

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ
ESCOLA DE BELAS ARTES
PROGRAMA DE PÓS-GRADUAÇÃO EM GESTÃO URBANA (PPGTU)**

GABRIEL TROYAN RODRIGUES

**MODELO DE PREVISÃO DE INUNDAÇÕES URBANAS: UMA ABORDAGEM
BASEADA EM DADOS DA BACIA HIDROGRÁFICA RIBEIRÃO DOS PADILHAS,
CURITIBA (PR)**

CURITIBA

2023

GABRIEL TROYAN RODRIGUES

**MODELO DE PREVISÃO DE INUNDAÇÕES URBANAS: UMA ABORDAGEM
BASEADA EM DADOS DA BACIA HIDROGRÁFICA RIBEIRÃO DOS PADILHAS,
CURITIBA (PR)**

Dissertação apresentada ao Programa de Pós-Graduação em Gestão Urbana da Escola de Belas Artes da Pontifícia Universidade Católica do Paraná, como requisito à obtenção do título de Mestre em Gestão Urbana.

Orientador: Prof. Dr. Fábio Teodoro de Souza

CURITIBA

2023

Dados da Catalogação na Publicação
Pontifícia Universidade Católica do Paraná
Sistema Integrado de Bibliotecas – SIBI/PUCPR
Biblioteca Central
Sônia Maria Magalhães da Silva – CRB 9/1191

R696m
2023
Rodrigues, Gabriel Troyan
Modelo de previsão de inundações urbanas : uma abordagem baseada em dados da bacia hidrográficas Ribeirão dos Padilhas, Curitiba (PR) / Gabriel Troyan Rodrigues ; orientador: Fábio Teodoro de Souza. – 2023.
60 f. : il. ; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Paraná,
Curitiba, 2023
Bibliografia: f. 57-60

1. Planejamento urbano. 2. Inundações – Previsão. 3. Mineração de dados (Computação). 4. Aprendizado do computador. I. Souza, Fabio Teodoro de. II. Pontifícia Universidade Católica do Paraná. Programa de Pós-Graduação em Gestão Urbana. III. Título.

CDD 20. ed. – 711.4


TERMO DE APROVAÇÃO

“MODELO DE PREVISÃO DE INUNDAÇÕES URBANAS: UMA ABORDAGEM BASEADA EM DADOS DA BACIA HIDROGRÁFICA RIBEIRÃO DOS PADILHAS, CURITIBA (PR)”


Por

GABRIEL TROYAN RODRIGUES

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Gestão Urbana, área de concentração em Gestão Urbana, da Escola de Belas Artes, da Pontifícia Universidade Católica do Paraná.



Prof. Dr. Paulo Nascimento Neto
Coordenador do Programa – PPGTU/PUCPR



Prof. Dr. Fábio Teodoro de Souza
Orientador – PPGTU/PUCPR



Profª. Dra. Agnes Silva de Araujo
Membro Interno – PPGTU/PUCPR



Profª. Dra. Luciene Pimentel da Silva
Membro Interno – PPGTU/PUCPR



Prof. Dr. Pedro Bueno Rocha Campos
Membro Externo - SENAC Jabaquara

Curitiba, 31 de março de 2023.

AGRADECIMENTOS

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) responsável pelo financiamento deste projeto de pesquisa de mestrado.

Às instituições que forneceram os dados necessários para a realização desta dissertação:

-) Instituto Nacional de Meteorologia – INMET;
-) Instituto Água e Terra do Paraná – IAT;
-) Instituto de Pesquisa e Planejamento Urbano de Curitiba – IPPUC;
-) Instituto de Terras, Cartografia e Geologia do Paraná – ITCG;
-) Sistema Meteorológico do Paraná – SIMEPAR
-) Defesa Civil do Estado do Paraná;
-) Guarda Municipal de Curitiba – Defesa Civil Municipal;

Ao Professor Fábio pela orientação e incentivo às atividades necessárias para o desenvolvimento desta dissertação.

Ao Programa de Pós-graduação em Gestão Urbana (PPGTU), professores, amigos e colegas que contribuíram direta ou indiretamente.

Aos meus pais e irmão, pelo suporte me proporcionado e por sempre me apoiarem e incentivarem.

A minha namorada, Milena, pela parceria e dedicação ao meu lado, me apoiando e incentivando também.

Aos meus companheiros de trabalho do Instituto Tecnológico de Transportes e Infraestrutura (ITTI) da UFPR, pela parceria, colaboração e apoio.

Depois da chuva sempre vem o sol.

(Autor desconhecido).

RESUMO

Trata-se de um estudo sobre os desastres naturais, com ênfase nas inundações urbanas, as quais têm ocorrido com maior frequência implicando em relevantes impactos socioeconômicos. Dentre as medidas direcionadas para minimizar as consequências das inundações, destacam-se os modelos empíricos atrelados com novas tecnologias de forma promissora e com menor custo financeiro em comparação aos modelos de aplicação similar. Assim, um modelo de previsão de inundação com aplicabilidade aprimorada pelas novas tecnologias torna-se protagonista para reduzir os impactos causados pelas inundações. Neste estudo, tem-se como objetivo comparar os modelos de previsão de inundações urbanas nos quais são utilizadas técnicas de mineração de dados, geoprocessamento (SIG) e *Machine Learning* (ou aprendizado da máquina). Os resultados ilustram a viabilidade da aplicação em áreas urbanas a partir do estudo de caso, com objetivo de contribuir para a gestão dos ambientes urbanos. A previsão da ocorrência de inundações é fundamental para alertar a população ribeirinha e de mobilização das equipes de atuação da defesa civil. Para isso, foram elaborados modelos para previsão de inundação com um dia de antecedência, onde os resultados obtidos dos modelos construídos com as técnicas de classificação de regras apresentaram resultados satisfatórios. Portanto, a previsão da ocorrência de inundações urbanas pode ser empregada como ferramenta de suporte à tomada de decisão para nortear as ações do poder público na gestão desta tipologia de desastre. O conhecimento apresentado busca contribuir nos debates das questões socioambientais e políticas públicas. Além disso, os resultados deste estudo podem ser replicados em outras localidades.

Palavras-chave: Inundação Urbana; Mineração de dados; Modelo de previsão; Planejamento Urbano; *Machine Learning*; SIG.

ABSTRACT

This is a study on natural disasters, with emphasis on urban floods, which have occurred more frequently, resulting in relevant socioeconomic impacts. Among the targeted measures to minimize the consequences of floods, empirical models linked with new technologies in a promising way and with lower financial cost in comparison to similar application models stand out. Thus, a flood prediction model with improved applicability by new technologies becomes a protagonist to reduce the impacts caused by floods. In this study, the objective is to compare urban flood prediction models in which data mining, geoprocessing (GIS) and Machine Learning techniques are used. The results illustrate the viability of the application in urban areas based on the case study, with the objective of contributing to the management of urban environments. Predicting the occurrence of floods is essential to alert the riverside population and to mobilize civil defense teams. For this, models were developed to predict flooding one day in advance, where the results obtained from the models built with the rule classification techniques showed satisfactory results. Therefore, forecasting the occurrence of urban floods can be used as a decision-making support tool to guide public authorities' actions in the management of this type of disaster. The knowledge presented seeks to contribute to debates on socio-environmental issues and public policies. In addition, the results of this study can be replicated in other locations.

Key-words: Urban Flood; Data mining; Forecasting model; Urban planning; Machine Learning; GIS.

LISTA DE ILUSTRAÇÕES

Figura 1: Valores autorizados no orçamento pelo governo federal para enfrentamento de Desastres (em R\$ milhões)	15
Figura 2: Percentual de execução orçamentária dos programas de enfrentamento de desastres.....	16
Figura 3: Inundação, enchente e alagamento.	20
Figura 4: Publicações que abrangem os três métodos de modelagem.....	26
Figura 5: Distribuição das publicações abrangentes das três categorias de modelagem por país	27
Figura 6: Estrutura da metodologia da pesquisa	29
Figura 7: Localização da Bacia Hidrográfica Ribeirão dos Padilhas	31
Figura 8: Caracterização da Bacia Hidrográfica Ribeirão dos Padilhas	33
Figura 9: Registros de inundação em Curitiba e na bacia hidrográfica Ribeirão dos Padilhas	36
Figura 10: Dendrograma (Distância Euclidiana).....	46
Figura 11: Dendrograma (Distância Euclidiana) – Recorte da variável em estudo. ..	46
Figura 12: RNA do tipo MLP.....	51

LISTA DE QUADROS

Quadro 1: Síntese dos trabalhos semelhantes.....	25
Quadro 2: Quantificação do Uso e Ocupação do Solo da Bacia Hidrográfica Ribeirão dos Padilhas.....	32
Quadro 3: Registros de Inundação em Curitiba conforme a Bacia Hidrográfica	35
Quadro 4: Variáveis Aplicadas	38
Quadro 5: Coeficientes de relação linear	43
Quadro 6: Coeficientes de carga fatorial	44
Quadro 7: Método <i>k-means</i>	45
Quadro 8: Matriz da confusão das combinações para a previsão de inundação (t_0).47	
Quadro 9: Matriz da confusão das combinações para a previsão de inundação (t_1).49	
Quadro 10: Divisão das amostras de entrada no <i>software</i> SNN	51
Quadro 11: Matriz de confusão situação 01	51
Quadro 12: Matriz de confusão situação 02	52
Quadro 13: Matriz de confusão situação 03.....	52
Quadro 14: Resultados de validação do <i>software</i> SNN	52
Quadro 15: Síntese dos resultados dos modelos.....	52

ABREVIATURAS E SIGLAS

ANA	Agência Nacional de Águas e Saneamento Básico
CBA	<i>Classification Based on Associations</i>
CNM	Confederação Nacional de Municípios
CRED	<i>Centre for Research on the Epidemiology of Disasters</i>
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
GARP	Produção de Conjunto de Regras de Algoritmos Genéticos
IAT	Instituto Água e Terra do Paraná
IBGE	Instituto Brasileiro de Geografia e Estatística
INMET	Instituto Nacional de Meteorologia
IPPUC	Instituto de Pesquisa e Planejamento Urbano de Curitiba
ITCG	Instituto de Terras, Cartografia e Geologia do Paraná
Km ²	Quilometro Quadrado
MCA	Integração da Análise Multicritério
MCDM	Método de decisão multicritério (<i>Multiple-criteria decision-making</i>)
MD	Mineração de Dados
ML	<i>Machine Learning</i>
MLP	<i>Multiple Layer Perceptron</i>
mm	Milímetros
PMC	Prefeitura Municipal de Curitiba
PNPDEC	Política Nacional de Proteção e Defesa Civil
QUEST	Árvore Estatística Eficiente Rápida e Imparcial
RF	<i>Random Forest</i>
RNA	Redes Neurais Artificiais
SIG	Sistema de Informação Geográfica
SIMEPAR	Sistema Meteorológico do Paraná
SNN	<i>Statistica Neural Networks</i>
SVM	Máquina de Vetores de Suporte
UNISDR	<i>UN Office for Disaster Risk Reduction</i>
UTM	<i>Universal Transversa de Mercator</i>
WELLSVM	Máquina de Vetor de Suporte Fracamente Rotulado

SUMÁRIO

1	INTRODUÇÃO	12
1.1	PROBLEMATIZAÇÃO	13
1.2	OBJETIVOS.....	17
1.2.1	Objetivos Específicos.....	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	PLANEJAMENTO E GESTÃO URBANA.....	18
2.2	DESASTRES NATURAIS (INUNDAÇÕES URBANAS).....	19
2.3	FERRAMENTAS TECNOLÓGICAS	21
2.3.1	Sistema de Informação Geográfica (SIG)	22
2.3.2	<i>Machine Learning</i>	22
2.3.3	Mineração de dados	23
2.3.4	Análise Multivariada	24
2.3.5	Redes Neurais Artificiais (RNA)	24
2.4	APLICAÇÃO NO PLANEJAMENTO URBANO.....	25
3	ESTRUTURAÇÃO METODOLÓGICA	29
3.1	ESTUDO DE CASO.....	30
3.2	COLETA DE DADOS.....	34
3.3	PREPARAÇÃO DOS DADOS	34
3.4	CARACTERIZAÇÃO DAS VARIÁVEIS.....	35
3.4.1	Dados da Defesa Civil	35
3.4.2	Dados Meteorológicos	37
3.4.3	Definição das Variáveis.....	37
3.5	ANÁLISE MULTIVARIADA	39
3.6	MODELAGEM	40
3.6.1	Classification Based on Associations (CBA)	40
3.6.2	Redes Neurais Artificiais (RNA)	40
3.6.3	Acurácia e Precisão.....	41
4	RESULTADOS	43
4.1	ANÁLISE MULTIVARIADA	43
4.2	PREVISÃO DE INUNDAÇÃO	47
4.2.1	<i>Classification Based on Associations (CBA)</i>.....	47
4.2.2	Redes Neurais Artificiais (RNA)	50

4.3	APLICABILIDADE NO PLANEJAMENTO URBANO	52
5	CONCLUSÕES E RECOMENDAÇÕES.....	55
6	REFERÊNCIAS	57

1 INTRODUÇÃO

As políticas de modernização na agropecuária ocorridas na década de 1970, proporcionaram aos grandes produtores rurais a forte mecanização de seus processos produtivos e redução drástica na demanda de mão de obra, que resultou em um intenso êxodo rural entre os anos de 1970 e 1980 (MUELLER & MARTINE, 1997). O aumento da população urbana durante esse período resultou em impactos danosos para cidade pelo fato de concentrar as oportunidades de emprego em um fragmento da cidade e estender a ocupação de periferias cada vez mais distantes.

