do SE. O resultado obtido foi satisfatório (87%).
1	Janizadeh <i>et al.</i> (2021)	O objetivo do estudo é apresentar um novo modelo de mapeamento de suscetibilidade a inundações baseado na metodologia <i>Bayesian Additive Regression Tree</i> (BART). O modelo foi aplicado na bacia hidrográfica do Rio Kan, Irã, e comparado com os modelos NB e RF. Dentre os modelos avaliados, o BART apresentou o melhor desempenho.
1	Kalantar <i>et al.</i> (2021)	Brisbane, Austrália, teve as áreas propensas a inundações mapeadas por meio do RNA, DLNN e PSO. As melhores precisões por AUC foram avaliadas em PSO-DLNN (0,98).
1	Luu <i>et al.</i> (2021A)	Neste estudo, o classificador <i>Partial Decision Tree</i> (PART) e as técnicas de aprendizado de conjuntos AdaBoost, Bagging, Dagging e Random Subspace foram combinados para mapear áreas suscetíveis a inundações em Quang Binh, Vietnã. O modelo atingiu valores AUC acima de 90%.
1	Luu <i>et al.</i> (2021B)	Este estudo tem como objetivo desenvolver um modelo híbrido de mapeamento de suscetibilidade a inundações por meio dos modelos ADT, LM, REPT, J48 e NB. O estudo foi aplicado em Quang Binh, Vietnã, e obteve resultados satisfatórios.
1	Malekinezhad <i>et al.</i> (2021)	Hamadan, Irã, teve as áreas suscetíveis a inundações mapeadas por meio de sobreposição de mapas. O resultado do estudo foi satisfatório.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Malik e Pal (2021)	O mapeamento de suscetibilidade a inundações foi estimado usando dados de precipitação do MIROC5 do CMIP5 <i>Global Circulation Model</i> (GCM). Além disso, quatro funções de distribuição como log-normal (LN), <i>Log-Pearson</i> Tipo III (LPT-3), distribuição de valor extremo de <i>Gumbel</i> (EV-I) e distribuição de valor extremo-III (EV-III) foram aplicadas com períodos de intervalo de recorrência para estimar sua probabilidade de ocorrências. O método de <i>Weibull</i> é mais útil com AUC = 0,885.
2	Malik <i>et al.</i> (2021)	A análise da suscetibilidade a inundações foi feita na bacia hidrográfica do Rio Dwarkeswar, Índia. Os modelos empregados foram Lógica <i>Fuzzy</i> , FR, MCDM e LR. A AUC mostrou que o melhor nível de precisão é do modelo LR (0,916).
1	Masoumi (2021)	Zanjar, Irã teve as zonas urbanas propensas a inundações avaliadas por meio de GIS e MCDM. Os resultados indicaram as áreas de alta suscetibilidade a inundações.
1	Mirzaei <i>et al.</i> (2021)	O estudo mapeou a suscetibilidade a inundações em Haraz, Irã. Os modelos empregados foram <i>Extreme Gradient Boosting</i> (EGB), FR, RF e GAM. Os resultados da pesquisa atual mostram que o modelo de RF e EGB têm os melhores desempenhos com AUC de 0,985 e 0,980.
1	Msabi e Makonyo (2021)	O artigo produziu o mapa de suscetibilidade a inundações em Dodoma, Tanzânia. A análise baseou-se em AHP, apresentando resultado a AUC = 87,24%.
1	Mudashiru, Sabtu, Abustan (2021)	O estudo traz uma revisão dos modelos empregados em mapeamentos de áreas suscetíveis a inundações.
1	Narimani <i>et al.</i> (2021)	Por meio do modelo AHP as áreas suscetíveis a inundações foram mapeadas em Seoul, Coreia do Sul. O mapa de inundações indicou que 40% da área apresenta alto risco de inundações.
1	Natarajan <i>et al.</i> (2021)	Em Chennai, Índia, as áreas suscetíveis a inundações foram mapeadas através de RF. O mapeamento obteve uma taxa de sucesso de 95,6%.
1	Ngo <i>et al.</i> (2021)	Por meio do modelo <i>Quantum Particle Swarm Optimization</i> (QPSO) e CDT para mapeamento de áreas suscetíveis a inundações em Hanoi, Vietnã. O resultado mostra que o modelo QPSO-CDT teve um bom desempenho (90,4%). Dentre os fatores condicionantes se destaca na influência a inundações o uso do solo, inclinação e curvatura.
1	Panahi <i>et al.</i> (2021A)	Este estudo utiliza-se dos modelos SVR, GOA e PSO para modelagem de inundações em Qazvin Plain, Irã. O modelo SVR-GOA teve o melhor desempenho (AUC = 0,959, RMSE = 0,31 e MSE = 0,098).

