



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA HIDRÁULICA E AMBIENTAL PROGRAMA
DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

LUCIANO HAMED CHAVES HAIDAR SOUSA

SISTEMAS URBANOS DE DRENAGEM SUSTENTÁVEL: UMA ABORDAGEM
ENTRE BIM E APRENDIZADO DE MÁQUINA

FORTALEZA

2024

LUCIANO HAMED CHAVES HAIDAR SOUSA

SISTEMAS URBANOS DE DRENAGEM SUSTENTÁVEL: UMA ABORDAGEM ENTRE
BIM E APRENDIZADO DE MÁQUINA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal do Ceará, como requisito parcial para a obtenção do título de Mestrado em Engenharia Civil. Área de concentração: Recursos Hídricos.

Orientadora: Prof^ª. Dra. Ticianá Marinho de Carvalho Studart.

FORTALEZA
2024

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- S697s Sousa, Luciano Hamed Chaves Haidar.
Sistemas urbanos de drenagem sustentável : uma abordagem entre BIM e aprendizado de máquina /
Luciano Hamed Chaves Haidar Sousa. – 2024.
68 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-
Graduação em Engenharia Civil: Recursos Hídricos, Fortaleza, 2024.
Orientação: Profa. Dra. Ticianá Marinho de Carvalho Studart.
1. BIM. 2. redes neurais. 3. programação visual. I. Título.

CDD 627

LUCIANO HAMED CHAVES HAIDAR SOUSA

SISTEMAS URBANOS DE DRENAGEM SUSTENTÁVEL: UMA ABORDAGEM ENTRE
BIM E APRENDIZADO DE MÁQUINA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal do Ceará, como requisito parcial para a obtenção do título de Mestrado em Engenharia Civil. Área de concentração: Recursos Hídricos.

Aprovada em: 29/11/2024.

BANCA EXAMINADORA

Prof^ª. Dra. Ticiano Marinho de Carvalho Studart (Orientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. Paulo Roberto Lacerda Tavares
Universidade Federal do Cariri (UFCA)

Prof^ª. Dra. Celme Torres Ferreira da Costa
Universidade Federal do Cariri (UFCA)

Aos meu pais, Ana e Antônio

AGRADECIMENTOS

Agradeço primeiramente a Deus pela minha existência e pela oportunidade de ter chegado até aqui.

Agradeço aos meus pais, Ana Lúcia e Antônio Alves, por terem sido meu alicerce, incentivando-me, estimulando-me e mostrando que a vida é cheia de possibilidades, e que eu poderia chegar onde quisesse.

Agradeço às minhas irmãs, Andressa, Andreia e Pollyanna. Afinal, a família é parte do que somos hoje, e cada uma, à sua maneira, contribuiu em algum momento da minha jornada.

Agradeço à professora Ticiane Studart por ter aceitado o desafio de me orientar nesta jornada. Sou grato por seus ensinamentos sobre hidrologia, que começaram na graduação e se estenderam até este mestrado. Sua abordagem na gestão de recursos hídricos me proporcionou uma nova perspectiva, não apenas sobre a engenharia, mas também sobre o porquê das coisas serem como são. Agradeço, ainda, pela paciência e perseverança que teve comigo.

Agradeço ao professor Assis, que, com seu jeito gentil e alegre, contribuiu significativamente para o meu entendimento da complexidade dos fenômenos hidrológicos da natureza e me introduziu ao mundo do aprendizado de máquina.

Agradeço à professora Cely Martins, que acreditou em mim desde o início da minha trajetória na graduação e continua a me incentivar no âmbito da pesquisa.

Agradeço à minha namorada e companheira, Camilly, que, durante todo esse tempo, me apoiou na minha jornada e me inspira a crescer e ser uma pessoa melhor a cada dia.

Agradeço aos meus amigos que, por algum motivo, acreditam na minha trajetória: Ana Stherfane, Sabrina e Francisco Marcélio, que me apoiam há muitos anos e continuam ao meu lado até hoje.

Agradeço aos membros da banca deste trabalho, por terem aceitado o convite e se disponibilizado a contribuir para o crescimento desta pesquisa.

Agradeço a todos os profissionais e professores que contribuíram para o meu aprendizado durante este ciclo. Cada um teve um papel muito importante na minha formação.

E, por fim, agradeço à UFC, que me acolheu e me permitiu desenvolver uma série de atividades que moldaram meu perfil pessoal e profissional.

“Uma mente que se abre a uma nova ideia, jamais retorna ao tamanho original.”
Albert Einstein.