O resultado foi uma urbanização desordenada, a qual sob a ótica ambiental, resultou na ocupação de áreas de risco ou estratégicas. Como consequências, são comuns os casos de inundações, onde o habitante é penalizado de forma individual, ou ainda em escalas de grande proporção, que acarreta em danos coletivos, como em caso de contaminação dos mananciais de abastecimento, o que afeta a cidade como um todo (BRASIL, 2001).

O aumento do acúmulo de gases de efeito estufa tem resultado em alterações na atmosfera, a qual tem apresentado temperaturas cada vez mais elevadas e por consequência, alterações no volume e periodicidade das chuvas críticas conhecidas e previstas. Devido a essas alterações do clima, é esperado um crescimento na gravidade e periodicidade das inundações (BERGHUIJS et al., 2017). Atrelado a esse fato, os desastres naturais têm sido objeto de preocupação dos gestores das cidades, uma vez que possuem grande potencial de danos significativos às populações, como perda de vidas, econômicas, sociais e ambientais.

Desta forma, o planejamento urbano carece de novos instrumentos que possam estabelecer diretrizes igualitárias e proporcionar novas metodologias de gestão. Assim, há necessidade de adotar novas ferramentas e métodos resultantes do desenvolvimento tecnológico para auxiliar na avaliação de uso e ocupação do solo, ao empregar as técnicas sob a ótica do planejamento e gestão urbana.

Apresentam-se de maneira promissora, as técnicas de geoprocessamento através do uso do Sistema de Informações Geográfica (SIG), a qual possui a capacidade para estabelecer relações espaciais entre elementos gráficos. E ainda, as técnicas de *Machine Learning* (ou aprendizado da máquina), que vem a identificar e priorizar estratégias de atuação a partir da inserção de dados e da inteligência artificial.

As referidas ferramentas podem contribuir para a tomada de decisão dos gestores, haja vista a capacidade de representar a realidade, o que possibilita mapear as áreas suscetíveis a desastres naturais, áreas de preservação, áreas de expansão urbana, entre outras demandas.

Em uma análise de risco é possível elaborar medidas preventivas, planificar as eventualidades emergências e estabelecer ações conjuntas entre comunidade e o poder público, com o intuito de promover a defesa permanente contra os desastres naturais (ALMEIDA, 2007).

Tendo em vista as demandas apresentadas, esta dissertação tem como objetivo principal responder a seguinte questão problema: **como as novas tecnologias podem contribuir na previsão de inundações urbanas e no planejamento urbano?** Deste modo, a pesquisa busca padrões da relação entre as variáveis que acarretam na ocorrência de inundações, com a aplicação das técnicas de geoprocessamento (SIG) e de aprendizado da máquina no recorte geográfico da Bacia Hidrográfica do Ribeirão dos Padilhas, localizada no Município de Curitiba, para demonstrar a aplicabilidade de tais ferramentas tecnológicas como suporte à gestão e planejamento urbano.

1.1 Problemática

A base teórica sobre o tema dos desastres naturais é formada por inúmeros conceitos e práticas metodológicas. Mesmo que não exista um padrão universal, é possível identificar algumas diretrizes para categorias qualitativas e quantitativas de desastres e seus componentes. O ponto de partida é o próprio desastre, caracterizado pelas mudanças decorrentes da interação entre fenômenos naturais e as condições características de uma comunidade, que resulta em impactos negativos sobre as pessoas, a economia, o meio ambiente, entre outros fatores (RIBEIRO et al., 2016).

Nos últimos 20 anos, mundialmente os desastres relacionados ao clima causaram a morte de milhões de pessoas, bilhões de desabrigados ou deslocados. Dos mais de 7 mil eventos registrados, 91% foram causados por inundações, tempestades, secas, ondas de calor e outros eventos climáticos extremos (CRED, UNISDR, 2018).

Ainda sob a ótica mundial, as inundações consistem na categoria de desastre com maior incidência, responsável por 43% do total no período de 1998 a 2017, além de afetar mais de 2 bilhões de pessoas. Outro impacto causado pelas inundações, foi o grande número de mortes ocorridas devido a este tipo de evento que resultou em 142.088 mortes (CRED, UNISDR, 2018).

As perdas econômicas geradas pelas inundações alcançaram 23% do total das perdas causadas por desastres relacionadas ao clima, o que representa 656 bilhões de dólares no período de 1998 a 2017. Entre os anos de 2006 e 2017, foi constatado que a área das atividades da pecuária, pesca, agricultura e silvicultura dos países em desenvolvimento, absorveram 26% dos danos causados em inundações, tempestades e secas. As inundações corresponderam a dois terços desses danos (CRED, UNISDR, 2018).

Cabe destacar, que as inundações urbanas são o tipo de desastre natural mais recorrente no Brasil, responsáveis por ocasionar danos econômicos estimados em aproximadamente 9 bilhões de dólares entre os anos 1990 e 2015 (CRED, UNISDR, 2018). Assim, este tipo de evento é considerado um dos mais graves desastres da natureza, pois além de causar prejuízos de milhões de dólares por danos materiais e à infraestrutura, também ocasiona a morte de milhares de pessoas todos os anos. Em razão disso, é importante fornecer informações seguras ao público para que haja prevenção e redução de danos.


Segundo levantamento realizado pela Confederação Nacional de Municípios (CNM, 2022), no período de 2013 a 2022, foram registrados no Brasil milhares de desastres em geral, os quais causaram R\$ 341,3 bilhões de prejuízos, com relevantes perdas ambientais, materiais e fatalidades. Esses desastres, a despeito de sua natureza, como chuvas torrenciais e consequentes deslizamentos de massa e inundações, encobrem por diversas vezes o real motivo, que se deve à ausência de políticas públicas de habitação, saneamento básico e infraestrutura eficazes que escancaram a precariedade da articulação de políticas de prevenção de desastres.

Apesar do estudo divulgar informações sobre os prejuízos causados por desastres no Brasil entre anos de 2013 a 2022, cabe destacar que outros levantamentos acerca das despesas foram realizados por parte do governo federal a partir do recorte entre os anos de 2010 a 2022. Os levantamentos foram mensurados por meio das execuções orçamentárias de programas federais de drenagem urbana,

gestão de riscos, prevenção, preparação, resposta à desastres, reabilitação e reconstrução de áreas danificadas e destruídas (CNM, 2022).

A Figura 1 ilustra os valores autorizados para os programas citados, os quais apresentam reduções significativas nos últimos anos. No ano de 2022, somente 1,2 bilhão de reais foram autorizados para a pauta, se considerar a inflação do período, deve ser o menor valor real destinado para o enfrentamento de desastres desde o ano de 2010 (CNM, 2022).

Figura 1: Valores autorizados no orçamento pelo governo federal para enfrentamento de Desastres (em R\$ milhões)



Fonte: Adaptado de CNM, 2022.

Outro fato alarmante ao analisar a execução orçamentária desses programas é o baixo percentual de execução. A Figura 2 ilustra que o percentual médio de execução do orçamento foi de 47% no período entre 2010 e 2021. Isso indica que a cada R\$ 100,00 que o governo federal autorizou para ser destinado à prevenção ou resposta a desastre, apenas R\$ 47,00 foram efetivamente gastos (CNM, 2022).

Figura 2: Percentual de execução orçamentária dos programas de enfrentamento de desastres



Ainda, o levantamento destaca que no período de 2010 a 2021, o governo federal orçou o valor de 36,5 bilhões de reais para auxiliar os municípios em ações de gestão de riscos, prevenção, respostas a desastres e recuperação de áreas destruídas e/ou danificadas. Entretanto, no referido período, o governo federal efetuou o repasse de somente 15,3 bilhões de reais. Ao comparar os prejuízos de R\$ 341,3 bilhões que os desastres causaram em todo país entre os anos de 2013 a 2022, o valor pago pela União correspondeu apenas a 4,5% desse total (CNM, 2022).

De acordo com dados da Defesa Civil do Estado do Paraná relacionados ao tema, cabe destacar o desastre ocorrido no município de União da Vitória no ano de 1983, o qual desabrigou aproximadamente 2.400 famílias e levou a óbito 18 pessoas. Em 2011, foi registrado o desastre denominado “*águas de março*”, o qual atingiu 4 municípios do litoral do Estado, ocasionou a morte de 4 pessoas e afetou mais de 18 mil pessoas (PARANÁ, 2019).

Apesar do município de Curitiba não possuir um histórico de grandes desastres naturais, os registros disponíveis de acordo com a Defesa Civil Municipal, relatam que nos anos de 1983, 1994 e 1999, ocorreram inundações que deixaram a cidade em Estado de Emergência (CURITIBA, 2009).

Ainda, Zanella (2014) constata que entre os anos de 1980 e 2002, ocorreram 85 inundações no município de Curitiba, dentre estas, 7 eventos tiveram maior magnitude por superar 100 mm totais diários de precipitação. Destaca-se o evento ocorrido em 1995, o qual levou o município a decretar Estado de Calamidade Pública

em virtude de ter desabrigado aproximadamente 16 mil pessoas, no óbito de 3 pessoas e nos prejuízos estimados de 20 milhões de reais.

Portanto, denota-se a partir da recorrência dos desastres e a redução dos investimentos em ações de prevenção e mitigação dos mesmos, em especial as inundações urbanas, a demanda por medidas viáveis é imprescindível para auxiliar na tomada de decisão e fomentar políticas públicas para gestão de desastres, bem como, o ordenamento da ocupação territorial.

1.2 Objetivos

O objetivo deste trabalho consiste em comparar os modelos de previsão de inundações urbanas.

1.2.1 Objetivos Específicos

Para atingir o objetivo geral desta pesquisa, tem-se os seguintes objetivos específicos:

-) Demonstrar a aplicabilidade da inteligência artificial ao Planejamento e a Gestão da cidade através do estudo de caso na bacia hidrográfica Ribeirão dos Padilhas; e,
-) Avaliar a acurácia da previsão dos modelos.

2 FUNDAMENTAÇÃO TEÓRICA

O referencial teórico se estrutura em quatro questões principais, discutidos inicialmente o planejamento e gestão urbana (1), desastres naturais (2) e ferramentas tecnológicas (3). Na sequência são discutidos os modelos utilizados para aprimoramento do Planejamento Urbano (4), os quais estão diretamente relacionados.

2.1 Planejamento e Gestão Urbana

O planejamento urbano consiste em uma prática que busca racionalizar os processos de desenvolvimento das cidades, com o objetivo de quantificá-los por meio da elaboração do diagnóstico municipal, como suporte para elaboração de propostas que compreendam uma ótica multidisciplinar, ao utilizar um método unificador que promova o raciocínio lógico e induza a decisões corretas (GONZALES; FRANCISCONI; PAVIANI, 2013).

O planejamento pode ser definido como as possibilidades de prever as tendências do fenômeno em estudo para intervenção. Portanto, o conhecimento de um determinado fenômeno possibilita realizar previsões de seu comportamento. Dessa forma, a aplicação do método científico aos fenômenos urbanos se demonstra necessária por exigência da própria natureza do planejamento (GONZALES; FRANCISCONI; PAVIANI, 2013).

A gestão e o planejamento urbano têm se direcionado principalmente à elaboração do plano diretor e de zoneamento, os quais definem padrões de ocupação do solo fundamentados pela dinâmica de mercados fomentados pela classe de média e alta renda, o qual ocupa um espaço superior à sua dimensão. Deste modo, os mercados de baixa renda são ignorados, o que ocasiona uma escassez de espaços na cidade (BRASIL, 2001).

Para impulsionar as mudanças territoriais que demandam as cidades, inclui-se os instrumentos de indução do desenvolvimento urbano, os quais tem o objetivo de identificar a ocupação das áreas que dispõem de infraestrutura e equipamentos aptas para urbanização ou povoamento e evitar a ocupação indevida de locais sem infraestrutura ou frágeis do ponto de vista ambiental (BRASIL, 2001).

Ainda, os instrumentos de desenvolvimento urbano têm a função de aumentar a disponibilidade de espaço e edificações para sanar a demanda existente e evitar que os indivíduos que não encontrem oportunidades de moradia nas regiões centrais, se instalem em periferias longínquas, áreas desprovidas de infraestrutura, áreas de risco de inundação, desabamentos ou de preservação ambiental (BRASIL, 2001).

2.2 Desastres Naturais (Inundações Urbanas)

Neste capítulo, são apresentadas as definições e inter-relações de termos essenciais no campo da gestão de riscos e desastres. Começando pelo conceito de desastre, que se refere a situações em que eventos adversos afetam áreas que não possuem a capacidade estrutural necessária para resistir aos impactos. Um desastre é resultado da combinação de um fenômeno prejudicial em um cenário vulnerável, englobando eventos naturais, tecnológicos ou de origem antrópica. Os desastres causam danos humanos, materiais e ambientais, gerando prejuízos econômicos e sociais significativos (BRASIL, 2017).

Dentro desse contexto, o evento adverso descreve um acontecimento físico, potencialmente prejudicial, que pode causar morte, lesões, danos materiais, interrupção de atividades sociais e econômicas, ou degradação do meio ambiente. Esses eventos podem ser de natureza natural, como terremotos, enchentes e tempestades, ou de origem humana, como acidentes industriais ou colapsos estruturais (BRASIL, 2017).

As áreas suscetíveis são definidas por características físicas que as tornam propensas a ocorrências de eventos adversos. Essa suscetibilidade expressa uma condição potencial de risco, considerando atributos geográficos, topográficos, climáticos e outros fatores que influenciam a probabilidade de um evento ocorrer em determinada região (BRASIL, 2017).

Por sua vez, a vulnerabilidade é a exposição socioeconômica ou ambiental de um cenário sujeito à ameaça natural, tecnológica ou de origem antrópica (BRASIL, 2017). Ela indica como as condições preexistentes tornam os elementos expostos mais ou menos propensos a serem afetados pelos eventos adversos. A vulnerabilidade é influenciada por fatores socioeconômicos, culturais, institucionais e

ambientais, refletindo as condições de vida e as características coletivas e individuais de uma determinada área (MARANDOLA JR., 2009).