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
2	Panahi <i>et al.</i> (2021B)	Os modelos CNN e RNN foram utilizados para analisar a suscetibilidade a inundações em Golestan, Irã. Os resultados mostraram que o modelo CNN (AUC=0,832) teve um desempenho ligeiramente melhor que o modelo RNN (AUC=0,814).
1	Pandey <i>et al.</i> (2021)	O estudo avaliou a suscetibilidade da Planície do Rio Ganga, Índia por meio dos modelos em conjunto de FR, EBF e CART. O resultado demonstrou que os modelos híbridos avaliados apresentaram predição satisfatória.
1	Pham <i>et al.</i> (2021A)	O MCDM e dois modelos híbridos (<i>AdaBoost-DT</i> e <i>Bagging-DT</i>) foram utilizados para mapear a suscetibilidade a inundações em Quang Nam, Vietnã. Os resultados mostram que todos os modelos propostos tiveram um bom desempenho, mas o desempenho do modelo <i>Bagging-DT</i> (AUC = 0,96) é o melhor em comparação aos outros modelos.
1	Pham <i>et al.</i> (2021B)	Através dos modelos híbridos com base em ELM, PSO, <i>Deep Belief Network</i> (DBN) e BP as áreas propensas a inundações de Quang Nam, Vietnã foram analisadas. O novo modelo proposto apresenta-se eficiente, com predição 96,7%.
1	Pham <i>et al.</i> (2021C)	Neste estudo, os modelos <i>Best First Decision Tree</i> (BFT), <i>Bagging</i> (Bagging-BFT), <i>Decorate</i> (Bagging-BFT) e <i>RandomSubspace</i> (RSS-BFT) foram utilizados para previsão da suscetibilidade a inundações em Nghe Na, Vietnã. O resultado apontou o conjunto Decorate-BFT modelo que alcançou o melhor valor de predição (98,9%).
1	Pham <i>et al.</i> (2021D)	Através dos modelos MCDM, AHP e DNN as áreas suscetíveis a inundações foram mapeadas em Quang Nam, Vietnã. O método com a maior taxa de predição foi o DNN (96,3%).
1	Prasad <i>et al.</i> (2021)	Através de KNN, RF, BRT, <i>Adabag</i> (AB) e <i>Nearest Shrunked Centroids</i> (NSC) áreas suscetíveis a inundações de Western Ghats, Índia foram mapeadas. O resultado demonstrou o melhor resultado para o modelo híbrido AB-RF (94%).
1	Rahman <i>et al.</i> (2021)	O estudo teve como objetivo principal o desenvolvimento de modelos para distribuição espacial de evacuações de emergências. Para analisar, identificar e distribuir os centros de evacuações foi gerada através de MCDM e modelos ML o mapa de suscetibilidade a inundações. Através do mapeamento gerado foi possível planejar e otimizar os centros de evacuações.
1	Santos, Pinheiro, Gallo Junior (2021)	O modelo HAND foi aplicado em São Luiz do Paraitinga, Brasil teve as áreas suscetíveis a inundações mapeadas. O resultado apresentou que 13% das áreas sugeriram suscetibilidades a inundações alta e muito alta.

Tabela 16 - Resumo sucinto e contribuição dos artigos analisados na revisão estruturada (continuação).