RESUMO

Os sistemas urbanos de drenagem sustentável (SUDS) são uma resposta não convencional e necessária aos desafios relacionados à gestão das águas pluviais em cidades que enfrentam um crescimento urbano acelerado. Esses sistemas têm como objetivo reduzir os impactos negativos da urbanização no ciclo hidrológico, como o aumento da impermeabilização do solo e enchentes urbanas. Para otimizar a tomada de decisão nas soluções a serem implantadas, o uso de tecnologias como o Building Information Modeling (BIM) e o aprendizado de máquina (ML) têm sido cada vez mais exploradas no desenvolvimento de soluções de drenagem. No contexto de drenagem urbana sustentável, o BIM proporciona uma plataforma integrada para gerenciar dados de projeto, modelar cenários e analisar a performance de dispositivos, como trincheiras drenantes, pavimentos permeáveis e bacias de retenção. O aprendizado de máquina, por sua vez, oferece ferramentas preditivas e analíticas que permitem melhorar a eficiência do planejamento e do desempenho dos SUDS, analisando dados hidrológicos. Este trabalho objetiva desenvolver um fluxo de trabalho utilizando BIM e aprendizado de máquina, por meio de Redes Neurais Recorrentes e dados extraídos de satélite, para o dimensionamento de sistemas urbanos de drenagem sustentável. Com isso, foram utilizadas técnicas de aprendizado de máquina, por meio da linguagem Python, e, ainda, desenvolvidos algoritmos de programação visual para auxiliar no dimensionamento de dispositivos de SUDS. Para validação, foi utilizada uma aplicação prática para comparação das três soluções implementadas (pavimento permeável, trincheira drenante e bacia de retenção). Diante do exposto, foi possível verificar as potencialidades e os pontos de melhoria da interconexão entre a ferramenta BIM utilizada e o aprendizado de máquina, contribuindo para embasar novos caminhos para essa integração.

Palavras-chave: bim; redes neurais; programação visual

ABSTRACT

Sustainable Urban Drainage Systems (SUDS) are a non-conventional and necessary response to the challenges related to stormwater management in cities experiencing rapid urban growth. These systems aim to reduce the negative impacts of urbanization on the hydrological cycle, such as increased soil impermeability and urban flooding. To optimize decision-making regarding the solutions to be implemented, technologies such as Building Information Modeling (BIM) and Machine Learning (ML) have been increasingly explored in the development of drainage solutions. In the context of sustainable urban drainage, BIM provides an integrated platform for managing project data, modeling scenarios, and analyzing the performance of devices such as infiltration trenches, permeable pavements, and detention basins. Machine Learning, on the other hand, offers predictive and analytical tools that enhance the efficiency of planning and the performance of SUDS by analyzing hydrological data. This study aims to develop a workflow using BIM and Machine Learning, through Recurrent Neural Networks (RNN) and satellite-extracted data, for the design of sustainable urban drainage systems. To this end, Machine Learning techniques were applied using the Python programming language, and visual programming algorithms were also developed to assist in the design of SUDS devices. For validation, a practical application was carried out to compare the three implemented solutions (permeable pavement, infiltration trench, and detention basin). Based on the results, it was possible to identify the potentialities and areas for improvement in the integration between the BIM tool used and Machine Learning, contributing to paving new pathways for this integration.

Keywords: bim; neural networks; visual programming

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1: Linha do tempo decretos e lei envolvendo BIM | 15 |
| Figura 2: Estrutura do trabalho | 19 |
| Figura 3: Sistema de pavimento permeável infiltração total | 21 |
| Figura 4: Sistema de pavimento permeável infiltração parcial | 22 |
| Figura 5 Sistema de pavimento permeável sem infiltração | 22 |
| Figura 6: Exemplo de trincheira drenante | 24 |
| Figura 7: Bacia de detenção..... | 26 |
| Figura 8: Sistema de bacia de detenção..... | 27 |
| Figura 9: Diagrama de conjuntos de inteligência artificial..... | 28 |
| Figura 10: Arquitetura de uma RNA | 30 |
| Figura 11: Arquitetura de RNR..... | 31 |
| Figura 12: Arquitetura RNR padrão | 32 |
| Figura 13: Rede Neural Recorrente do tipo LSTM | 32 |
| Figura 14: As dimensões do BIM..... | 34 |
| Figura 15: Ciclo de vida de um ativo | 35 |
| Figura 16: Visão macro da pesquisa | 38 |
| Figura 17: Mapa de localização do terreno. | 39 |
| Figura 18: Site para acesso aos dados de chuva | 39 |
| Figura 19: Dados de chuva mensal extraídos via satélite..... | 40 |
| Figura 20: Dados diários de chuva extraídos via satélite | 40 |
| Figura 21: Vista aérea do objeto de estudo..... | 41 |
| Figura 22: Fluxo do algoritmo em python..... | 43 |
| Figura 23: Masterplan do objeto de estudo | 44 |
| Figura 24 Automação para criação de alinhamentos em série..... | 45 |
| Figura 25 Automação para criação de perfis | 45 |
| Figura 26 Perfil longitudinal projetado | 46 |
| Figura 27 Algoritmo para criação de corredores | 46 |
| Figura 28 Modelagem dos corredores do empreendimento | 47 |
| Figura 29 Modelagem tridimensional do terreno projetado | 47 |
| Figura 30 Microbacias de contribuição | 48 |
| Figura 31 Algoritmo em BIM de dimensionamento de multiplas soluções de drenagem..... | 49 |
| Figura 32: Histograma de distribuição de chuva pré-processamento..... | 51 |