Por fim, o risco de desastre é o potencial de ocorrência de um evento adverso em um cenário socioeconômico e ambiental vulnerável. A gestão de risco de desastre engloba o planejamento, a coordenação e a implementação de medidas preventivas para reduzir os riscos de desastres e evitar a criação de novos riscos (BRASIL, 2017). Cabe destacar, que os riscos só existem quando há presença humana, do contrário, são eventos naturais e não há vulnerabilidade.

O crescimento populacional e a exploração do mercado imobiliário, estão entre os principais agravantes para a ocorrência de desastres, pois sem alternativa de habitação, as populações de menor poder aquisitivo tendem a se instalar em áreas de baixo valor econômico, como por exemplo, nas planícies aluviais sujeitas à inundação (OLIVEIRA et al., 2006).

As inundações são definidas como o transbordamento de água proveniente de recursos hídricos superficiais devido a precipitações anormais, o que diferencia do conceito de enchente, que é a gradual elevação do nível do rio, mas no qual não ocorre o transbordamento de sua calha de escoamento. Ainda relacionado, tem o conceito de alagamento, que pode ser definido pela insuficiência do sistema de drenagem que resulta no acúmulo das precipitações (TUCCI, 2007).

Figura 3: Inundação, enchente e alagamento.



Fonte: Curitiba, 2017.

A inunda  o pode ser definida por um evento hidrol gico que ocorre em consequ ncia de epis dios de origem natural. Todavia, quando o fen meno atinge e afeta a popula  o humana,   denominado de desastre natural. Em termos hidrol gicos, as inunda  es resultam do aumento do n vel dos rios acima de sua vaz o habitual que gera o transbordamento da  gua para as  reas pr ximas a ele (KOBAYAMA et al., 2006).

As medidas utilizadas para minimizar as inunda  es se dividem em estruturais, que exigem maior aporte financeiro e as n o estruturais, que em geral s o economicamente mais vi veis e se baseia em a  es de preserva  o e conserva  o, e objetiva estabelecer um equil brio entre a popula  o urbana residente pr xima ao leito do rio e o meio ambiente (TUCCI, 2007).

Para Tucci (2007) a gest o da inunda  o   alcan ada por uma combina  o de medidas estruturais e n o estruturais que possibilite   popula  o local minimizar suas perdas e manter uma conviv ncia harm nica com o rio. As a  es incluem medidas de engenharia e de cunho social, econ mico e administrativo. As escolhas dessas a  es formam o planejamento da prote  o contra a inunda  o e seus efeitos.

2.3 Ferramentas Tecnol gicas

O desenvolvimento da tecnologia da informa  o disponibilizou novos recursos para modernizar os processos de planejamento e gest o urbana. Ao mesmo tempo,   poss vel desenvolver novos usos da informa  o, cada vez mais explorados pelos  rg os de gest o urbana brasileiros. As t cnicas convencionais de planejamento urbano, quando aplicadas para monitorar a expans o das cidades, n o s o suficientes para acompanhar a velocidade com que o fen meno ocorre (FARINA, 2016).

Por isso, novos m todos, os quais empregam tecnologias mais adequadas para detectar a expans o urbana e as altera  es ambientais decorrentes, vem contribuir para maior efici ncia da a  o dos  rg os de planejamento (FARINA, 2016).

A seguir, conceitua-se algumas ferramentas tecnol gicas com aplicabilidade e maior ader ncia ao planejamento e gest o urbana.

2.3.1 Sistema de Informação Geográfica (SIG)

Nos últimos anos, impulsionado pelos avanços tecnológicos, a essência da representação de cidades e regiões migrou quase que integralmente para o âmbito digital, as quais passaram a ser representadas por meio de Sistemas de Informações Geográficas (SIG) (BATTY, 2007).

O SIG pode ser definido como instrumento de elaboração eletrônica que permite a coleta, gestão, análise e representação automatizada de dados georreferenciados (MOURA, 2014). Existem várias aplicações do Sistema de Informação Geográfica (SIG) no planejamento urbano, como a análise de localização adequada para diferentes tipos de infraestrutura urbana, como escolas, hospitais, parques, estações de transporte público e instalações de reciclagem.

Os planejadores podem usar dados geográficos para identificar as áreas onde essas infraestruturas são mais necessárias, levando em consideração a distribuição da população, a acessibilidade e outros fatores relevantes. Ou ainda, na gestão de recursos naturais, onde auxilia na gestão de recursos naturais urbanos, como áreas verdes, bacias hidrográficas, qualidade do ar e disponibilidade de água, possibilitando uma abordagem sustentável e eficiente.

Essas são apenas algumas das aplicações do SIG na gestão urbana, e suas capacidades podem ser adaptadas para atender às necessidades específicas de cada cidade ou região. Para o presente trabalho, será aplicado para localização de situações de risco, permitindo identificar e auxiliar no planejamento de ações preventivas e de resposta a emergências.

2.3.2 *Machine Learning*

As técnicas de *Machine Learning* (ou aprendizado da máquina) são capazes de processar e analisar um grande volume de dados rapidamente. Ainda, as técnicas demonstram possibilidade para reconhecimento de padrões e previsão de tendências, o que vem a tornar possível identificar prontamente informações que destoam do padrão previamente estabelecido (MONARD e BARANAUSKAS, 2005).

O aprendizado da máquina pode ser dividido em *supervisionado* e *não supervisionado*. Na primeira opção, é fornecido ao algoritmo de aprendizado, ou

indutor, um conjunto de exemplos de treinamento para os quais o rótulo de classe associado é conhecido. Para o aprendizado não supervisionado, o indutor analisa os exemplos fornecidos e tenta determinar se alguns deles podem ser agrupados de alguma maneira, o que resulta na formação de agrupamentos ou *clusters* (MONARD e BARANAUSKAS, 2005).

A aplicação do aprendizado de máquina no planejamento urbano envolve o uso de algoritmos e modelos para analisar grandes conjuntos de dados geográficos e extrair informações relevantes para tomar decisões informadas. Por exemplo, o aprendizado de máquina pode ser utilizado para prever padrões de crescimento urbano, demanda de transporte, necessidades de infraestrutura e distribuição de serviços públicos.

2.3.3 Mineração de dados

A evolução da computação permitiu o aumento da capacidade de processamento e armazenamento de dados. O processo de extração de conhecimento de base de dados tem o objetivo de encontrar conhecimento a partir de um conjunto de dados para ser utilizado em um processo decisório. Trata-se de uma área multidisciplinar que incorpora técnicas utilizadas em diversas áreas, como Base de Dados, Inteligência Artificial e Estatística (PUGLIESE; MLEANDA; PAULA, 2007).

A Mineração de Dados (MD) é aceita por diversos pesquisadores como o processo de identificação de padrões válidos, novos, potencialmente úteis e compreensíveis embutidos nos dados. O processo de MD pode ser dividido em cinco etapas: identificação do problema, pré-processamento, extração de padrões, pós-processamento e utilização do conhecimento (PUGLIESE; MLEANDA; PAULA, 2007).

Uma parte relevante da Mineração de Dados emprega técnicas e algoritmos na execução, dentre elas, a Análise Estatística, Aprendizado da Máquina, Algoritmos Genéticos e Redes Neurais Artificiais (PUGLIESE; MLEANDA; PAULA, 2007).

A mineração de dados pode ser aplicada no planejamento urbano para extrair informações valiosas a partir de conjuntos de dados complexos. Através da análise de dados geográficos, demográficos, econômicos e sociais, a mineração de dados pode revelar padrões e tendências que são essenciais para o planejamento urbano. Por exemplo, pode-se utilizar algoritmos de mineração de dados para identificar áreas

de crescimento populacional, padrões de mobilidade, demanda por serviços públicos, distribuição desigual de recursos, entre outros aspectos relevantes.

2.3.4 Análise Multivariada

A análise multivariada busca identificar padrões quantitativos no banco de dados a partir das variáveis, que são preponderantes para construção do modelo quantitativo (SOUZA, 2019).

A análise multivariada contempla abordagens analíticas, que incluem a mineração de dados para estudar fenômenos, dentre eles, os desastres naturais (SOUZA, 2019). Com isso, possibilita a redução de riscos ambientais globais em localidades com grande variação de características, com o objetivo de desenvolver sistemas sustentáveis referentes à prevenção de desastres naturais, e em especial, as inundações urbanas.

2.3.5 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) são inspiradas nas estruturas neurais biológicas e desenvolvidas por modelos matemáticos, em que as habilidades computacionais são agregadas por meio do aprendizado e generalização, de modo a adaptar seus parâmetros pela interação com o meio externo (BRAGA; CARVALHO; LUDERMIR, 2005).

Dentre as funcionalidades das RNAs, incluem-se a solução de problemas de aproximação, predição, classificação, categorização e otimização. Os quais podem ser apresentados de diferentes formas, como reconhecimento de caracteres, reconhecimento de voz, predição de séries temporais, modelagem de processos, entre outras (BRAGA; CARVALHO; LUDERMIR, 2005).

Portanto, as redes neurais podem ser aplicadas no planejamento urbano como ferramentas poderosas de análise e previsão. Por exemplo, elas podem ser usadas para otimizar o planejamento do uso do solo, considerando múltiplos fatores, como densidade populacional, acessibilidade e impactos ambientais. O modelo de RNA pode fornecer subsídios essenciais para tomada decisões, considerando a complexidade e as interações dinâmicas presentes no ambiente urbano.

2.4 Aplicação no Planejamento Urbano

Na perspectiva do planejamento e gestão urbana, são diversas as possibilidades de aplicação destas ferramentas tecnológicas ao considerar sua capacidade operacional. A partir da revisão bibliográfica foram encontrados trabalhos semelhantes ao proposto, os quais são sintetizados no Quadro 1.

Quadro 1: Síntese dos trabalhos semelhantes

Identificação	Local do estudo	Objetivo	Técnica Utilizada
KOURGIALAS & KARATZAS (2011).	Bacia do rio Koiliaris, à 15 km a leste da Cidade de Chania, Creta, Grécia.	Uma abordagem viável para estabelecer a estratégia de gestão de inundações em uma área de captação, com base na Diretiva Europeia.	Integração da análise multicritério (MCA) com um SIG baseado em grade.
MOJADDADI et. al., (2017).	A bacia do rio Damansara está localizada ao lado de Kampung Baru Subang em Selangor, Malásia.	Determinar o nível de risco de inundação em uma área de estudo que é afetada por inundações anuais. A previsão de cheias é para evitar custos futuros devido à a via expressa.	Para estimar a probabilidade, utilizou a razão de frequência (FR) combinada com a máquina de vetores de suporte (SVM). Em seguida, para estimar a profundidade o modelo hidráulico 2D.
RIZEEI, PRADHANA E SAHARKHIZ (2019).	Cidade de Damansara, na Península da Malásia.	Analisar a posição ideal dos centros de resposta de emergência, haja vista a etapa fundamental para o planejamento urbano e mitigação de riscos.	Técnica de aprendizado da máquina (ML), a <i>Multiple Layer Perceptron</i> (MLP).
DARABI et. al., (2019).	Cidade de Sari, ao norte do Irã, próximo a foz da bacia hidrográfica do rio Tarjan e do mar Caspian.	Desenvolver novas abordagens baseadas nas técnicas de aprendizado da máquina para modelar e mapear o risco de inundação urbana.	Técnicas de ML de Produção de Conjunto de Regras de Algoritmos Genéticos (GARP) e na Árvore Estatística Eficiente Rápida e Imparcial (QUEST).
ZHAO et. al., (2019).	Pequim, a capital da China.	Fornecer uma abordagem para a avaliação da suscetibilidade a inundações em áreas urbanas de alta heterogeneidade espacial.	Modelo de ML semi supervisionado - a Máquina de Vetor de Suporte Fracamente Rotulado (WELLSVM).
POURGHASEMI et. al., (2020).	Província de Fars, no Irã.	Avaliar a probabilidade de múltiplos riscos (inundação, incêndio florestal e deslizamento).	Mapas de suscetibilidade elaborados com o modelo Random Forest (RF) no software estatístico R.
RAFIEI-SARDOOI et. al., (2021).	Cidade de Jiroft, Irã	Integração de ferramentas multicritério de tomada de decisão e aprendizado de máquina na avaliação de risco de inundação urbana.	Elaboração dos mapas de risco de inundação com três métodos de ML (máquina de vetor de suporte, floresta aleatória e árvore de regressão aprimorada).


Fonte: O autor.

Pode-se observar que a minoria dos trabalhos encontrados é do continente europeu. Isso se deve a uma exigência da União Europeia para que todos os países

membros elaborassem mapas de inundação e risco para seu território até o ano de 2015. Deste modo, atualmente grande quantidade de países europeus possui mapas de inundações elaborados por organizações governamentais (COOK e MERWADE, 2009).

O trabalho de Mudashiru et. al. (2021), realizou uma revisão da geração de publicações relacionadas no período de 2000 a 2021, para os três métodos de mapeamento de risco de inundação. São considerados os métodos de modelagem física (numérica), física e empírica. Os métodos de modelagem com base física são subcategorizados em modelos numéricos 1, 2 e 3D, enquanto os métodos de modelagem empírica são subcategorizados em aprendizado de máquina, MCDM e métodos estatísticos.

O trabalho obteve o resultado de um total de 249 artigos, dos quais 109 artigos foram revisados para a modelagem física (numérica), 25 artigos para modelo físico e 115 artigos para os métodos de modelagem empírica. A Figura 4 ilustra as publicações conforme as referidas metodologias.