Termo de Pesquisa	Autor (Ano)	Resumo da contribuição da pesquisa
1	Shahabi <i>et al.</i> (2021)	O mapeamento de suscetibilidades foi realizado na bacia hidrográfica de Haraz, Irã. Os modelos utilizados foram DBN com algoritmo BP e GA. O resultado mostra que o modelo proposto apresenta precisão de predição (AUC = 0,985).
1	Shahiri Tabarestani e Afzalimehr (2021)	O mapeamento de áreas suscetíveis a inundações em Mazandaran, Irã, foi realizado por meio dos modelos RNA, AHP, WofE e <i>Multi-Attributive Border Approximation Area Comparison</i> (MABAC). O valor de AUC para a taxa de previsão deste modelo híbrido MABAC WofE-AHP foi de 86,1%.
1	Stamellou <i>et al.</i> (2021)	A bacia hidrográfica do Rio Erasinós, Grécia, teve as áreas propensas a inundações mapeadas por meio do modelo AHP. Os resultados mostraram picos significativos na classe moderada de suscetibilidade às inundações.
1	Suppawimut (2021)	O mapa de suscetibilidade a inundações de San Pa Tong, Tailândia, foi realizado por meio dos modelos SI e Wf. A validação dos modelos utilizando a AUC revelou que as taxas de predição foram de 92,05% e 93,52% para SI e Wf, respectivamente.
1	Vojtek <i>et al.</i> (2021)	As áreas suscetíveis a inundações da bacia hidrográfica do Rio Topľ'a, Eslováquia, foram avaliadas por meio dos métodos BRT, AHP e <i>Machine Learning-Boosted Classification</i> (BCT). O melhor desempenho apresentado foi do modelo BRT (91,42%).
1	Wang <i>et al.</i> (2021)	Neste estudo, o mapeamento da suscetibilidade a inundações foi realizado em Poyang, China. Os modelos FR, SVM, CART, IRN, IOE e <i>Multi-layer Perceptron Neural Network</i> (MLO) juntamente com o <i>Probability Density</i> (PD) de maneira conjunta, tendo destaque na taxa de predição o modelo MLO-PD (94,9%).
1	Wubalem <i>et al.</i> (2021)	A sub-bacia hidrográfica do lago Tana, Etiópia, teve a suscetibilidade a inundações avaliadas por meio dos modelos AHP, FR e LR. Como o resultado indicou, o modelo FR tem melhor desempenho (AUC = 99,1%).

ANEXO B

O Anexo B evidencia as coordenadas inventariadas de pontos de inundações e não inundações. O intuito é demonstrar uma base de dados para replicação e atualizações futuras deste estudo. O inventário é apresentado na Tabela 17.

Tabela 17 - Coordenadas do inventários de pontos de inundações e não inundações.

Ponto	Latitude	Longitude	Inventário	Fonte
1	-23,7194120	-47,4217190	Inundação	IPMET
2	-23,7155000	-47,4114000	Inundação	
3	-23,7150900	-47,4176830	Inundação	
4	-23,6638180	-47,2276460	Inundação	
5	-23,6628000	-47,2254980	Inundação	
6	-23,6580280	-47,5901030	Inundação	
7	-23,6147990	-47,0154990	Inundação	
8	-23,5509190	-47,2010690	Inundação	
9	-23,5490040	-47,2031860	Inundação	
10	-23,5480000	-47,4373020	Inundação	
11	-23,5468940	-47,4798390	Inundação	
12	-23,5463120	-47,4965210	Inundação	
13	-23,5434250	-47,1972050	Inundação	
14	-23,5391920	-47,4626270	Inundação	
15	-23,5384710	-47,1537670	Inundação	
16	-23,5349710	-47,1549260	Inundação	
17	-23,5349620	-47,1500970	Inundação	
18	-23,5294860	-47,1788670	Inundação	
19	-23,5243430	-47,1409070	Inundação	
20	-23,5239960	-47,2626610	Inundação	
21	-23,5231860	-47,4879260	Inundação	
22	-23,5199530	-47,2558170	Inundação	
23	-23,5178170	-47,1453090	Inundação	
24	-23,5169220	-47,4898190	Inundação	
25	-23,5142270	-47,4634900	Inundação	
26	-23,5140800	-47,4770770	Inundação	
27	-23,5049990	-47,4725990	Inundação	
28	-23,5028000	-47,4984020	Inundação	
29	-23,5016710	-47,4580610	Inundação	
30	-23,4967060	-47,4688680	Inundação	
31	-23,4863090	-47,4427640	Inundação	
32	-23,4825740	-47,4599800	Inundação	
33	-23,4787860	-47,5531040	Inundação	
34	-23,4777390	-47,5367390	Inundação	
35	-23,4746040	-47,4548300	Inundação	
36	-23,4722980	-47,5130770	Inundação	
37	-23,4715000	-47,4412990	Inundação	
38	-23,4710710	-47,7406460	Inundação	
39	-23,4703450	-47,4861830	Inundação	
40	-23,4697420	-47,5066720	Inundação	
41	-23,4697420	-47,5066720	Inundação	
42	-23,4689600	-47,7392880	Inundação	
43	-23,4650970	-47,4940340	Inundação	
44	-23,4557090	-47,7882770	Inundação	

Tabela 17 - Coordenadas do inventários de pontos de inundações e não inundações (continuação).