| | |
|---|----|
| Figura 33: Boxplot de chuva pré-processamento | 52 |
| Figura 34: Gráfico de dispersão de chuva pré-processamento | 52 |
| Figura 35: Previsão de chuva x dados reais..... | 53 |
| Figura 36: Histograma de distribuição de chuva pós-processamento | 53 |
| Figura 37: Boxplot pós-processamento | 54 |
| Figura 38: Comparação entre dados reais e previsões..... | 54 |
| Figura 39: Chuva ao longo do tempo (Modelo x real) | 55 |
| Figura 40: Modelagem da superfície projetada | 57 |
| Figura 41 Rotina de dimensionamento de múltiplas soluções de SUDS | 59 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1: Indicadores de desempenho | 55 |
| Tabela 2: Comparativo método manual e método automatizado | 57 |
| Tabela 3: Dados de entrada..... | 58 |
| Tabela 4: Resultados de dimensionamento..... | 59 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|----------------|--|
| RNR | Redes Neurais Recorrentes |
| NBR | Norma Brasileira Regulamentar |
| BIM | <i>Building Information Modelling</i> |
| SUDS | Sistema Urbano de Drenagem Sustentável |
| RNA | Redes Neurais Artificiais |
| LSTM | <i>Long Short-Term Memory</i> |
| GRU | <i>Gated Recurrent Unit</i> |
| MAE | Erro absoluto médio |
| R ² | Coefficiente de Determinação |
| NSE | Eficiência de Nash-Sutcliffe |
| MSE | Erro Quadrático Médio |

SUMÁRIO

| | | |
|-------------|--|-----------|
| 1 | INTRODUÇÃO | 15 |
| 1.1. | Objetivos | 18 |
| 1.1.1. | <i>Objetivo geral</i> | 18 |
| 1.1.2. | <i>Objetivos específicos</i> | 18 |
| 1.2. | Estrutura do trabalho | 19 |
| 2 | REFERENCIAL TEÓRICO | 20 |
| 2.1. | Drenagem Urbana | 20 |
| 2.1.1. | <i>Pavimento Permeável</i> | 21 |
| 2.1.2. | <i>Trincheira Drenante</i> | 23 |
| 2.1.3. | <i>Bacia de Detenção</i> | 26 |
| 2.2. | Machine Learning na hidrologia | 27 |
| 2.2.1. | <i>Aprendizado de Máquina</i> | 28 |
| 2.2.2. | <i>Redes Neurais Artificiais (RNA)</i> | 29 |
| 2.2.3. | <i>Redes Neurais Recorrentes (RNR)</i> | 30 |
| 2.3. | BIM | 33 |
| 3 | METODOLOGIA | 38 |
| 3.1. | Área de Estudo | 38 |
| 3.2. | Obtenção dos dados | 39 |
| 3.3. | Indicadores de desempenho RNR | 41 |
| 3.4. | Método de treino-teste | 43 |
| 3.5. | Fluxo do algoritmo desenvolvido | 43 |
| 3.6. | Fluxo desenvolvido para modelagem BIM | 44 |
| 4 | ANÁLISE DOS RESULTADOS | 50 |
| 4.1. | Redes neurais recorrentes | 50 |
| 4.1.1. | <i>Pré-processamento</i> | 51 |
| 4.1.2. | <i>Pós processamento:</i> | 53 |
| 4.1.3. | <i>Indicadores de desempenho</i> | 55 |
| 4.2. | Modelagem BIM | 56 |
| 5 | CONSIDERAÇÕES FINAIS | 61 |
| | REFERÊNCIAS | 63 |
| | APENDICE A - DADOS DE PRECIPITAÇÃO TRMM | 65 |

1 INTRODUÇÃO

O processo de urbanização nas últimas décadas tem sido um tema amplamente estudado no campo da hidrologia urbana. Com o grande crescimento da impermeabilização das cidades devido ao desenvolvimento urbano, o ciclo hidrológico natural das cidades tem se alterado. Segundo Canholi (2005), essa impermeabilização reduz de maneira significativa a capacidade de absorção de água dos solos o que culmina no aumento da frequência e intensidade de problemas como enchentes e alagamentos em águas urbanizadas.

Paralelo a isso, tem-se um movimento crescente no âmbito nacional no tocante a utilização do BIM- Building Information Modelling, ou ainda, Modelagem da Informação e Construção aplicado aos edifícios e as obras de infraestrutura. No decorrer dos últimos anos, o movimento se deu no setor privado e público, também corroborado pela criação de decretos conforme a Figura 1, e ainda a lei de licitações (Brasil, 2021) que em seu artigo 19 diz que nas licitações de obras públicas de arquitetura e engenharia, sempre que adequado, devem ser utilizados preferencialmente a modelagem da informação da construção ou tecnologias e processos mais avançados que venham a substituí-la, e isso mostra a importância e o impacto que esta tecnologia possui no âmbito nacional. Dentre os principais objetivos incluem a disseminação do uso do BIM, o estabelecimento de normas e padrões, a capacitação de profissionais para a transição para este novo processo, e a promoção do uso de padrões neutros de interoperabilidade (Brasil, 2020).

Figura 1: Linha do tempo decretos e lei envolvendo BIM



Fonte: Elaborado pelo autor.

Tangente a isso, o crescimento populacional e a urbanização das cidades representam grandes desafios de complexidade relevante, especialmente devido à rapidez desse

crescimento e às mudanças climáticas, que evidenciam cada vez mais eventos extremos. Isso impõe uma série de restrições para as obras de drenagem dos empreendimentos. Por essa razão, têm-se recorrido a soluções que utilizam a natureza como meio de atenuar as problemáticas decorrentes da urbanização acelerada. Medidas como telhados verdes, pavimentos permeáveis e bacias de retenção emergem como soluções sustentáveis e eficientes para o manejo das águas pluviais. Essas soluções têm demonstrado potencial para reduzir enchentes, melhorar a qualidade da água e contribuir para a sustentabilidade urbana (Ferreira, 2021).