Cabe destacar que o método de modelagem empírica, o qual pode ser categorizado como uma abordagem mais recente no método de modelagem de risco de inundação, demonstrou um aumento de 35% no percentual de publicação entre 2000 e 2019. Isso pode estar relacionado ao crescente interesse em aprendizado de

máquina e inteligência artificial e melhor tomada de decisão como ferramenta chave no mapeamento de áreas de risco de inundação (MUDASHIRU et. al., 2021).

A Figura 5 ilustra a distribuição das publicações por categoria de modelagem e país.

Figura 5: Distribuição das publicações abrangentes das três categorias de modelagem por país



Fonte: Mudashiru et. al., 2021.

O resultado das descobertas sistemáticas da literatura indica uma taxa de aplicação de 46,20% de métodos de modelagem empírica, o que supera a taxa de aplicação de 43,8% para modelagem baseada fisicamente e de 10% para métodos de modelagem física (MUDASHIRU et. al., 2021).

O autor destaca que apesar da capacidade dos modelos físicos em apresentar cenários de inundações precisos e realistas, esses modelos são caros para se construir. Ainda que os modelos empíricos possam delinear regiões de perigo/suscetibilidade de inundação e avaliar a vulnerabilidade e o risco de inundação, esses modelos não podem prever a profundidade do fluxo, a velocidade e a probabilidade de recorrência futura (MUDASHIRU et. al., 2021).

Por fim, destaca-se que com todas as capacidades e poucas limitações dessas abordagens, pesquisadores e tomadores de decisão podem encontrar precisão, potencial, oportunidade de combinar e entender incertezas e riscos associados a esses métodos. E ainda, os pesquisadores podem escolher as inúmeras lacunas e trabalhar nelas para fazer uma melhoria significativa no campo da análise de inundações (MUDASHIRU et. *al.*, 2021).

No Brasil, não houve significativo progresso em relação ao mapeamento de risco de inundação, principalmente na inexistência de uma metodologia consolidada entre os órgãos para elaboração. Já na gestão de inundações, houve por meio da implementação da Política Nacional de Proteção e Defesa Civil (PNPDEC), a descentralização de responsabilidades, divididas entre esfera Federal, Estadual e Municipal.

Um fator relevante, foi a definição do mapeamento das áreas de inundações utilizado como critério para o desenvolvimento do programa de habitação social Minha Casa Minha Vida, em 2009 e que sofreu diversas modificações. Dentre elas, a Portaria Ministério das Cidades nº 114/2018, a qual prioriza a implantação de moradia social para população que está em áreas de risco de inundação.

Portanto, os modelos de previsão desempenham um papel fundamental no planejamento e na gestão urbana, pois fornecem uma visão baseada em dados sobre as tendências e os desafios futuros enfrentados pelas cidades. Ao utilizar esses modelos, os gestores possuem uma tomada de decisão mais informada e eficiente, possibilitando a implementação de medidas preventivas e soluções sustentáveis.

Além disso, os modelos de previsão permitem a avaliação de diferentes cenários e a análise de impacto de políticas urbanas, contribuindo para o desenvolvimento de estratégias adaptativas e resilientes. Em um cenário urbano de constante transformação, a importância dos modelos de previsão para o planejamento e a gestão urbana é indiscutível, pois fornecem uma base sólida para a tomada de decisões que impactam diretamente a qualidade de vida dos habitantes e a sustentabilidade das cidades.


3 ESTRUTURAÇÃO METODOLÓGICA

Trata-se de uma pesquisa exploratória que busca analisar a viabilidade da adoção de ferramentas tecnológicas no planejamento urbano. A metodologia está dividida em duas etapas principais, com o início pela revisão bibliográfica. Em seguida a pesquisa aplicada, com o propósito de gerar conhecimento para aplicação dirigida à solução de problemas específicos. Abaixo, as subdivisões das etapas metodológicas:

-) Fonte de dados: Literatura Científica e Dados Espaciais (geográficos);
-) Técnica de Coleta: Revisão narrativa e Levantamento Documental;
-) Técnicas de Análise: Argumentativa, Qualitativa e Análise Estatística.

A Figura 6 a seguir, ilustra as etapas de construção e estruturação da presente pesquisa.

Figura 6: Estrutura da metodologia da pesquisa



Fonte: O autor.

3.1 Estudo de Caso

A adoção de uma bacia hidrográfica como unidade de planejamento é considerada de aceitação universal, devido ao fato de constituir um sistema natural delimitado no espaço, composto por um conjunto de terras topograficamente drenadas por um curso d'água e seus afluentes, no qual suas interações físicas são integradas e assim, mais facilmente interpretadas (SANTOS, 2004).


A Bacia Hidrográfica do Ribeirão dos Padilhas é uma das 29 Bacias Hidrográficas que compõem a Sub-Bacia Hidrográfica Alto Iguaçu, com sua localização geopolítica inteiramente na região sul do Município de Curitiba, capital do Estado do Paraná.

O Município de Curitiba, possui a população de aproximadamente 1.963.726 habitantes e uma área de 435,495 km² (IBGE, 2021), a qual sobrepõem seis bacias hidrográficas: Atuba-Bacacheri, Belém, Barigui, Passaúna, Ribeirão dos Padilhas e Iguaçu.

A bacia hidrográfica Ribeirão dos Padilhas possui a área de 31,78 km², o que corresponde a ocupação parcial de 10 bairros dos 75 que compõem o Município de Curitiba. Dentre eles, cabe destacar os 6 bairros que possuem ocupação extensão territorial, sendo: Alto Boqueirão (2,49 km²), Capão Raso (2,14 km²), Ganchinho (3,41 km²), Pinheirinho (6,71 km²), Sítio Cercado (10,90 km²) e Xaxim (6,03 km²).

Segundo dados disponibilizados pelo IBGE (2010) por meio dos setores censitários, residiam na área da Bacia Hidrográfica aproximadamente 261.781 pessoas em 86.366 domicílios, a qual correspondia aproximadamente 15% da população curitibana no ano de 2010 (População total 1.751.907 pessoas).

Figura 7: Localização da Bacia Hidrográfica Ribeirão dos Padilhas



Fonte: ITCG, 2018; IPPUC, 2021; SUDERHSA, 2000, modificados pelo autor.

A Bacia Hidrográfica Ribeirão dos Padilhas (Figura 8), possui o total de 91.732,27 metros de extensão em corpos hídricos, com 48.024,27 metros canalizados (aproximadamente 52,29%). O Ribeirão dos Padilhas, corpo hídrico principal, possui 10.191,68 metros de extensão (SUDERHSA, 2002).

Na bacia hidrográfica em questão, também foram realizados outros estudos, como a simulação da mancha de inundação do Ribeirão dos Padilhas para a chuva com tempo de retorno de 100 anos (RODRIGUES & MOURA, 2021), que obteve como resultado 489 lotes afetados, com estimativas de perdas econômicas em mais de 22 milhões de reais (Figura 8).

Em relação ao uso e ocupação do solo, o trabalho de Rodrigues (2022) realizou a partir de imagens orbitais da bacia hidrográfica (satélite CBERS 04A do INPE) referentes ao dia 28 de fevereiro de 2022, o sensoriamento remoto e a classificação da imagem por pixels conforme o valor de refletância, o que tornou possível a elaboração do mapa de uso e ocupação do solo, para posterior avaliação do comportamento da ocupação da bacia hidrográfica.

O resultado deste trabalho ilustra-se na Figura 8 e o quantifica no Quadro 2 a seguir.


Quadro 2: Quantificação do Uso e Ocupação do Solo da Bacia Hidrográfica Ribeirão dos Padilhas

Classe	Área (Km²)	Percentual (%)
1 – Água	0,30	0,95%
2 – Urbano	20,72	65,22%
3 – Floresta	2,87	9,02%
4 – Solo Descoberto	2,46	7,75%
5 – Vegetação Rasteira	5,42	17,06%
Total	31,78	100,00%

Fonte: Rodrigues, 2022.

Portanto, a área foi escolhida por se tratar de uma bacia hidrográfica urbana, com alto índice de ocupação territorial (65,22%), com suas características físicas, econômicas e sociais previamente conhecidas, registros de inundação e ainda, outros estudos relacionados a temática.

Figura 8: Caracterização da Bacia Hidrográfica Ribeirão dos Padilhas



Fonte: ITCG, 2018; IPPUC, 2021; SUDERHSA, 2000, modificados pelo autor.

3.2 Coleta de dados

Inicialmente buscou-se nos órgãos de monitoramento, o histórico dos dados meteorológicos (principalmente pluviométricos), fluviométricos e registros de inundações. Também foram consultadas as instituições que possuem informações vetoriais e matriciais, que caracterizam o Município de Curitiba, com objetivo de criar um banco de dados para extração de conhecimento do cenário estudado. As instituições consultadas foram:

-) Prefeitura Municipal de Curitiba (PMC) – Superintendência da Guarda Municipal (Defesa Civil Municipal);
-) Instituto de Pesquisa e Planejamento Urbano de Curitiba (IPPUC);
-) Coordenadoria Estadual da Defesa Civil;
-) Instituto Água e Terra do Paraná (IAT);
-) Sistema Meteorológico do Paraná (SIMEPAR);
-) Agência Nacional de Águas e Saneamento Básico (ANA);
-) Instituto Nacional de Meteorologia (INMET);
-) Plataforma AGRITEMPO gerenciada pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA).

3.3 Preparação dos dados

Essa é a etapa que demanda maior tempo no processo de mineração. Primeiramente os dados são refinados, independentemente do procedimento de mineração, usado para avaliar a continuidade, frequência e *outliers* em termos de padronização e seleção de variáveis (Pérez et al., 2015).

Neste estudo, os dados foram organizados conforme sua periodicidade para criação de um banco de dados. Entretanto, devido à ausência de dados georreferenciados, são utilizados os dados obtidos junto aos órgãos que permitissem a organização em planilha eletrônica com registros diários.

3.4 Caracterização das Variáveis

3.4.1 Dados da Defesa Civil

A Defesa Civil Estadual disponibiliza as áreas sujeitas a inundação para o Município de Curitiba. Ao realizar o recorte para área de estudo, foi identificado que 4,71 Km² da área da bacia foi classificado como sujeita à inundação, o que representa aproximadamente 15% da extensão territorial. Entretanto, a Defesa Civil Estadual não disponibilizou os critérios utilizados para diagnosticar as áreas sujeitas a inundação.

Em busca das ocorrências das inundações, foi consultada a Defesa Civil Municipal, a qual é vinculada a Guarda Municipal, que disponibilizou os casos registrados de inundação no Município de Curitiba no horizonte dos últimos 11 anos (01/12/2011 à 01/12/2021). Em todo o Município foram registradas 979 ocorrências de inundações, sendo desses 89 casos na Bacia Hidrográfica Ribeirão dos Padilhas (Quadro 3).


Quadro 3: Registros de Inundação em Curitiba conforme a Bacia Hidrográfica

Bacia Hidrográfica	Número de registros
Ribeirão dos Padilhas	89
Rio Atuba-Bacacheri	196
Rio Barigui	349
Rio Belém	256
Rio Iguaçu	72
Rio Passaúna	17

Fonte: PMC, 2021, modificados pelo autor.

Os dados foram planilhados com os endereços onde ocorreram os eventos e especializados (Figura 9). Cabe destacar, que apesar da grande quantidade de ocorrências, diversas delas aconteceram no mesmo dia.

Figura 9: Registros de inundação em Curitiba e na bacia hidrográfica Ribeirão dos Padilhas



Fonte: ITCG, 2018; IPPUC, 2021; SUDERHSA, 2000; PMC, 2022, modificados pelo autor.

3.4.2 Dados Meteorológicos

A classificação climática mais conhecida e utilizada foi desenvolvida pelo pesquisador Wladimir Köppen (1948), a qual se baseia na correlação entre clima e vegetação sendo expressa por letras correspondentes a determinado clima. O Município de Curitiba, e consequentemente a bacia hidrográfica em estudo, encontra-se na seguinte classificação climática:

) **Cfb:** Clima temperado, com verão ameno. Chuvas uniformemente distribuídas, sem estação seca e a temperatura média do mês mais quente não chega a 22°C. A Precipitação varia de 1.100 a 2.000 mm. As geadas severas e frequentes, num período médio de ocorrência de 10 a 25 dias anualmente.

Para obtenção dos dados meteorológicos, foram consultados os diversos órgãos de monitoramento, apesar da existência de diversas estações de monitoramento no Município de Curitiba e região metropolitana, as mesmas apresentaram ausência de dados que incompatibilizam o uso no período em estudo.

A estação que apresentou a melhor consistência de dados, ao considerar a inexistência de ausência de informações e com o maior número de variáveis monitoradas, foi Estação do SIMEPAR (Coordenadas: Latitude -25.4486111 e Longitude -49.23055554), localizada próxima a região central do Município de Curitiba, a aproximadamente 8 km da nascente do Ribeirão dos Padilhas. Os dados fornecidos foram organizados em planilha eletrônica, de forma crescente conforme seu registro diário.

3.4.3 Definição das Variáveis

Na preparação dos dados, foram observadas situações que poderiam influenciar no modelo de maneira negativa, como a ausência em alguns casos do endereço exato da ocorrência da inundação, o que interfere em características físicas e econômicas, como declividade, tipo do solo, uso do solo, tipologia do loteamento, entre outras. Por esse motivo, as inundações foram divididas por ocorrência conforme as bacias hidrográficas, em busca de minimizar a ausência da precisão desses dados.

Também foram realizadas tentativas em relação ao cálculo das vazões do Ribeirão dos Padilhas. Entretanto, não foram encontrados dados disponíveis de estações fluviométricas do corpo hídrico em estudo ou em bacias hidrográficas a jusante, que pudessem ser utilizados para calibrar o modelo de chuva vazão por exemplo.