Ponto	Latitude	Longitude	Inventário	Fonte
45	-23,4537160	-47,4656410	Inundação	IPMET
46	-23,4412440	-47,0621110	Inundação	
47	-23,4384420	-47,0768620	Inundação	
48	-23,4265140	-47,3490030	Inundação	
49	-23,3655610	-47,9241830	Inundação	
50	-23,3604430	-47,8379060	Inundação	
51	-23,3526000	-47,8694000	Inundação	
52	-23,3429830	-47,8137090	Inundação	
53	-23,3271410	-47,7833520	Inundação	
54	-23,3255200	-47,3653980	Inundação	
55	-23,3241000	-47,7845000	Inundação	
56	-23,3172590	-47,8684620	Inundação	
57	-23,3081000	-47,1459010	Inundação	
58	-23,3066270	-47,1453210	Inundação	
59	-23,3064000	-47,1353990	Inundação	
60	-23,3058190	-47,1367000	Inundação	
61	-23,3012910	-47,3003390	Inundação	
62	-23,2925340	-47,6818390	Inundação	
63	-23,2814850	-47,6747890	Inundação	
64	-23,2784670	-47,6644330	Inundação	
65	-23,2637000	-47,3156010	Inundação	
66	-23,2145180	-47,5375180	Inundação	
67	-23,2008400	-47,2873460	Inundação	
68	-23,2018400	-47,2875460	Inundação	
69	-23,2007470	-47,3049890	Inundação	
70	-23,1723650	-47,3419910	Inundação	
71	-23,1684300	-47,3187140	Inundação	
72	-23,1594330	-47,7304990	Inundação	
73	-23,1114460	-47,2644690	Inundação	
74	-23,1072690	-47,2536240	Inundação	
75	-23,1052930	-47,7298700	Inundação	
76	-23,0960900	-47,7136650	Inundação	
77	-23,0611990	-47,8361020	Inundação	
78	-23,0511340	-47,8389780	Inundação	
79	-22,8935180	-48,4837070	Inundação	
80	-22,8880460	-48,4469760	Inundação	
81	-22,8805640	-48,4778060	Inundação	
82	-22,7908000	-48,1353000	Inundação	
83	-23,6919020	-47,0202920	Inundação	DataGEO
84	-23,6843560	-47,0229420	Inundação	
85	-23,6813250	-47,0205160	Inundação	
86	-23,5346200	-47,1578100	Inundação	
87	-23,5398200	-47,1829200	Inundação	
88	-23,531686	-47,1961250	Inundação	
89	-23,5310400	-47,2073900	Inundação	
90	-23,5210100	-47,2520100	Inundação	
91	-23,7122000	-47,4040720	Inundação	
92	-23,5620230	-47,4513490	Inundação	
93	-23,5059800	-47,4315660	Inundação	
94	-23,5059800	-47,4987600	Inundação	
95	-23,5127300	-47,4980600	Inundação	
96	-23,4976400	-47,4722700	Inundação	
97	-23,4922820	-47,4951800	Inundação	
98	-23,4915090	-47,4896250	Inundação	

Tabela 17 - Coordenadas do inventários de pontos de inundações e não inundações (continuação).