Uma abordagem paramétrica na avaliação dessas medidas permitirá uma análise mais rápida de seu desempenho. Com o BIM, é possível simular diferentes cenários e otimizar o projeto dessas soluções, considerando aspectos técnicos, econômicos e ambientais (Eastman, 2014).

Nos contextos urbanos, o aumento da impermeabilização do solo tem intensificado os problemas de drenagem, agravando eventos de alagamento e reduzindo a eficiência dos sistemas de escoamento (Tucci, 2007). Esses problemas são particularmente críticos em áreas com topografia desfavorável ou com restrições de vazão para lançamento. Além disso, a forma ideal de determinar a precipitação e o escoamento das águas é por meio do monitoramento hidrológico (Garcia, 2023). Contudo, em muitos locais, os dados hidrológicos convencionais, como registros de postos pluviométricos e fluviométricos, são limitados ou descontinuados, o que dificulta a precisão na modelagem e na concepção de sistemas de drenagem.

Diante disso, este estudo investiga a possibilidade de integrar o uso de BIM (Building Information Modeling) e técnicas de aprendizado de máquina, especificamente redes neurais recorrentes (RNNs), visando a modelagem hidrológica de sistemas urbanos de drenagem sustentável. Utilizando dados de precipitação extraídos de satélites, propõe-se explorar se essa abordagem pode auxiliar na solução das limitações associadas à obtenção de dados hidrológicos convencionais e na melhoria da precisão dos modelos de drenagem.

As redes neurais tradicionais não conseguem desempenhar um raciocínio de longos períodos, por outro lado, as redes neurais recorrentes resolvem esse problema, são redes com loops, permitindo que as informações persistam. Um dos tipos de rede neural recorrente é o LSTM (Long short-term memory) que além de possui a capacidade de memória, consegue integrar múltiplas fontes de dados, permitindo uma estimativa quantitativa mais precisa (Gavahi et al., 2023). Assim, o uso de LSTM para séries temporais de precipitação melhora a precisão das previsões e também fornece uma abordagem robusta para lidar com a complexidade dos dados meteorológicos.

A combinação de BIM e aprendizado de máquina na modelagem de sistemas de drenagem sustentável pode trazer grandes avanços para o planejamento urbano e a mitigação de riscos associados a eventos de chuva. O BIM possibilita a criação de um modelo digital completo e compatibilizado, permitindo a simulação e a visualização das soluções de drenagem. Quando aliado ao uso de redes neurais recorrentes, que, em comparação com as redes neurais artificiais tradicionais, são mais adequadas para modelar séries temporais hidrológicas e meteorológicas complexas (Yin, 2022), como dados de chuva extraídos de satélites, esse sistema pode oferecer previsões mais robustas e adaptar-se melhor às particularidades locais, mesmo em áreas onde dados pluviométricos convencionais são escassos.

Essa pesquisa justifica-se pela necessidade de encontrar métodos que integrem sustentabilidade e tecnologia para otimizar a gestão hídrica urbana, especialmente em cenários de mudança climática e expansão das áreas impermeáveis. A associação de BIM com aprendizado de máquina, por meio de redes neurais recorrentes, potencializa a análise e o dimensionamento de sistemas sustentáveis, como pavimentos permeáveis, trincheiras drenantes e bacias de retenção. Ao explorar essa integração, a pesquisa pretende contribuir com uma metodologia para o desenvolvimento de sistemas de drenagem, fornecendo subsídios para a redução de alagamentos nas cidades.

1.1. Objetivos

1.1.1. Objetivo geral

Desenvolver um fluxo de trabalho utilizando BIM (Modelagem da Informação da Construção) aprendizado de máquina por meio de Redes Neurais Recorrentes e dados extraídos de satélite para dimensionamento de sistemas urbanos de drenagem sustentável.