Deste modo, tendo em vista a ausência de dados que permitam o uso de outras variáveis, foram definidas para o presente estudo as variáveis meteorológicas e os registros de inundação, e foram criadas ainda outras variáveis a partir desses registros, conforme detalhadas no Quadro 4.

Quadro 4: Variáveis Aplicadas

Nº da Variável	Variável	Unidade de Medida	Fonte
01	Precipitação diária	mm/dia	SIMEPAR
02	Precipitação acumulada 2 dias	mm/dia	Adaptada de SIMEPAR
03	Precipitação acumulada 3 dias	mm/dia	Adaptada de SIMEPAR
04	Precipitação acumulada 4 dias	mm/dia	Adaptada de SIMEPAR
05	Precipitação acumulada 5 dias	mm/dia	Adaptada de SIMEPAR
06	Precipitação acumulada 6 dias	mm/dia	Adaptada de SIMEPAR
07	Precipitação acumulada 7 dias	mm/dia	Adaptada de SIMEPAR
08	Pressão atmosférica média diária	hectopascal – hPa	SIMEPAR
09	Temperatura máxima	°C	SIMEPAR
10	Temperatura mínima	°C	SIMEPAR
11	Temperatura média	°C	SIMEPAR
12	Variação da temperatura	°C	Adaptada de SIMEPAR
13	Média diária da umidade relativa do ar	%	SIMEPAR
14	Velocidade máxima da rajada do vento	m/s	SIMEPAR
15	Velocidade média diária do vento	m/s	SIMEPAR
16	Variação da velocidade média diária do vento com o dia anterior	m/s	Adaptada de SIMEPAR
17	Dias de estiagem	dia	Adaptada de SIMEPAR
18	Dias com chuva	dia	Adaptada de SIMEPAR
19	Casos de inundação em Curitiba	número	PMC
20	Inundação em Curitiba	sim ou não	Adaptada de PMC
21	Inundação na Bacia Rio Atuba-Bacacheri	sim ou não	Adaptada de PMC
22	Inundação na Bacia Rio Belém	sim ou não	Adaptada de PMC
23	Inundação na Bacia Rio Barigui	sim ou não	Adaptada de PMC
24	Inundação na Bacia Rio Passaúna	sim ou não	Adaptada de PMC
25	Inundação na Bacia Rio Iguaçu	sim ou não	Adaptada de PMC
26	Inundação na Bacia Ribeirão dos Padilhas	sim ou não	Adaptada de PMC

Fonte: SIMEPAR, 2022; PMC, 2021; modificados pelo autor.

Essas variáveis formam um banco de dados composto por 3.648 linhas e 26 colunas, o que totalizou 94.822 registros diários das condições meteorológicas e registros da ocorrência de inundações, sem ausência de informações no período definido para este estudo. Ainda, para posterior aplicação no software da modelagem para previsão do próximo dia, gerou-se uma segunda base de dados com a última

coluna repetida para saída do modelo, o que ocasiona 27 colunas, totalizando 98.469 registros diários.

3.5 Análise Multivariada

Para encontrar correlações relevantes entre as variáveis, foram aplicadas quatro técnicas de mineração de dados, sendo duas estatísticas (correlação linear e análise fatorial) e duas de agrupamento de dados ou *clustering* (*k-means* e dendograma). Para isso, as variáveis são inseridas no *software Statistica*, desenvolvido pela *StatSoft*.

A primeira técnica aplicada é a correlação linear, onde o coeficiente próximo de +1 ou -1 representa uma correlação linear positiva ou negativa perfeita. Destaca-se que a diagonal principal, apresenta valores iguais a 1, pois a correlação linear de uma variável com ela mesma é perfeita. Ainda, o coeficiente próximo a 0, representa a inexistência da correlação.

Outra técnica estatística aplicada, é a carga fatorial pode ser definida como a correlação da variável com o fator. Os fatores representam as dimensões latentes (construtos) que resumem o conjunto original de variáveis, mantendo a representatividade das características das variáveis. Se essa carga assume um valor positivo, significa que a variável está positivamente correlacionada com o fator, ou, se assume valor negativo, essa correlação é negativa.

Para o agrupamento das variáveis, são aplicadas duas técnicas para encontrar relações entre as mesmas. A primeira técnica *k-means*, usa um algoritmo simples para dividir os objetos em grupos de modo que a soma das distâncias do centro de um grupo a cada objeto no grupo seja tão pequena quanto que possível. São considerados quatro clusters para classificação da distância e observações em intervalos constantes.

A outra técnica de agrupamento, é do dendograma a qual apresenta um gráfico em formato de árvore, onde agrupa objetos semelhantes com base na distância matemática entre as variáveis em estudo, nesse caso a Distância Euclidiana.

3.6 Modelagem

Para previsão de inundação urbana, são utilizados dois métodos, o primeiro deles por regras de classificação através do *software Classification Based on Associations* (CBA), e na sequência com o uso de Redes Neurais Artificiais (RNA) com o uso do *software Statistica Neural Networks* (SNN).

3.6.1 Classification Based on Associations (CBA)

Os modelos preditivos são construídos com o uso de regras de classificação. No primeiro momento, o algoritmo percorre todo o conjunto de dados em busca de encontrar um conjunto de regras de forte suporte (união entre variáveis de entrada e saída). Na segunda etapa (validação do modelo), o algoritmo aplica o conjunto de regras para prever os casos de inundação.

O resultado da validação do classificador é apresentado em uma matriz de confusão, onde a diagonal principal mostra a classificação correta e a classificação incorreta é mostrado fora dessa diagonal. A acurácia do modelo (taxa de classificação correta) é a soma do amostras classificadas corretamente dividido pelo número total de amostras na validação (SOUZA, 2019).

O *software Classification Based on Associations* (CBA) da *School of Computing, National University of Singapore* (Liu et al., 1998), que tem a capacidade de produzir um classificador para explorar e prever através de regras de associação geradas entre os itens em um banco de dados.

Em busca de encontrar a melhor acurácia, foram utilizadas quatro combinações dentro do próprio *software* em relação a poda de regras (aquelas que são descartadas porque não melhoram a acurácia do classificador) e o uso ou não de regras pequenas (aquelas que consideram apenas uma variável).

3.6.2 Redes Neurais Artificiais (RNA)

Em sequência, para comparação ao modelo de previsão, é aplicado o modelo de Redes Neurais Artificiais (RNA), através do *software Statistica Neural Networks*

(SNN), que é um programa capaz de desenvolver modelos com RNA para a previsão de dados numéricos e de classificação, com base em suas séries históricas.

O *software STATISTICA Neural Network* (SNN) utiliza três diferentes metodologias, e escolhe o modelo de RNA com melhor desempenho. Destaca-se as classes de RNA:

-) *Multilayer Perceptron* (MLP) consiste basicamente em uma camada de entrada composta por nós de entrada, uma ou mais camadas ocultas e uma camada de saída composta por nós computacionais;
-) *Radial Basis Function* (RBF) tem a ideia fundamental da função da base radial é que o valor de destino previsto de um item provavelmente será o mesmo de outros itens com valores próximos de variáveis preditoras;
-) *Probabilistic Neural Network* (PNN) é um tipo de rede neural *feedforward* usada para lidar com problemas de classificação e reconhecimento de padrões. Na técnica PNN, a função de distribuição de probabilidade de cada classe é aproximada usando uma janela de *Parzen* e uma função não paramétrica. Então a probabilidade de cada classe é utilizada para estimar a probabilidade de classe de novos dados de entrada.

Para executar a modelagem, o programa permite a divisão das amostras em três grupos, sendo amostras de treino, verificação e teste. Nas amostras destinadas a treino, o *software* busca padrões e relações entre os dados. Já nas amostras de verificação, são aplicados os padrões e relações encontrados anteriormente para determinar erros e acertos do modelo. Nas amostras de teste, são verificadas as diferenças entre os padrões e relações encontradas, e ainda, os erros e acertos do modelo nas amostras restantes.

3.6.3 Acurácia e Precisão

A avaliação da acurácia e precisão dos modelos é calculada a partir das seguintes equações:

$$A \quad \acute{a}c \acute{i} = \left\{ \left(\frac{t_p}{p} \right) \times \left(\frac{p}{p + n} \right) \right\} + \left\{ \left(\frac{t_n}{n} \right) \times \left(\frac{n}{p + n} \right) \right\}$$

$$P_{\text{acerto}} = \left(\frac{t_p}{t_p + f_p} \right) o \left(\frac{t_n}{t_n + f_n} \right)$$

Onde:

t_p : amostras positivas classificadas como positivas;

p : amostras positivas;

t_n : amostras negativas classificadas como negativas;

n : amostras negativas

f_p : amostras negativas classificadas como positivas;

f_n : amostras positivas classificadas como negativas.

Cabe ressaltar que para cada modelo as equações são aplicadas em diferentes quantitativos amostrais. Para o modelo de previsão através das regras de associação por meio do CBA, as amostras de acerto e erro são calculadas a partir do total de registros do banco de dados. Já o modelo de previsão com o uso das redes neurais, utiliza as amostras de acerto e erro apenas da etapa de verificação.

4 RESULTADOS

Os resultados da pesquisa são discutidos em três domínios, com início pela aplicação das quatro técnicas de mineração de dados para análise multivariada (1). Em seguida, é realizado a previsão de inundação na área de estudo com o uso de duas técnicas de *machine learning* (2). Por fim, é discutido a aplicabilidade destas ferramentas e contribuições para a temática do planejamento urbano (3).

4.1 Análise Multivariada

A análise multivariada é realizada pelo *software Stastisc*, onde as variáveis foram inseridas em busca de identificar relação entre as mesmas. Para isso, foram aplicadas as quatro técnicas de mineração de dados, os quais os resultados são apresentados a seguir.

A primeira técnica aplicada foi a correlação linear (Quadro 5), onde para facilitar a visualização e posterior análise, se encontram destacados em verde os valores próximos de +1, em amarelo os valores próximos a 0, e em vermelho os valores próximos de -1.

Quadro 5: Coeficientes de relação linear

Var.	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26
1	1,00	0,77	0,63	0,54	0,49	0,45	0,42	-0,23	-0,05	0,16	0,02	-0,22	0,33	0,22	0,01	0,05	-0,24	0,31	0,52	0,52	0,47	0,45	0,45	0,19	0,30	0,30
2	0,77	1,00	0,86	0,75	0,67	0,62	0,57	-0,24	-0,10	0,15	-0,01	-0,29	0,36	0,16	0,01	0,05	-0,29	0,41	0,42	0,47	0,38	0,38	0,38	0,19	0,31	0,27
3	0,63	0,86	1,00	0,90	0,81	0,75	0,69	-0,22	-0,12	0,14	-0,02	-0,30	0,35	0,14	0,02	0,08	-0,32	0,45	0,34	0,40	0,30	0,31	0,33	0,17	0,27	0,22
4	0,54	0,75	0,90	1,00	0,93	0,85	0,79	-0,20	-0,12	0,13	-0,03	-0,30	0,33	0,13	0,04	0,08	-0,34	0,46	0,29	0,36	0,26	0,26	0,30	0,14	0,24	0,19
5	0,49	0,67	0,81	0,93	1,00	0,94	0,88	-0,17	-0,12	0,12	-0,04	-0,29	0,32	0,12	0,05	0,08	-0,35	0,46	0,25	0,34	0,24	0,24	0,28	0,15	0,21	0,17
6	0,45	0,62	0,75	0,85	0,94	1,00	0,95	-0,16	-0,11	0,12	-0,03	-0,27	0,30	0,10	0,04	0,08	-0,36	0,45	0,24	0,32	0,23	0,23	0,26	0,14	0,21	0,17
7	0,42	0,57	0,69	0,79	0,88	0,95	1,00	-0,16	-0,10	0,13	-0,02	-0,26	0,29	0,09	0,02	0,06	-0,36	0,43	0,23	0,30	0,22	0,20	0,24	0,13	0,19	0,15
8	-0,23	-0,24	-0,22	-0,20	-0,17	-0,16	-0,16	1,00	-0,48	-0,57	-0,57	-0,06	0,11	-0,40	-0,25	-0,12	0,29	-0,24	-0,09	-0,16	-0,11	-0,11	-0,09	-0,06	-0,06	-0,08
9	-0,05	-0,10	-0,12	-0,12	-0,12	-0,11	-0,10	-0,48	1,00	0,67	0,92	0,66	-0,49	0,25	-0,03	-0,10	0,09	-0,02	0,06	0,08	0,06	0,06	0,06	0,01	0,02	0,04
10	0,16	0,15	0,14	0,13	0,12	0,12	0,13	-0,57	0,67	1,00	0,86	-0,11	0,02	0,26	0,13	-0,10	-0,20	0,26	0,09	0,15	0,11	0,09	0,13	0,03	0,06	0,07
11	0,02	-0,01	-0,02	-0,03	-0,04	-0,03	-0,02	-0,57	0,92	0,86	1,00	0,36	-0,31	0,27	0,05	-0,11	-0,02	0,09	0,07	0,10	0,07	0,07	0,08	0,02	0,04	0,06
12	-0,22	-0,29	-0,30	-0,30	-0,29	-0,27	-0,26	-0,06	0,66	-0,11	0,36	1,00	-0,69	0,07	-0,17	-0,03	0,33	-0,29	-0,02	-0,05	-0,03	-0,02	-0,05	-0,01	-0,04	-0,01
13	0,33	0,36	0,35	0,33	0,32	0,30	0,29	0,11	-0,49	0,02	-0,31	-0,69	1,00	-0,19	-0,08	-0,10	-0,34	0,32	0,08	0,15	0,10	0,09	0,12	0,03	0,08	0,07
14	0,22	0,16	0,14	0,13	0,12	0,10	0,09	-0,40	0,25	0,26	0,27	0,07	-0,19	1,00	0,61	0,20	-0,13	0,16	0,11	0,15	0,08	0,13	0,11	0,03	0,07	0,10
15	0,01	0,01	0,02	0,04	0,05	0,04	0,02	-0,25	-0,03	0,13	0,05	-0,17	-0,08	0,61	1,00	0,26	-0,12	0,06	-0,03	-0,01	-0,03	0,01	-0,02	0,00	-0,03	-0,01
16	0,05	0,05	0,08	0,08	0,08	0,08	0,06	-0,12	-0,10	-0,10	-0,11	-0,03	-0,10	0,20	0,26	1,00	-0,08	0,05	0,00	0,01	0,00	0,02	-0,01	0,01	0,01	0,03
17	-0,24	-0,29	-0,32	-0,34	-0,35	-0,36	-0,36	0,29	0,09	-0,20	-0,02	0,33	-0,34	-0,13	-0,12	-0,08	1,00	-0,35	-0,08	-0,15	-0,09	-0,10	-0,11	-0,04	-0,06	-0,07
18	0,31	0,41	0,45	0,46	0,46	0,45	0,43	-0,24	-0,02	0,26	0,09	-0,29	0,32	0,16	0,06	0,05	-0,35	1,00	0,11	0,21	0,10	0,12	0,16	0,05	0,10	0,11
19	0,52	0,42	0,34	0,29	0,25	0,24	0,23	-0,09	0,06	0,09	0,07	-0,02	0,08	0,11	-0,03	0,00	-0,08	0,11	1,00	0,49	0,52	0,53	0,50	0,25	0,38	0,45
20	0,52	0,47	0,40	0,36	0,34	0,32	0,30	-0,16	0,08	0,15	0,10	-0,05	0,15	0,15	-0,01	0,01	-0,15	0,21	0,49	1,00	0,59	0,64	0,67	0,25	0,39	0,44
21	0,47	0,38	0,30	0,26	0,24	0,23	0,22	-0,11	0,06	0,11	0,07	-0,03	0,10	0,08	-0,03	0,00	-0,09	0,10	0,52	0,59	1,00	0,38	0,37	0,18	0,24	0,25
22	0,45	0,38	0,31	0,26	0,24	0,23	0,20	-0,11	0,06	0,09	0,07	-0,02	0,09	0,13	0,01	0,02	-0,10	0,12	0,53	0,64	0,38	1,00	0,34	0,14	0,30	0,30
23	0,45	0,38	0,33	0,30	0,28	0,26	0,24	-0,09	0,06	0,13	0,08	-0,05	0,12	0,11	-0,02	-0,01	-0,11	0,16	0,50	0,67	0,37	0,34	1,00	0,18	0,26	0,24
24	0,19	0,19	0,17	0,14	0,15	0,14	0,13	-0,06	0,01	0,03	0,02	-0,01	0,03	0,03	0,00	0,01	-0,04	0,05	0,25	0,25	0,18	0,14	0,18	1,00	0,16	0,10
25	0,30	0,31	0,27	0,24	0,21	0,21	0,19	-0,06	0,02	0,06	0,04	-0,04	0,08	0,07	-0,03	0,01	-0,06	0,10	0,38	0,39	0,24	0,30	0,26	0,16	1,00	0,34
26	0,30	0,27	0,22	0,19	0,17	0,17	0,15	-0,08	0,04	0,07	0,06	-0,01	0,07	0,10	-0,01	0,03	-0,07	0,11	0,45	0,44	0,25	0,30	0,24	0,10	0,34	1,00