Ponto	Latitude	Longitude	Inventário	Fonte
99	-23,4885990	-47,4914990	Inundação	DataGEO
100	-23,4878710	-47,4951370	Inundação	
101	-23,4934220	-47,4314060	Inundação	
102	-23,4718700	-47,4509000	Inundação	
103	-23,4697300	-47,5119400	Inundação	
104	-23,4553600	-47,4779800	Inundação	
105	-23,4530300	-47,4729500	Inundação	
106	-23,4510100	-47,4694500	Inundação	
107	-23,4517300	-47,4644700	Inundação	
108	-23,4263400	-47,5080000	Inundação	
109	-23,4247000	-47,5023300	Inundação	
110	-23,4249800	-47,4489600	Inundação	
111	-23,1632222	-47,7319167	Inundação	Levantamento de Campo
112	-23,1961944	-47,7983889	Inundação	
113	-23,3446944	-47,8211389	Inundação	
114	-23,3416667	-47,8438611	Inundação	
115	-23,3242222	-47,7831667	Inundação	
116	-23,3154167	-47,7350278	Inundação	
117	-23,3394167	-47,6907500	Inundação	
118	-23,2874444	-47,6523611	Inundação	
119	-23,2235278	-47,5198889	Inundação	
120	-23,2273056	-47,5648889	Inundação	
121	-23,1005000	-47,7183056	Inundação	
122	-23,0962500	-47,7140556	Inundação	
123	-23,1030556	-47,7086111	Inundação	
124	-23,1002500	-47,7139167	Inundação	
125	-23,0775833	-47,7956111	Inundação	
126	-23,0409167	-47,8440000	Inundação	
127	-23,0413056	-47,8413056	Inundação	
128	-23,0340278	-47,8197500	Inundação	
129	-22,9853056	-47,8159444	Inundação	
130	-23,0390972	-47,8929167	Inundação	
131	-23,0371667	-47,8656111	Inundação	
132	-23,0225556	-47,9056389	Inundação	
133	-23,0318611	-47,8973056	Inundação	
134	-23,0554167	-47,9599722	Inundação	
135	-23,0560278	-47,9618333	Inundação	
136	-23,0781389	-47,9752778	Inundação	
137	-23,0369444	-47,9757778	Inundação	
138	-23,0257500	-47,9946389	Inundação	
139	-23,0168611	-47,9999444	Inundação	
140	-23,0253278	-48,0656944	Inundação	
141	-23,0175556	-48,0000000	Inundação	
142	-23,0167500	-48,1395833	Inundação	
143	-22,7952861	-48,1167889	Inundação	
144	-22,7845833	-48,1259444	Inundação	
145	-22,9403889	-48,2946944	Inundação	
146	-22,8997500	-48,4390833	Inundação	
147	-22,8723056	-48,4431667	Inundação	
148	-22,7777917	-48,4006389	Inundação	
149	-22,7566944	-48,3654167	Inundação	
150	-22,7283472	-48,3733889	Inundação	
151	-23,1823056	-48,3069722	Inundação	
152	-23,0949722	-48,2699444	Inundação	

Tabela 17 - Coordenadas do inventários de pontos de inundações e não inundações (continuação).

Ponto	Latitude	Longitude	Inventário	Fonte
153	-23,0910000	-48,2755556	Inundação	Levantamento de Campo
154	-23,2033333	-48,2101389	Inundação	
155	-23,2472222	-48,1881111	Inundação	
156	-23,2481944	-48,1969722	Inundação	
157	-23,2394444	-48,0000000	Inundação	
158	-23,2340278	-48,1215556	Inundação	
159	-23,2012500	-48,1218611	Inundação	
160	-23,1726389	-48,1259722	Inundação	
161	-23,1782500	-48,1206667	Inundação	
162	-23,1785278	-48,1213056	Inundação	
163	-23,1930833	-48,1092778	Inundação	
164	-23,2200000	-47,9685278	Inundação	
165	-23,2220000	-47,9669722	Inundação	
166	-23,2219722	-47,9620556	Inundação	
167	-23,2279722	-47,9507500	Inundação	
168	-23,1524167	-47,8221944	Inundação	
169	-23,1651111	-47,8134167	Inundação	
170	-23,3005833	-48,0603917	Inundação	
171	-23,2240083	-47,7805472	Inundação	
172	-23,1968278	-47,7551500	Inundação	
173	-23,4691667	-47,4473611	Inundação	
174	-23,6482778	-47,5215278	Inundação	
175	-23,6398889	-47,5716111	Inundação	
176	-23,6567500	-47,5856111	Inundação	
177	-23,7056667	-47,4228056	Inundação	
178	-23,7050556	-47,4393611	Inundação	
179	-23,7031467	-47,0355278	Inundação	
180	-23,6834167	-47,3408611	Inundação	
181	-23,6565000	-47,2253056	Inundação	
182	-23,6540000	-47,2240833	Inundação	
183	-23,6230000	-47,1875556	Inundação	
184	-23,5311389	-47,1368889	Inundação	
185	-23,4388333	-47,0616389	Inundação	
186	-23,4007778	-47,1226944	Inundação	
187	-23,4031944	-47,1205000	Inundação	
188	-23,3049722	-47,1343333	Inundação	
189	-23,2596667	-47,2963056	Inundação	
190	-23,5228518	-47,2517890	Inundação	
191	-23,2056750	-47,3006750	Inundação	
192	-23,4471768	-47,6503979	Não Inundação	Levantamento de Campo
193	-23,4481841	-47,6159640	Não Inundação	
194	-23,5607844	-47,3198996	Não Inundação	
195	-23,8225735	-47,3984484	Não Inundação	
196	-23,1613717	-48,2496523	Não Inundação	
197	-23,7996813	-47,0911967	Não Inundação	
198	-23,7966688	-47,1198201	Não Inundação	
199	-23,5980303	-47,0067255	Não Inundação	
200	-22,4886468	-48,3553929	Não Inundação	
201	-22,6213460	-48,4720877	Não Inundação	
202	-22,6707399	-48,5619590	Não Inundação	
203	-22,7034110	-48,4322723	Não Inundação	
204	-22,6354013	-48,2917760	Não Inundação	
205	-22,6677647	-48,3799499	Não Inundação	
206	-22,8088299	-48,4226565	Não Inundação	