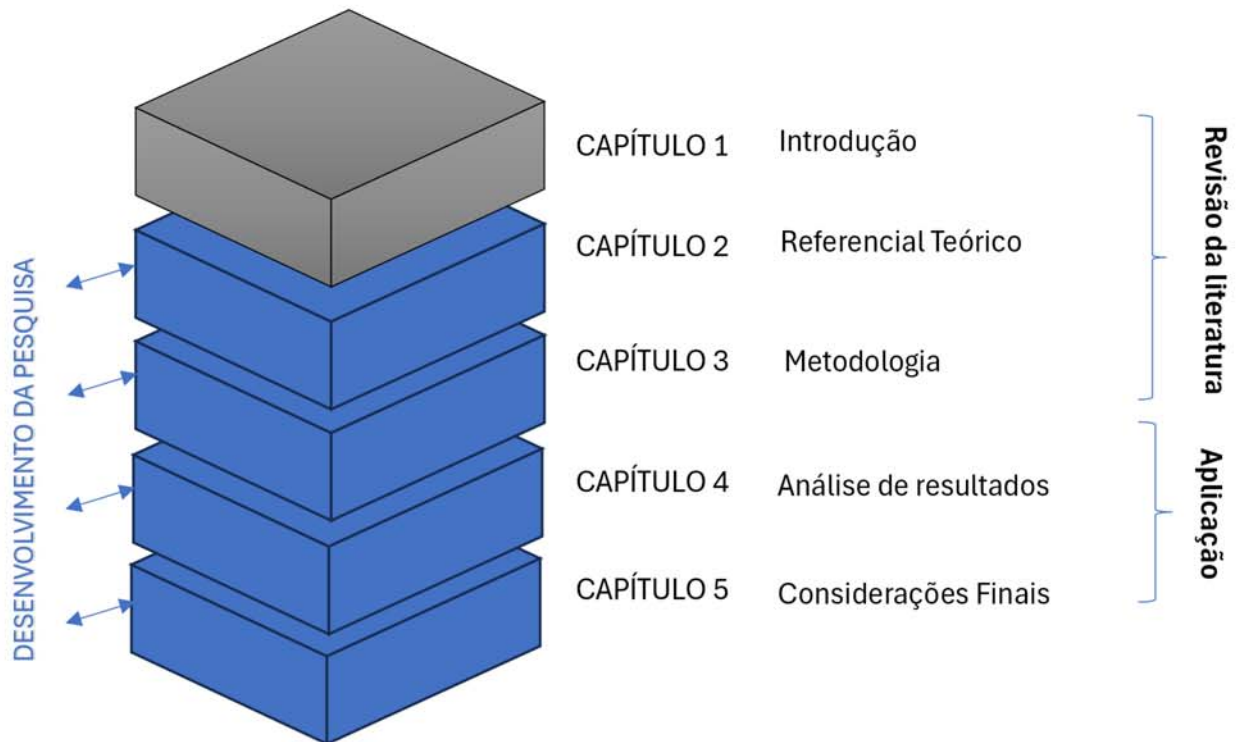
1.1.2. Objetivos específicos

- Aplicar redes neurais recorrentes para análise de dados hidrológicos.
- Explorar o uso do BIM para a modelagem de sistemas de drenagem sustentável.
- Desenvolver um fluxo de trabalho automatizado e verificar as possibilidades de integração do modelo BIM e modelo RNR.

1.2. Estrutura do trabalho

A dissertação apresentada está organizada em cinco capítulos principais, conforme figura xx a seguir.

Figura 2: Estrutura do trabalho



Fonte: Elaborado pelo autor

Capítulo 1: Trata-se da contextualização abordando dois assuntos principais: BIM, Sistemas Urbanos de Drenagem Sustentável e redes neurais. Além disso, trata sobre o problema de pesquisa, justificativa e objetivos do trabalho.

Capítulo 2: Trazendo dois assuntos principais, a revisão bibliográfica

Capítulo 3: Apresenta as abordagens metodológicas da pesquisa e, bem como as ferramentas utilizadas e a caracterização do objeto de estudo.

Capítulo 4: Expõe as aplicações realizadas e os resultados quantitativos, qualitativos e indicadores de desempenho, com suas respectivas análises sobre o que foi gerado.

Capítulo 5: Trata das considerações finais, demonstrando os objetivos que foram atingidos, comentários e sugestões para pesquisas futuras.

2 REFERENCIAL TEÓRICO

2.1. Drenagem Urbana

Nos sistemas de drenagem urbana, segundo Moura (2004), tem-se os sistemas clássicos e os sistemas compensatórios. Os sistemas clássicos são inspirados no higienismo, tem o objetivo de escoar as águas pluviais o mais breve possível para um determinado corpo hídrico. Possui elementos de captação, condução e lançamento. Esse sistema possui eficiência hidráulica, e por isso, apresenta alguns pontos de atenção, pois com este tipo de concepção e o aumento da urbanização este sistema começa a apresentar falhas o que resultando em alagamentos. E a ampliação de capacidade do sistema se torna cada vez mais onerosa.

As medidas não convencionais ou ainda, medidas compensatórias em drenagem urbana podem ser entendidas como estruturas, obras, dispositivos ou mesmo como conceitos diferenciados de projeto, cuja utilização não se encontra ainda disseminada. São soluções que diferem do conceito tradicional de canalização, mas podem estar a ela associadas, para adequação ou otimização do sistema de drenagem. (Canholi, 2005).

No contexto da drenagem urbana, emergem diversas incertezas no que tange a relação entre chuva-vazão, pode-se destacar a complexidade da resposta hidrológica em áreas urbanas, onde o rápido escoamento superficial devido à impermeabilização pode resultar em picos de vazão elevados durante eventos de chuva intensa. Essa dinâmica é ainda mais desafiadora devido à variabilidade espacial das precipitações urbanas, conforme observado por Shuster et al. (2005), que influencia significativamente a distribuição e magnitude das enchentes urbanas.

Além disso, estudos de caso realizados por Silva (2022) demonstraram a aplicação de modelos de aprendizado de máquina para previsão de vazões, ressaltando a importância de abordagens avançadas para lidar com as incertezas inerentes à interação complexa entre chuvas, superfícies urbanas e drenagem.