Obs.: Numeração das variáveis encontra-se apresentada no Quadro 4.

Fonte: O autor.

De acordo com a matriz de correlação linear, pode-se observar que as variáveis de número de casos de inundação em Curitiba (19) e ocorrências de inundação em Curitiba (20) possuem uma relação linear baixa de 0,52 com a variável de precipitação (1). Também cabe destacar, a correlação inversa considerável de -0,69 apresentada entre as variáveis meteorológicas de variação da temperatura (12) e média diária da umidade relativa do ar (13).

As variáveis foram divididas em quatro fatores e destacadas em verde nos valores próximos de +1, em amarelo os valores próximo a 0, e em vermelho os valores próximos de -1 (Quadro 6). Pode-se observar que os resultados são baixos, com destaque para o maior valor de velocidade média diária do vento no fator 04.

Quadro 6: Coeficientes de carga fatorial

Nº da Variável	Variável	Fator 01	Fator 02	Fator 03	Fator 04
01	Precipitação diária	-0,0998	-0,0171	-0,0772	0,0512
02	Precipitação acumulada 2 dias	-0,1124	0,0137	-0,0053	-0,0128
03	Precipitação acumulada 3 dias	-0,1148	0,0326	0,0542	-0,0549
04	Precipitação acumulada 4 dias	-0,1139	0,0435	0,0900	-0,0831
05	Precipitação acumulada 5 dias	-0,1114	0,0477	0,1050	-0,0960
06	Precipitação acumulada 6 dias	-0,1076	0,0476	0,1095	-0,1074
07	Precipitação acumulada 7 dias	-0,1025	0,0447	0,1106	-0,1175
08	Pressão atmosférica média diária	0,0388	0,1648	-0,1499	-0,0797
09	Temperatura máxima	0,0101	-0,2515	0,0496	-0,1648
10	Temperatura mínima	-0,0328	-0,1848	0,1452	-0,0871
11	Temperatura média	-0,0062	-0,2429	0,0995	-0,1407
12	Variação da temperatura	0,0468	-0,1497	-0,0807	-0,1326
13	Média diária da umidade relativa do ar	-0,0549	0,1427	0,0240	-0,0221
14	Velocidade máxima da rajada do vento	-0,0290	-0,1187	0,0965	0,3641
15	Velocidade média diária do vento	-0,0093	-0,0412	0,1242	0,4518
16	Var. da vel. do vento com o dia anterior	-0,0105	0,0084	0,0470	0,3131
17	Dias de estiagem	0,0569	-0,0196	-0,1312	-0,0727
18	Dias com chuva	-0,0701	0,0065	0,1286	-0,0201
19	Casos de inundação em Curitiba	-0,0710	-0,0580	-0,2059	0,0489
20	Inundação em Curitiba	-0,0838	-0,0672	-0,1884	0,0487
21	Inundação na Bacia Rio Atuba-Bac.	-0,0641	-0,0524	-0,1677	0,0263
22	Inundação na Bacia Rio Belém	-0,0651	-0,0558	-0,1707	0,0676
23	Inundação na Bacia Rio Barigui	-0,0681	-0,0509	-0,1540	0,0231
24	Inundação na Bacia Rio Passaúna	-0,0330	-0,0220	-0,0820	0,0115
25	Inundação na Bacia Rio Iguaçu	-0,0524	-0,0316	-0,1334	0,0233
26	Inundação na Bacia R. dos Padilhas	-0,0495	-0,0452	-0,1458	0,0564

Fonte: O autor.

O Quadro 7 apresenta a divisão das variáveis por *cluster* e a distância entre as variáveis.

Quadro 7: Método *k-means*


Cluster 01		Cluster 04	
Variável	Distância	Variável	Distância
Média diária da umidade relativa do ar	0,00	Precipitação diária	8,871
		PP 2 dias	14,486
		Temperatura máxima	19,568
		Temperatura mínima	9,920
		Temperatura média	13,438
		Variação da temperatura	6,108
		Velocidade máxima da rajada do vento	4,183
		Velocidade média diária do vento	3,250
		Variação vel. do vento com o dia anterior	4,680
		Dias de estiagem	5,241
		Dias com chuva	4,239
		Casos de inundação em Curitiba	4,948
		Inundação em Curitiba	5,006
		Inundação na Bacia Rio Atuba-Bacacheri	5,060
		Inundação na Bacia Rio Belém	5,055
		Inundação na Bacia Rio Barigui	5,050
		Inundação na Bacia Rio Passaúna	5,093
		Inundação na Bacia Rio Iguaçu	5,082
		Inundação na Bacia R. dos Padilhas	5,078

Fonte: O autor.

Pode-se observar na Figura 10 que as variáveis de pressão atmosférica e média diária da umidade relativa do ar, assim como no método *k-means*, foram inicialmente separadas das demais, o que demonstra a baixa correlação.


Em relação a Figura 11, apresenta-se o recorte do galho da variável em estudo, onde o resultado foi o esperado, já que os casos de inundação em Curitiba e nas bacias hidrográficas possuem forte correlação. Cabe destacar, a proximidade com a variável de variação da velocidade do vento com o dia anterior.

Figura 10: Dendrograma (Distância Euclidiana)



Fonte: O autor.

Figura 11: Dendrograma (Distância Euclidiana) – Recorte da variável em estudo.



Fonte: O autor.

4.2 Previsão de Inundação

Os resultados para os modelos de previsão de inundação através das regras de classificação com o uso do *software Classification Based on Associations (CBA)*, e na sequência com o uso de Redes Neurais Artificiais (RNA) com a aplicação do *software Statistica Neural Networks (SNN)* são apresentados a seguir.

4.2.1 *Classification Based on Associations (CBA)*

As 26 variáveis apresentadas no Quadro 4, foram inseridas no *software CBA* para realizar o processo de regras de classificação. Foram realizados dois modelos, sendo para ocorrência de inundação no dia (t_0) e para o próximo dia (t_1). Em busca de encontrar a melhor acurácia, foram utilizadas quatro combinações dentro do próprio *software* em relação a poda de regras e o uso ou não de regras pequenas. O Quadro 8, apresenta a matriz de confusão para previsão (t_0).

Quadro 8: Matriz da confusão das combinações para a previsão de inundação (t_0)

	Com poda de regras e não usar regras pequenas		Com poda de regras e usar regras pequenas		Sem poda de regras e usar regras pequenas		Sem poda de regras e não usar regras pequenas	
Ocorreu inundação?	Não	Sim	Não	Sim	Não	Sim	Não	Sim
Amostras	3574	24	3592	6	3596	2	3575	23
	2	47	4	45	2	47	1	48
Acurácia	99,29%		99,73%		99,89%		99,34%	
Precisão	99,94%		99,89%		99,94%		99,97%	
Nº de Regras	63		82		101		71	

Fonte: O autor.

Observa-se que a opção de sem poda de regras e usar regras pequenas apresentou melhor acurácia e precisão, e ainda gerou o maior número de regras. Nesta opção, a matriz de confusão (Quadro 8) de apresentou a previsão incorreta 2 vezes em situações em 49 que as inundações ocorreram, mas o *software* previu que não, e ainda 2 vezes em situações em 3.598 que as inundações não ocorreram, mas o *software* previu que sim. Desta forma com o uso das equações apresentadas anteriormente, o modelo obteve a acurácia de 99,89% e a precisão de 99,94%.

Portanto, será a opção utilizada para realizar a previsão de inundação no dia (t_0). Em relação às 101 regras de classificação geradas, 84 são para quando não irá

ocorrer inundações e 17 são para quando irá ocorrer. Destacam-se a seguir, três exemplos das regras de alto suporte e nível de confiança:

Regra 01: $\text{Inun_Iguacu_} > _ \text{NO} = \text{Y}$; $\text{Inun_Atuba_} > _ \text{NO} = \text{Y}$; $\text{TVAR_} > _ 11 = \text{Y}$; $\text{VEL_Vet_} < _ 1_75 = \text{Y}$; $\rightarrow \text{Class} = \text{Inun_Padilha_} > _ \text{NO}$

(14.807% 100.000% 540 540 14.807%)

Para essa regra em específico, o suporte de 14,807% foi calculado pela divisão de 540 vezes pelo total de valores da amostra em que ocorreu a condicionante da fórmula (ou seja, 540 vezes em 3646 registros). Para a confiança de 100%, observa-se que das 540 vezes que ocorreram essas condições no banco de dados, nas mesmas 540 não ocorreram inundações.

Portanto, essa regra implica que quando não houverem registros de inundação na bacia do rio Iguaçu (Inun_Iguacu), não houverem registros de inundação na bacia do rio Atuba-Bacacheri (Inun_Atuba), a variação da temperatura diária (TVAR) for maior que 11°C e a velocidade média diária do vento (VEL_Vet) for menor que 1,75 m/s, não irá ocorrer inundação na bacia hidrográfica Ribeirão dos Padilhas.

Regra 02: $\text{Inun_Passauna_} > _ \text{NO} = \text{Y}$; $\text{Inun_belem_} > _ \text{NO} = \text{Y}$; $16_ < _ \text{TMD_} < _ 20 = \text{Y}$; $\text{VEL_Vet_} > _ 2_20 = \text{Y}$; $\rightarrow \text{Class} = \text{Inun_Padilha_} > _ \text{NO}$

(12.120% 100.000% 442 442 12.120%)

Da mesma maneira, essa regra determina que quando não houverem registros de inundação na bacia do rio Passaúna (Inun_Passauna), não houverem registros de inundação na bacia do rio Belém (Inun_belem), a Temperatura Média Diária (TMD) for entre 16 e 20°C e a velocidade média diária do vento (VEL_Vet) for maior que 2,20 m/s, não irá ocorrer inundação na área de estudo.

Regra 03: $\text{Inun_barigui_} > _ \text{NO} = \text{Y}$; $16_ < _ \text{TMD_} < _ 20 = \text{Y}$; $\text{TVAR_} > _ 11 = \text{Y}$; $\rightarrow \text{Class} = \text{Inun_Padilha_} > _ \text{NO}$;

(13.491% 100.000% 492 492 13.491%)

Essa regra resulta que quando não houverem registros de inundação na bacia do rio Barigui (Inun_barigui), a Temperatura Média Diária (TMD) for entre 16 e 20°C e a variação da temperatura diária (TVAR) for maior que 11°C, não irá ocorrer inundação na bacia Ribeirão dos Padilhas.