Tabela 17 - Coordenadas do inventários de pontos de inundações e não inundações (continuação).

Ponto	Latitude	Longitude	Inventário	Fonte
207	-22,7198912	-48,3275436	Não Inundação	Levantamento de Campo
208	-22,7505851	-48,5461317	Não Inundação	
209	-22,5239481	-48,4738317	Não Inundação	
210	-22,5164868	-48,5338206	Não Inundação	
211	-23,0418743	-48,1821695	Não Inundação	
212	-22,9509770	-48,0035273	Não Inundação	
213	-22,8285370	-47,9074071	Não Inundação	
214	-22,7778375	-47,8674145	Não Inundação	
215	-22,7738737	-47,8594682	Não Inundação	
216	-22,7328365	-48,0775154	Não Inundação	
217	-22,9806450	-47,9512889	Não Inundação	
218	-23,0338347	-47,8799215	Não Inundação	
219	-23,0663847	-47,8706882	Não Inundação	
220	-23,1823286	-48,0817777	Não Inundação	
221	-23,1805659	-48,2255010	Não Inundação	
222	-23,0383721	-48,2744565	Não Inundação	
223	-22,9997226	-48,3280659	Não Inundação	
224	-22,9534252	-48,2734492	Não Inundação	
225	-23,2622112	-47,5575001	Não Inundação	
226	-23,2959736	-47,7008316	Não Inundação	
227	-23,3195886	-47,9360118	Não Inundação	
228	-23,1880458	-47,8633388	Não Inundação	
229	-23,1128826	-47,6560825	Não Inundação	
230	-23,1510844	-47,7648683	Não Inundação	
231	-23,0852384	-47,4185893	Não Inundação	
232	-23,1448915	-47,2682441	Não Inundação	
233	-23,1776840	-47,3815066	Não Inundação	
234	-23,5280666	-47,5516989	Não Inundação	
235	-23,6284211	-47,1875128	Não Inundação	
236	-23,6591617	-47,6075094	Não Inundação	
237	-23,5236458	-47,5090576	Não Inundação	
238	-23,4855279	-47,4363565	Não Inundação	
239	-23,7078374	-47,0255559	Não Inundação	
240	-23,3012151	-46,9647650	Não Inundação	
241	-23,3388294	-46,9736346	Não Inundação	
242	-23,3180963	-46,9855913	Não Inundação	
243	-23,3258561	-47,2156232	Não Inundação	
244	-23,5374959	-47,8550567	Não Inundação	
245	-23,5418234	-47,9641409	Não Inundação	
246	-23,6785914	-47,2597429	Não Inundação	
247	-23,8082315	-47,2053127	Não Inundação	
248	-23,6848216	-47,5421904	Não Inundação	
249	-23,5845417	-47,4702168	Não Inundação	
250	-23,4345043	-47,7458653	Não Inundação	
251	-22,8802415	-48,0898685	Não Inundação	
252	-22,8685832	-48,0632690	Não Inundação	
253	-22,8490533	-48,2945320	Não Inundação	
254	-23,2357867	-48,2810741	Não Inundação	
255	-22,9101796	-48,0195245	Não Inundação	
256	-22,8902856	-48,2058315	Não Inundação	
257	-22,8905794	-48,1609231	Não Inundação	
258	-22,8056311	-48,0128092	Não Inundação	
259	-22,8011088	-47,9865882	Não Inundação	
260	-22,8088104	-47,9893058	Não Inundação	