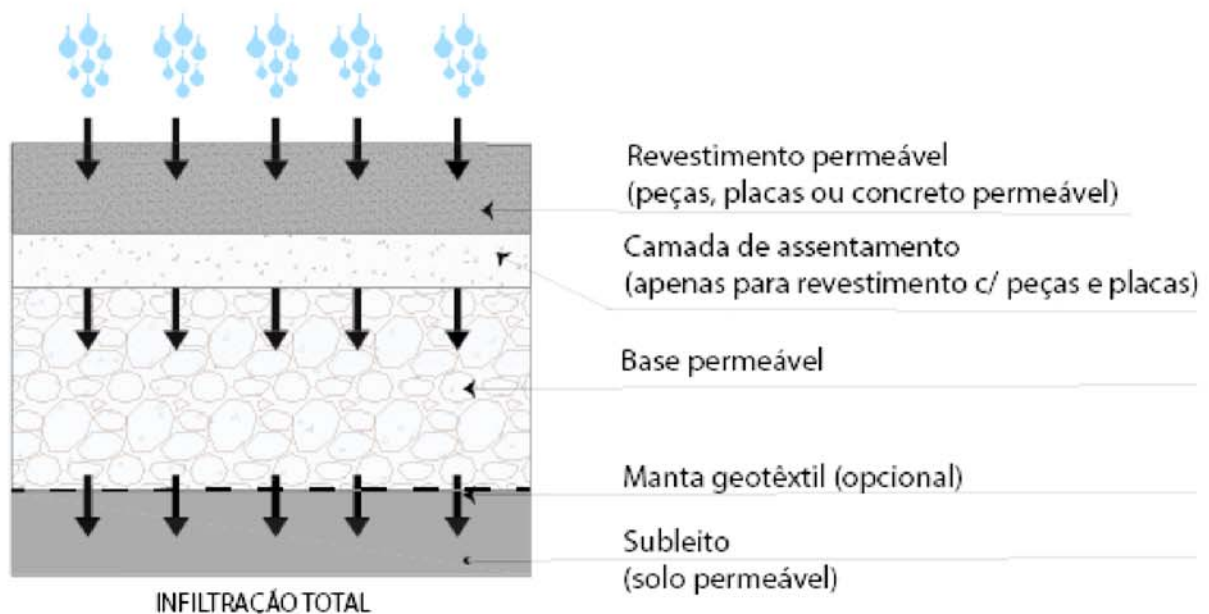
Os sistemas urbanos de drenagem sustentável (SUDS) têm se tornado cada vez mais relevantes na gestão de águas pluviais em áreas urbanas. Estes sistemas visam minimizar os impactos negativos da urbanização, como enchentes e poluição hídrica, promovendo a infiltração e o tratamento natural das águas. Este trabalho aborda três componentes fundamentais dos SUDS: pavimento permeável, trincheira drenante e bacia de retenção.

2.1.1. Pavimento Permeável

O pavimento permeável é uma solução que permite a infiltração da água da chuva através de sua superfície, reduzindo o escoamento superficial e promovendo a recarga do lençol freático (Tucci, 2001). Este tipo de pavimento pode ser feito de diversos materiais, como concreto poroso, blocos de concreto intertravados ou asfalto permeável. A NBR 16416, classifica os pavimentos permeáveis quanto ao sistema em três categorias: Com infiltração total, infiltração parcial e sem infiltração.

No sistema de infiltração total, toda a água escoada para o pavimento é absorvida e infiltrada no subleito, conforme Figura 3.


Figura 3: Sistema de pavimento permeável infiltração total



Fonte: Elaborado pelo autor

No sistema de infiltração parcial, parte da água é absorvida pelo subleito e parte é direcionada por uma tubulação de drenagem no pavimento conforme Figura 4.


Figura 4: Sistema de pavimento permeável infiltração parcial



Fonte: Elaborado pelo autor

No sistema sem infiltração toda a água absorvida pelo pavimento é direcionada as tubulações de drenagem por meio dos furos das paredes dos tubos, Figura 5.

Figura 5 Sistema de pavimento permeável sem infiltração



Fonte: Elaborado pelo autor

Para o dimensionamento destes dispositivos a NBR utiliza a seguinte formulação, Equação (1):

$$H_{\text{máx}} = \frac{\Delta Q_c R + P - fTe}{V_r} \quad (1)$$

Onde:

$H_{\text{máx}}$ é a altura do reservatório (m);

$\Delta Q_c R$ é o produto entre a precipitação excedente (ΔQ_c) e a área de contribuição para uma dada chuva de projeto pela relação entre área de contribuição e a área do pavimento permeável (R);

P é precipitação projeto (m);

f taxa de infiltração do solo (m/h);

T é o tempo de enchimento da camada de reservatório (h) e

V_r o índice de vazios da base.

2.1.2. Trincheira Drenante


As trincheiras drenantes são estruturas subterrâneas projetadas para coletar e infiltrar água da chuva. Elas são geralmente construídas com materiais porosos e são preenchidas com pedras ou outros agregados que facilitam a passagem da água. Essas trincheiras podem ser utilizadas em áreas urbanas para controlar o escoamento e reduzir o risco de inundações. Dentre as principais vantagens da construção de trincheiras drenantes destacam-se como uma solução eficiente e sustentável para a gestão de águas pluviais. Sua instalação é simples, com baixo custo e materiais acessíveis, como brita e geotêxteis, permitindo uma implementação prática. Além disso, favorecem a recarga do lençol freático, ajudando a equilibrar o ciclo hidrológico urbano, e reduzem significativamente o escoamento superficial, minimizando riscos de enchentes. Integradas ao paisagismo, proporcionam benefícios estéticos e ambientais, promovendo o controle de poluição difusa ao filtrar sedimentos e impurezas. Adaptáveis a diversas aplicações, como áreas residenciais e vias urbanas, as trincheiras representam uma alternativa funcional e ambientalmente integrada para drenagem urbana.