O mesmo procedimento foi realizado para previsão de inundação para próximo dia (t_1). O Quadro 9, apresenta a matriz de confusão para previsão (t_1).

Quadro 9: Matriz da confusão das combinações para a previsão de inundação (t_1)

	Com poda de regras e não usar pequenas regras		Com poda de regras e usar pequenas regras		Sem poda de regras e usar regras pequenas		Sem poda de regras e não usar regras pequenas	
Ocorreu inundação?	Não	Sim	Não	Sim	Não	Sim	Não	Sim
Amostras	3597	0	3583	14	3594	3	3597	0
	49	0	25	24	11	38	49	0
Acurácia	98,66%		98,93%		99,62%		98,66%	
Precisão	98,66%		99,31%		99,69%		98,66%	
Nº de Regras	127		173		245		176	

Fonte: O autor.

Observa-se que a opção de sem poda de regras e usar regras pequenas apresentou melhor acurácia e precisão, e ainda gerou o maior número de regras. Nesta opção, a matriz de confusão (Quadro 9) de apresentou a previsão incorreta 11 vezes em situações em 38 que as inundações ocorreram, mas o software previu que não, e ainda 3 vezes em 3.594 situações em que as inundações não ocorreram, mas o software previu que sim. Desta forma com o uso das equações apresentadas anteriormente, o modelo obteve a acurácia de 99,62% e a precisão de 99,69%.

Portanto, da mesma maneira que utilizada para previsão no dia (t_0), será a opção para realizar a previsão de inundação no dia (t_1). Em relação às 245 regras de classificação geradas, 221 são para quando não irá ocorrer inundações e 24 são para quando irá ocorrer. Destacam-se a seguir, três exemplos das regras de alto suporte e nível de confiança:

Regra 01: Inun_barigui_>_NO = Y; 22_<_TMAX_<_26_5 = Y; VENT_<_7 = Y; -> Class = Prev_inund_>_NO;

(11.492% 100.000% 419 419 11.492%)

Essa regra resulta que quando não houverem registros de inundação na bacia do rio Barigui (Inun_barigui), a Temperatura Máxima Diária (TMAX) for entre 22 e 26,5°C e a Velocidade máxima da rajada do vento (VENT) for menor que 7 m/s, não irá ocorrer inundação na bacia Ribeirão dos Padilhas.

Regra 02: Inun_Iguacu_>_NO = Y; 22_<_TMAX_<_26_5 = Y; 2_5_<_PP5_<_20 = Y; -> Class = Prev_inund_>_NO;

(11.327% 100.000% 413 413 11.327%)

Essa regra implica que quando não existirem registros de inundação na bacia do rio Iguaçu (Inun_Iguacu), a Temperatura Máxima Diária (TMAX) for entre 22 e

26,5°C e a Precipitação Acumulada nos últimos 5 dias (PP5) for entre 2,5 e 20 mm, não irá ocorrer inundação na bacia hidrográfica Ribeirão dos Padilhas.

Regra 03: $\text{Inun_barigui_} > _ \text{NO} = Y$; $22 < _ \text{TMAX_} < _ 26_5 = Y$; $\text{VEL_Ant_} < _ 0_2 = Y$; $\rightarrow \text{Class} = \text{Prev_inund_} > _ \text{NO}$;

(10.724% 100.000% 391 391 10.724%)

Essa regra resulta que quando não existirem registros de inundação na bacia do rio Barigui (Inun_barigui), a Temperatura Máxima Diária (TMAX) for entre 22 e 26,5°C e Variação da velocidade média diária do vento com o dia anterior (VEL_Ant) for menor que 0,2 m/s, não irá ocorrer inundação na bacia Ribeirão dos Padilhas.

Como pode-se observar, os modelos estabeleceram regras consistentes com êxito para previsão de ocorrência e não ocorrência de inundação na bacia Hidrográfica Ribeirão dos Padilhas em ambos os períodos (t_0 e t_1). Ou seja, um modelo de previsão de inundação em relação aos dados meteorológicos, ou ainda, um modelo chuva *versus* inundação.

Essas regras podem ser adicionadas e aplicadas no sistema de alerta da defesa civil municipal, contribuindo para efetividade das situações de mobilização das equipes de resgate e de atenção ou remoção da população ribeirinha.

4.2.2 Redes Neurais Artificiais (RNA)

Para a aplicação da modelagem por Redes Neurais Artificiais (RNA), utilizou-se o *software Statistica Neural Networks* (SNN), onde foram utilizadas apenas as variáveis meteorológicas e a ocorrência de casos de inundação na bacia hidrográfica Ribeirão dos Padilhas (variáveis numeradas de 01-17; e 26, descritas no Quadro 4). As demais variáveis não puderam ser inseridas devido ao grande número de repetições dos valores 0 e 1, que faz o *software* entenda que se tratam de variáveis categóricas, e o mesmo as ignora.

Para esse modelo, buscou-se a previsão da ocorrência de inundação para o próximo dia (t_1). Na execução do *software*, o modelo possibilita que o usuário determine a quantidade de amostras para treinamento, verificação e teste. Em busca de encontrar a melhor acurácia possível, foram testadas três situações distintas em relação a divisão do número de amostras de entrada para o modelo (Quadro 10).


Quadro 10: Divisão das amostras de entrada no *software* SNN

Situação	Nº de Amostras Treino	%	Nº de amostras de Verificação	%	Nº de amostras de Teste	%
01	2550	70%	548	15%	548	15%
02	2186	60%	730	20%	730	20%
03	1823	50%	912	25%	911	25%

Fonte: O autor.

O melhor desempenho foi obtido com os resultados obtidos com a RNA do tipo *Multilayer Perceptron* (MLP). Portanto, os resultados foram obtidos com uma RNA do tipo MLP com 16 camadas e 19 neurônios na camada oculta (Figura 12).

Figura 12: RNA do tipo MLP



Fonte: O autor.

No Quadro 11 ao Quadro 13, apresentam-se a matriz de confusão das 3 situações realizadas.

Quadro 11: Matriz de confusão situação 01

	Treinamento		Verificação		Teste	
Ocorreu inundação?	Não	Sim	Não	Sim	Não	Sim
Nº Total de Amostras	2520	30	539	9	538	10
Amostras que acertou	1696	21	327	5	327	6
Amostras que errou	824	9	212	4	211	4

Fonte: O autor.

Quadro 12: Matriz de confusão situação 02

	Treinamento		Verificação		Teste	
Ocorreu inundação?	Não	Sim	Não	Sim	Não	Sim
Nº Total de Amostras	2160	26	717	13	720	10
Amostras que acertou	1517	19	469	7	479	7
Amostras que errou	643	7	248	6	241	3

Fonte: O autor.

Quadro 13: Matriz de confusão situação 03

	Treinamento		Verificação		Teste	
Ocorreu inundação?	Não	Sim	Não	Sim	Não	Sim
Nº Total de Amostras	1798	25	899	13	900	11
Amostras que acertou	1359	16	610	10	611	9
Amostras que errou	439	9	289	3	289	2

Fonte: O autor.

Para verificar a acurácia e precisão dos resultados, deve-se analisar a taxa de acerto das amostras de verificação (Quadro 14).

Quadro 14: Resultados de validação do *software* SNN

Situação	01		02		03	
Ocorreu inundação?	Não	Sim	Não	Sim	Não	Sim
Nº Total de Amostras	539	9	717	13	899	13
Amostras que acertou	327	5	469	7	610	10
Amostras que errou	212	4	248	6	289	3
Acurácia	60,58%		65,21%		67,98%	
Precisão	98,79%		98,74%		99,51%	

Fonte: O autor.

Pode-se observar que a situação 03, com menos amostras para treino, apresentou melhor acurácia e precisão. Justifica-se ao fato do pequeno número de amostras que ocorreram inundações (49 dias distintos no total de 3.646 dias), os quais ainda foram divididos nos três grupos de análise (treino, verificação e teste), que resultou em um baixo número de casos para validação para as situações 01 e 02.

4.3 Aplicabilidade no Planejamento Urbano

O Quadro 15 apresenta a síntese dos modelos executados para previsão de inundação na Bacia Hidrográfica Ribeirão dos Padilhas.

Quadro 15: Síntese dos resultados dos modelos

Tipo do Modelo	Previsão realizada	Acurácia	Precisão
Regras de Classificação (CBA)	Previsão no dia (t_0)	99,89%	99,94%
Regras de Classificação (CBA)	Previsão para o próximo dia (t_1)	99,62%	99,69%
Redes Neurais Artificiais (SNN)	Previsão para o próximo dia (t_1)	67,98%	99,51%

Fonte: O autor.

Os modelos do *software* CBA exibiram resultados estatísticos relevantes para previsão de inundações urbanas. O modelo com as regras de classificação para previsão de inundação no dia (t_0) apresentou uma acurácia de 99,89%. Já o modelo das regras para previsão de inundação no próximo dia (t_1) demonstraram o nível de acerto de 99,62%.

O modelo de previsão de inundação para o próximo dia (t_1) através das redes neurais artificiais (RNA) com o uso do SNN, apresentou um nível de acerto próximo de 70%. Pode-se atribuir esse índice ao fato da necessidade do modelo de dados para treinamento, verificação e teste, o que reduz o número de amostras para previsão. Cabe destacar, que possivelmente com a adição de outras variáveis seja obtida uma melhor acurácia, ainda que pese não ter sido possível utilizar todas as variáveis do banco de dados.

Ainda em relação a comparação dos modelos, cabe destacar também o tempo de processamento computacional, que para o CBA é medido em segundos, e para a RNA no SNN é medido em horas.

Apesar dos resultados distintos, os modelos do *software* CBA demonstraram a aplicabilidade das ferramentas tecnológicas para o planejamento urbano, com a utilização da base os dados primários de instituições públicas de monitoramento, o que ilustra a possibilidade de inserção dessas ferramentas na previsão e monitoramento das inundações urbanas.

No planejamento urbano, algumas ações de prevenção de desastres naturais são realizadas de forma isolada pela gestão pública, e minoritariamente na esfera digital. No Estado do Paraná, pode-se destacar o sistema de alertas para chuvas intensas, realizado pela Defesa Civil do Estado do Paraná, através do cadastro do telefone do cidadão, o qual é notificado em caso da possibilidade de chuvas torrenciais, a partir de previsões meteorológicas realizadas pelo SIMEPAR.

Entretanto, o objetivo da presente pesquisa é contribuir com o desenvolvimento de uma metodologia para um sistema de alerta com maior acurácia, a partir da utilização de outras variáveis, além de considerar apenas a previsão de precipitação diária, como são as metodologias atuais.

Apesar dos resultados encontrados apontarem que os dados meteorológicos e registros de inundações são suficientes para realizar o modelo de previsão de

inundações urbanas, vale destacar que, para aumento da acurácia do modelo e consequentemente das suas regras de previsão, são necessários ações para o aumento do monitoramento das variáveis, bem como, sua disponibilidade em precisão e qualidade das informações.

Portanto, em comparação aos estudos listados no Quadro 1, o presente trabalho obteve êxito em replicar metodologias para previsão de inundação por meio de métodos empíricos. Os demais métodos (físico e físico-numérico), não foram possíveis de serem replicados devido à ausência de dados georreferenciados, fator limitante deste estudo.

5 CONCLUSÕES E RECOMENDAÇÕES

Esta pesquisa demonstrou inicialmente a relevância dos impactos causados pelos desastres naturais, em especial as inundações urbanas, as dificuldades de gestão desses desastres com orçamento reduzido anualmente e a ocorrência dos desastres cada vez mais frequentes e severos.

Em sequência, buscou-se elucidar como as ferramentas tecnológicas estão agregando na gestão e planejamento urbano através do fomento de informações e consequentemente subsídios para a tomada de decisões dos gestores. Ilustrou-se também que, sob a ótica mundial, modelos de mapeamento das áreas de risco de inundação e outras medidas, como sistemas de alerta, estão em curso de pesquisa constantemente.

A pesquisa demonstrou que dentre os modelos existentes de modelagem (física-numérica, física e empírica), os modelos empíricos possuem grande capacidade de identificar áreas de risco de inundação e é a tipologia que necessita de menor investimento econômico. Por esse fato, está em crescente uso em pesquisas e aplicações, apesar das suas limitações, como não prever profundidade, velocidade, entre outras.

Ainda, foi realizada a análise multivariada por meio da aplicação das quatro técnicas de mineração de dados que apresentaram correlações esperadas e desconhecidas entre as variáveis, o que confirma que as inundações urbanas são fenômenos complexos e compostas por multivariáveis.

A aplicação dos modelos de regras de classificação com o CBA para previsão de inundações urbanas para o dia (t_0) e próximo dia (t_1), obtiveram êxito, uma vez que estatisticamente suas regras demonstraram níveis de suporte e confiança significativos, os quais uma vez implantados, irão contribuir para que as equipes da defesa civil não sejam mobilizadas sem necessidade, ou seja, quando irá ocorrer inundações.

O segundo modelo de previsão de inundações urbanas para o próximo dia (t_1) com o uso de Redes Neurais Artificiais (RNA), apresentou o nível de acurácia de aproximadamente 68%, o que resulta na possibilidade de agregar outras variáveis para melhorar a nível de acerto do modelo. Pode-se também atribuir ao fato de o

modelo necessitar de exemplos para treino, verificação e teste, o que divide a base de dados em três partes.

A modelagem ainda demonstrou a importância da realização do monitoramento meteorológico e do registro das ocorrências dos eventos de inundações, bem como, a relevância de informações especiais de precisão, fator preponderante para redução do uso de outras variáveis encontradas na busca de informações para composição do banco de dados do presente estudo. Isso limitou a presente pesquisa a realizar a modelagem apenas para um sistema de alerta de ocorrências de inundação.