Tabela 17 - Coordenadas do inventários de pontos de inundações e não inundações (continuação).

Ponto	Latitude	Longitude	Inventário	Fonte
261	-22,8196388	-48,0122322	Não Inundação	Levantamento de Campo
262	-23,0747354	-47,9356360	Não Inundação	
263	-23,0969168	-47,9299490	Não Inundação	
264	-23,1614045	-48,1953074	Não Inundação	
265	-23,0854169	-48,1953494	Não Inundação	
266	-23,0823531	-48,3659385	Não Inundação	
267	-23,0481576	-47,6295872	Não Inundação	
268	-23,0336463	-47,7121326	Não Inundação	
269	-23,1364950	-47,8330286	Não Inundação	
270	-23,2519558	-47,4070701	Não Inundação	
271	-23,4367939	-47,1838291	Não Inundação	
272	-23,3950333	-47,4823232	Não Inundação	
273	-23,4448942	-47,5654668	Não Inundação	
274	-23,5284155	-47,0501531	Não Inundação	
275	-23,4112549	-47,3529282	Não Inundação	
276	-23,4115696	-47,3644176	Não Inundação	
277	-23,4115224	-47,3859117	Não Inundação	
278	-23,7904346	-47,5033137	Não Inundação	
279	-23,8013365	-47,5299440	Não Inundação	
280	-23,8374101	-47,4708495	Não Inundação	
281	-23,7854506	-47,2739450	Não Inundação	
282	-23,8058483	-47,2673136	Não Inundação	
283	-23,7082669	-47,2704824	Não Inundação	
284	-23,7714745	-47,5629118	Não Inundação	
285	-23,5443092	-47,4876797	Não Inundação	
286	-23,5803408	-47,6345344	Não Inundação	
287	-23,4202444	-47,4646169	Não Inundação	
288	-23,3194103	-47,5343089	Não Inundação	
289	-23,4464130	-47,7928891	Não Inundação	
290	-23,4339058	-47,8845527	Não Inundação	
291	-23,3945375	-47,9138481	Não Inundação	
292	-23,2601480	-47,7928891	Não Inundação	
293	-23,2332029	-47,8310403	Não Inundação	
294	-23,2768522	-47,9309196	Não Inundação	
295	-23,2098253	-47,9713372	Não Inundação	
296	-23,1798584	-47,4605982	Não Inundação	
297	-23,2050827	-47,5494078	Não Inundação	
298	-23,2770201	-47,5232812	Não Inundação	
299	-23,7368488	-47,1065981	Não Inundação	
300	-23,7483907	-47,0751622	Não Inundação	
301	-23,7603103	-47,1033874	Não Inundação	
302	-23,7348972	-47,2068237	Não Inundação	
303	-23,6072230	-47,5001135	Não Inundação	
304	-23,4331293	-47,4929785	Não Inundação	
305	-23,4982256	-47,5290311	Não Inundação	
306	-23,3350863	-47,6160779	Não Inundação	
307	-23,3337013	-47,5622298	Não Inundação	
308	-23,3836356	-47,5708232	Não Inundação	
309	-23,3638466	-47,7007429	Não Inundação	
310	-23,4733895	-47,4118180	Não Inundação	
311	-23,5512028	-47,3730373	Não Inundação	
312	-23,4823922	-47,4664426	Não Inundação	
313	-23,4609453	-47,4838184	Não Inundação	
314	-23,4497811	-47,4624344	Não Inundação	

Tabela 17 - Coordenadas do inventários de pontos de inundações e não inundações (continuação).