Apesar das diversas vantagens, as trincheiras drenantes possuem limitações que devem ser consideradas. São suscetíveis a colmatação caso não sejam corretamente dimensionadas ou mantidas, e sua eficiência é limitada em solos com baixa permeabilidade ou em eventos de chuvas intensas. Além disso, apresentam o risco de contaminação do lençol freático em áreas urbanas com presença de poluentes. Em ambientes densamente ocupados, o

espaço necessário para sua implantação pode ser um desafio, e sua eficiência a longo prazo depende de manutenções periódicas, como limpeza de filtros e reposição de materiais drenantes. Assim, seu uso requer planejamento cuidadoso para maximizar os benefícios e minimizar os impactos.

As trincheiras drenantes, Figura 6, são amplamente utilizadas nas Soluções Urbanas de Drenagem Sustentável (SUDs), com o objetivo de reduzir o escoamento superficial e promover a recarga do lençol freático em áreas urbanas. Elas são projetadas para capturar a água da chuva, armazená-la temporariamente e permitir sua infiltração gradual no solo, contribuindo para a mitigação de enchentes e para o controle da poluição da água. A infiltração controlada permite que o solo atue como um filtro natural, reduzindo contaminantes antes que a água chegue ao lençol freático, melhorando a qualidade das águas subterrâneas. Em comparação com métodos convencionais de drenagem, as trincheiras drenantes não apenas controlam o escoamento, mas também oferecem benefícios ecológicos e econômicos, sendo uma estratégia viável para promover cidades mais resilientes e ambientalmente sustentáveis (Fletcher et al., 2015).

Figura 6: Exemplo de trincheira drenante



Fonte: Elaborado pelo autor

Dimensionamento pelo método discorrido por Graciosa (2008) das trincheiras de infiltração:

$$V_p = \frac{10^3}{3,6} \cdot i \cdot t_d \cdot A_d \quad (2)$$

Em que:

V_p = volume de projeto, em m³

i = intensidade de precipitação, em mm/h

t_d = tempo de precipitação, em s

A_d = área de drenagem conectada à trincheira de infiltração, em m²

$$A_{inf} = 2 * L \frac{H}{2} = L * H \quad (3)$$

Volume efetivo de armazenamento ($V_{a,ef}$)

$$V_{a,ef} = v * V_t \quad (4)$$

Em que:

v = porosidade da brita utilizada para o enchimento da trincheira. Logo o armazenamento efetivo da trincheira é igual a:

$$V_{a,ef} = \left(\frac{10^3}{3,6} \cdot i \cdot t_d \cdot A_d \right) - (I * L * H) \quad (5)$$

Onde:

i = intensidade de precipitação, em mm/h

t_d = tempo, em segundos

A_d = área de drenagem da trincheira em m²

I = Infiltração acumulada até o instante t , em m³/m²

A_{inf} = área efetiva de infiltração = $L \cdot H$ (m²)

Considerando a porosidade, tem-se a equação (6).

$$V_t = \left[\frac{\left(\frac{10^3}{3,6} \cdot i \cdot t_d \cdot A_d \right) - (I * L * H)}{\phi} \right] \quad (6)$$


As dimensões da trincheira são: B (largura), H (profundidade) e L (comprimento).

2.1.3. *Bacia de Detenção*

As bacias de detenção (

Figura 7) são reservatórios temporários que armazenam água da chuva durante eventos de precipitação intensa, liberando-a lentamente para os corpos d'água adjacentes. Essas estruturas são projetadas para evitar a sobrecarga dos sistemas de drenagem e minimizar os riscos de enchentes.