Cabe destacar ainda, que o sistema de alerta se faz necessário para que a gestão pública possa realizar a mobilização da equipe da defesa civil, a qual notifica a população e em casos extremos, realiza remoção de pessoas para abrigos com objetivo de evitar óbitos. Portanto, quanto maior for a acurácia do sistema, menor serão as chances da mobilização da equipe da defesa civil sem eventuais ocorrências.

Isto posto, este estudo cumpriu de maneira plena seu objetivo principal, com destaque ao método de classificação que atingiu com êxito as regras para a previsão de ocorrência e não ocorrência de inundações urbanas na bacia hidrográfica estudada. Por fim, recomenda-se para a continuidade dessa linha de pesquisa:

-) Buscar informações espacializadas mais precisas a fim de incluir mais variáveis nos modelos de previsão;
-) Testar a modelagem em outras localidades que possuam maior número de variáveis espacializadas e históricos de monitoramento;
-) Considerar outros modelos de aprendizado da máquina para previsão de inundações urbanas, em especial, que resultem na identificação de áreas de risco.

6 REFERÊNCIAS

ALMEIDA, C.M. et.al.; **Geoinformação em urbanismo: cidade real x cidade virtual**. São Paulo: Oficina de Textos, 2007.

BATTY, M. Geomatics in Urban and Regional Planning – Challenges e Perspectives. IN: ALMEIDA, C.M. CÂMARA, G. MONTEIRO, A. M. V. (Orgs.) **Geoinformação em urbanismo: cidade real x cidade virtual**. São Paulo: Oficina de Textos, 2007.

BERGHUIJS, W. R., AALBERS, E. E., LARSEN J. R., TRANCOSO, R. Recent changes in extreme floods across multiple continents. **Environmental Research Letters** Volume 12. DOI: <DOI 10.1088/1748-9326/aa8847>. 2017.

BRAGA, Antônio de Pádua; CARVALHO, André Carlos Ponce de Leon Ferreira de; LUDERMIR, Teresa Bernarda. Redes Neurais Artificiais. In: REZENDE, Solange Oliveira (org.). **Sistemas Inteligentes: fundamentos e aplicações**. Barueri: Manole, 2005. P. 141-168.

BRASIL. **Estatuto da Cidade**: guia para implementação pelos municípios e cidadãos. Brasília, DF: Câmara dos Deputados, Coordenação de Publicações, 2001.

BRASIL. Ministério da Integração Nacional. **Noções Básicas em Proteção e Defesa Civil e em Gestão de Riscos**. Brasília, DF. 1º Edição. 2017.

BRASIL. **Portaria Ministério das Cidades nº 114**, de 09 de fevereiro de 2018. Disponível em: <http://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/3216370/do1-2018-02-14-portaria-n-114-de-9-de-fevereiro-2018-3216366>. Acesso em: 20 jul. 2020.

Centre for Research on the Epidemiology of Disasters (CRED); UN Office for Disaster Risk Reduction (UNISDR). **Economic Losses, Poverty & Disasters (1998-2017)**. 2018. Disponível em: <<https://www.emdat.be/publications>>. Acesso em: 27 de jul. de 2020.

CONFEDERAÇÃO NACIONAL DE MUNICÍPIOS (CNM). **Danos e prejuízos causados por desastres no Brasil entre 2013 a 2022**. 2022. Disponível em: <<https://www.cnm.org.br/biblioteca/exibe/15317>>. Acesso em: 10 de ago. de 2023.

COOK, A.; MERWADE, V. Effect of topographic data, geometric configuration and modeling approach on flood inundation mapping. **Journal of Hydrology**. Vol. 377. P. 131-142. Out. 2009.

CURITIBA. Coordenadoria Municipal de Proteção e Defesa Civil. **A Defesa Civil no Município de Curitiba**. 2009. Disponível em: <<http://www.defesacivil.curitiba.pr.gov.br/historico.aspx>>. Acesso em: 28 de fev. de 2023.

CURITIBA. **Plano Diretor de Drenagem (PDD)**. 2017. Disponível em: <<https://mid.curitiba.pr.gov.br/2017/00211748.pdf>>. Acesso em: 10 de jan. de 2022.

DARABI, H. CHOUBIN, B. RAHMATI, O. HAGHIGHI, A. T. PRADHAN, B. Urban flood risk mapping using the GARP and QUEST models: A comparative study of machine learning techniques. **Journal of Hydrology**. N. 569, p. 142-154, 2019.

EXCIMAP. **Handbook on Good Practices for Flood Mapping in Europe**. Bruxelas (Bélgica): European Exchange Circle on Flood Mapping, 2007.

FARINA, F. C. Abordagem sobre as técnicas de geoprocessamento aplicadas ao planejamento e gestão urbana. **CADERNOS EBAPE**. BR, v. 4, nº 4, dezembro, Rio de Janeiro: RJ, 2006.

GONZALES, Suely Franco Netto; FRANCISCONI, Jorge Guilherme; PAVIANI, Aldo. (Org.) **Planejamento e urbanismo na atualidade brasileira**: objeto, teoria, prática. São Paulo; Rio de Janeiro, RJ: Live Expressão, 2013.

IBGE (Instituto Brasileiro de Geografia e Estatística). **Censo Brasileiro de 2010**. Rio de Janeiro: IBGE, 2012. Instituto Brasileiro de Geografia e Estatística (IBGE).

IBGE (Instituto Brasileiro de Geografia e Estatística). **IBGE - CIDADES**. 2022. <<https://cidades.ibge.gov.br/>>. Acesso em: 10 de jan. de 2022.

IPPUC (Instituto de Pesquisa e Planejamento Urbano de Curitiba). **Cadastro Técnico**. 2019. Disponível em: <<http://ippuc.org.br/geodownloads/geo.htm>>. Acesso em: 10 de jan. de 2022.

ITCG (Instituto de Terras, Cartografia e Geologia do Paraná). **Divisão Político-Administrativa**. 2018. <<http://www.itcg.pr.gov.br/modules/faq/category.php?categoryid=8#>>. Acesso em: 10 de jan. de 2022.

KOBIYAMA, M.; MENDONÇA, M.; MORENO, D.A.; MARCELINO, I.P.V.O.; MARCELINO, E.V.; GONÇALVES, E.F.; BRAZETTI, L.L.P.; GOERL, R.F.; MOLLERI, G.; RUDORFF, F. **Prevenção de desastres naturais**: conceitos básicos. Curitiba: Organic Trading, 2006. 109 p.

KOURGIALAS N. N.; KARATZAS. G., P. Flood management and a GIS modelling method to assess flood-hazard areas—a case study, **Hydrological Sciences Journal**. Vol: 56:2. P. 212-225. DOI: <10.1080/02626667.2011.555836>. 2011.

LIU, B., W. HSU, S. CHEN, AND Y. MA. 1998. **Integrating Classification and Association Rule Mining**. In KDD-98. NewYork: AAAI ,27–31.

MARANDOLA JR., E. **População e mudança climática**. Dimensões humanas das mudanças ambientais globais. Campinas: Núcleo de Estudos de População (NEPO) - Unicamp, Brasília: UNFPA, p.29-52, 2009.

MOJADDADI, H.; PRADHAN, B.; NAMPAK, H.; AHMAD, N.; GHAZALI, A. H. Ensemble machine-learning-based geospatial approach for flood risk assessment using multi-sensor remote-sensing data and GIS. **Geomatics, Natural Hazards and Risk**. Volume 8:2, P. 1080-1102, DOI: <10.1080/19475705.2017.1294113>. 2017.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre Aprendizado de Máquina. In: REZENDE, S. O. (org.). **Sistemas Inteligentes: fundamentos e aplicações**. Barueri: Manole, 2005. P. 89-114.

MOURA, A. C. M. **Geoprocessamento na gestão e planejamento urbano**. 3ª ed. Rio de Janeiro: Interciência, 2014. 312 p.

MUDASHIRU R., B.; SABTU, N.; ABUSTAN, I.; BALOGUN, W. Flood hazard mapping methods: A review. **Journal of Hydrology**. Vol. 603. Part A. DOI: <<https://doi.org/10.1016/j.jhydrol.2021.126846>>. 2021.

MUELLER, C. C., MARTINE, G. Modernização da agropecuária, emprego agrícola e êxodo rural no Brasil – A década de 1980. **Revista de Economia Política**, Volume 17, nº 3 (67), Pg. 407-427. DOI: <<https://doi.org/10.1590/0101-31571997-0897>>. 1997.

OLIVEIRA, F. A., MELLO, E. L., PAIVA, E. C. R., CALIJURI, M. L., GUIMARÃES, A. O. **Identificação e Discriminação de Áreas de Risco no Entorno Urbano de Ipatinga, Brasil**. Rev. Int. de Desastres Naturales, Accidentes e Infraestructura Civil. Vol. 7(1), 2006.

PARANÁ. Coordenadoria Estadual da Defesa Civil. **Maiores Desastres**. 2019. Disponível em: <<http://www.defesacivil.pr.gov.br/Pagina/Maiores-desastresregistrados-no-Parana>>. Acesso em: 28 de fev. de 2023.

PÉREZ, J., E. ITURBIDE, V. OLIVARES, M. HIDALGO, A. MARTÍNEZ, AND N. ALMANZA. 2015. **A Data Preparation Methodology in Data Mining Applied to Mortality Population Databases**. Journal of Medical Systems 39 (11): 152. DOI: <10.1007/s10916-015-0312-5>.

POURGHASEMI, H. R.; KARIMINEJAD, N.; AMIRI, M.; EDALAT, M.; ZARAFSHAR, M.; BLASCHKE, T.; CERDAL, A. Assessing and mapping multihazard risk susceptibility using a machine learning technique. **Scientific Reports**. Vol. 3203. DOI: <<https://doi.org/10.1038/s41598-020-60191-3>>. 2020.

PUGLIESI, J. B.; MLEANDA, E. A.; PAULA, M. F. Mineração de Dados. In: REZENDE, Solange Oliveira (org.). **Sistemas Inteligentes: fundamentos e aplicações**. Barueri: Manole, 2005. P. 89-114.

RAFIEI-SARDOOI, E.; AZAREH, A.; CHOUBIN, B.; MOSAVI A. H.; CLAGUE J. J. Evaluating urban flood risk using hybrid method of TOPSIS and machine learning. **International Journal of Disaster Risk Reduction**. Vol. 66. DOI: <<https://doi.org/10.1016/j.ijdrr.2021.102614>>. 2021.

RIBEIRO N., A.; BATISTA, L. F. D. R.; COUTINHO, R.Q. Methodologies for generation of hazard indicator maps and flood prone areas: municipality of Ipojuca/PE. **RBRH**, Porto Alegre, v. 21, n. 2, p. 377-390, junho de 2016. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S2318-03312016000200377&lng=en&nrm=iso>. Acesso em: 20 de maio de 2019.

RIZEEI, H. M. PRADHANA, B. SAHARKHIZ, M. A. Allocation of emergency response centres in response to pluvial floodingprone demand points using integrated multiple

layer perceptron and maximum coverage location problem models. **International Journal of Disaster Risk Reduction**. N. 38, 2019.

RODRIGUES, G.T. **Geoprocessamento Aplicado a Área De Planejamento Urbano: Análise Espacial do Uso e Ocupação do Solo da Bacia Hidrográfica Ribeirão dos Padilhas, no Município de Curitiba (PR)**. Trabalho de Conclusão de Curso de Especialização. Pontifícia Universidade Católica de Minas Gerais (PUC Minas). 2022.

RODRIGUES, G.T., DE MOURA, E.N. (2021). Use of GIS to Estimate Socioeconomic Losses Caused by Urban Floods: A Tool for Improving Disaster Management. In: Leal Filho, W., Tortato, U., Frankenberger, F. (eds) Integrating Social Responsibility and Sustainable Development. **World Sustainability Series**. Springer, Cham. DOI: <https://doi.org/10.1007/978-3-030-59975-1_43>. 2021.

SANTOS, R. F. **Planejamento Ambiental: Teoria e Prática**. São Paulo/SP, Ed. Oficina de Textos, 2004.

SIMEPAR (Sistema de Tecnologia e Monitoramento Ambiental do Paraná). **Dados Meteorológicos**. 2022. Disponível em: <<http://simepar.br/>>. Acesso em: 27 de maio de 2022.

SOUZA, F. T. Previsão de morbidade em cidades um estudo da poluição atmosférica e doenças respiratórias na Região Metropolitana de Curitiba (RMC). **Anais XVIII ENANPUR 2019**. Natal, RN, 2019.

SUDERHSA (Superintendência de Desenvolvimento de Recursos Hídricos e Saneamento Ambiental do Estado do Paraná). **Hidrografia Bacia do Alto Iguaçu**. 2000. Disponível em: <<http://www.aguasparana.pr.gov.br/modules/conteudo/conteudo.php?conteudo=91>>. Acesso em: 27 de maio de 2021.

SUDERHSA (Superintendência de Desenvolvimento de Recursos Hídricos e Saneamento Ambiental do Estado do Paraná). **Sub-Bacias do Alto Iguaçu**. 2000. Disponível em: <<http://www.aguasparana.pr.gov.br/modules/conteudo/conteudo.php?conteudo=90>>. Acesso em: 27 de maio de 2021.

TUCCI, C. E. M. **Inundações urbanas**. Porto Alegre: ABRH/RHAMA, 2007. 393 p.

ZANELLA, M. E. **Inundações em Curitiba**: impactos, risco e vulnerabilidade socioambiental. Fortaleza: Imprensa Universitária, 2014. 194 p.

ZHAO, G.; PANG, B.; XU, Z.; PENG, D.; XU, L. Assessment of urban flood susceptibility using semi-supervised machine learning model. **Science of The Total Environment**. Volume 659. Pg. 940-949. DOI: <<https://doi.org/10.1016/j.scitotenv.2018.12.217>>. 2019.