Ponto	Latitude	Longitude	Inventário	Fonte
315	-23,4326572	-47,4057323	Não Inundação	Levantamento de Campo
316	-23,4336855	-47,3662800	Não Inundação	
317	-23,5042379	-47,4370213	Não Inundação	
318	-23,5014468	-47,4221218	Não Inundação	
319	-23,5057803	-47,4850880	Não Inundação	
320	-23,5267970	-47,4850565	Não Inundação	
321	-23,2656986	-47,6390673	Não Inundação	
322	-23,6404951	-47,8511022	Não Inundação	
323	-23,6318911	-47,6961261	Não Inundação	
324	-23,5623040	-47,7970442	Não Inundação	
325	-23,4726131	-47,7476869	Não Inundação	
326	-23,3881685	-48,0272943	Não Inundação	
327	-23,3838035	-47,8106426	Não Inundação	
328	-23,2991910	-47,8332228	Não Inundação	
329	-23,2037501	-47,6326982	Não Inundação	
330	-23,2173486	-47,6145250	Não Inundação	
331	-23,1443933	-47,5296607	Não Inundação	
332	-23,1290321	-47,4673555	Não Inundação	
333	-23,0862013	-47,5676020	Não Inundação	
334	-23,1678339	-47,5544443	Não Inundação	
335	-23,4964209	-47,1736145	Não Inundação	
336	-23,7881368	-47,3269222	Não Inundação	
337	-23,7609084	-47,3565954	Não Inundação	
338	-23,6826334	-47,4432854	Não Inundação	
339	-23,6715113	-47,3706765	Não Inundação	
340	-23,6020081	-47,3174998	Não Inundação	
341	-23,5986505	-47,4268120	Não Inundação	
342	-23,2849001	-47,5788921	Não Inundação	
343	-23,3308158	-47,3180245	Não Inundação	
344	-23,3519689	-47,2825174	Não Inundação	
345	-23,3461770	-47,0633056	Não Inundação	
346	-23,5046995	-46,9739294	Não Inundação	
347	-23,6201184	-47,1068919	Não Inundação	
348	-23,6863898	-47,1585576	Não Inundação	
349	-23,7959747	-47,1636780	Não Inundação	
350	-23,4542510	-47,2519419	Não Inundação	
351	-23,4117769	-47,0296662	Não Inundação	
352	-23,4801888	-47,0550164	Não Inundação	
353	-23,4943538	-47,0082193	Não Inundação	
354	-23,5154230	-47,0321634	Não Inundação	
355	-23,5448023	-47,1438050	Não Inundação	
356	-23,5141639	-47,1956385	Não Inundação	
357	-23,4844488	-47,3246978	Não Inundação	
358	-23,3452326	-47,4754138	Não Inundação	
359	-23,2982257	-47,4065402	Não Inundação	
360	-23,3720098	-47,1776751	Não Inundação	
361	-23,3984512	-47,7363024	Não Inundação	
362	-23,3441834	-47,5217492	Não Inundação	
363	-23,3722407	-47,6313552	Não Inundação	
364	-23,3507098	-47,7055170	Não Inundação	
365	-23,2697487	-47,7171639	Não Inundação	
366	-22,8972921	-47,7329500	Não Inundação	
367	-22,8825027	-47,6925114	Não Inundação	
368	-22,9315662	-47,8340569	Não Inundação	

Tabela 17 - Coordenadas do inventários de pontos de inundações e não inundações (continuação).

Ponto	Latitude	Longitude	Inventário	Fonte
369	-22,9704466	-47,8636146	Não Inundação	Levantamento de Campo
370	-23,1287961	-48,0320265	Não Inundação	
371	-23,0379299	-48,0147137	Não Inundação	
372	-22,9713228	-48,1580429	Não Inundação	
373	-23,3145575	-48,0255001	Não Inundação	
374	-23,1474310	-48,0858536	Não Inundação	
375	-22,8350026	-48,4193931	Não Inundação	
376	-22,8207746	-48,5125257	Não Inundação	
377	-22,7508098	-48,3216439	Não Inundação	
378	-22,8207326	-48,0459817	Não Inundação	
379	-22,7760131	-48,2659280	Não Inundação	
380	-23,0450020	-48,0894421	Não Inundação	
381	-23,2418331	-47,2918244	Não Inundação	
382	-23,7431496	-47,4913521	Não Inundação	