Figura 7: Bacia de detenção

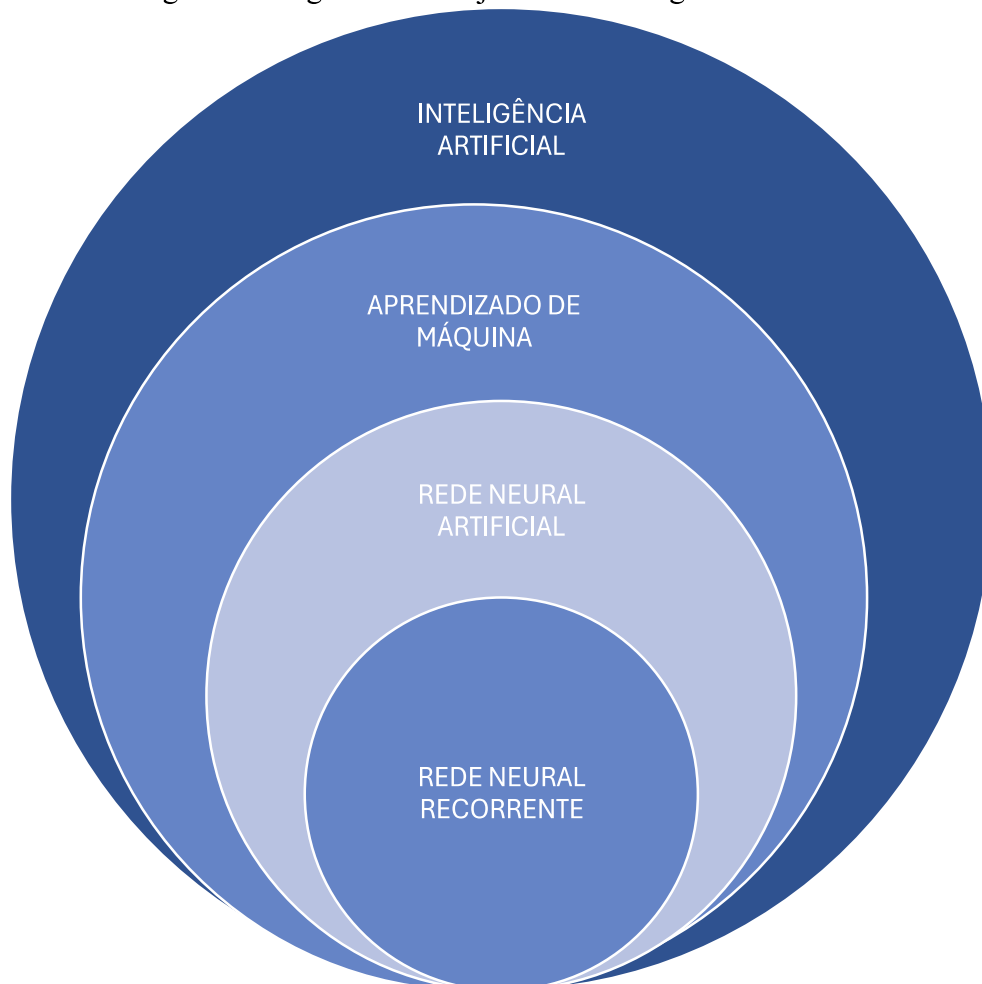


Fonte: Elaborado pelo autor

Traz como vantagens: Controle do escoamento de águas pluviais, reduzindo o risco de inundações; Possibilidade de recuperação de áreas degradadas e criação de habitats para a fauna e flora; Melhoria da qualidade da água, permitindo que sedimentos e poluentes se depositem antes da liberação.

neurais artificiais e redes neurais recorrentes. Para facilitar o entendimento na Figura 9, tem se essas técnicas como conjuntos dentro de inteligência artificial.

Figura 9: Diagrama de conjuntos de inteligência artificial



Fonte: Elaborado pelo autor

2.2.1. Aprendizado de Máquina

Segundo Murphy (2012), aprendizado de máquina é o desenvolvimento de algoritmos que permitem a computadores realizar tarefas complexas com base na identificação de padrões em dados. Enfatiza a importância de uma abordagem probabilística, o que é particularmente relevante quando lidamos com dados hidrológicos, onde as incertezas são intrínsecas e difíceis de prever com exatidão. Em modelos de aprendizado de máquina para a hidrologia, essa visão probabilística ajuda a entender as margens de erro e as variações nos padrões de chuva, vazão e outras variáveis. A capacidade dos modelos supervisionados e não supervisionados de generalizar para novos dados, considerando as incertezas, é essencial para previsões confiáveis

em cenários complexos e mutáveis, como a previsão de enchentes e a modelagem de bacias hidrográficas.

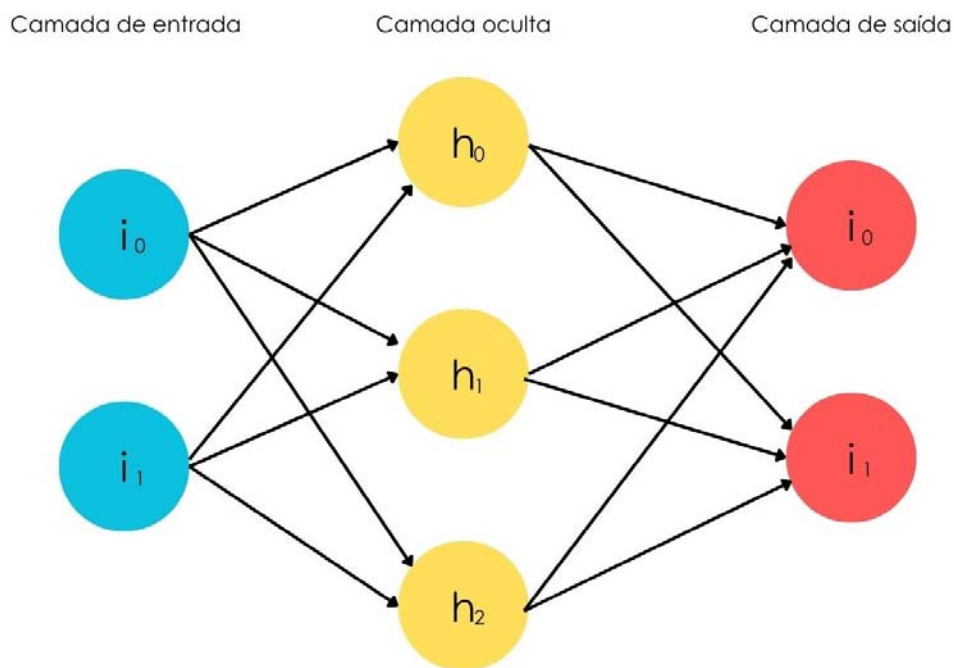
Na perspectiva de Bishop (2006) sobre aprendizado de máquina, focada em reconhecimento de padrões e na extração de representações significativas, oferece uma base metodológica para modelar dados hidrológicos de forma interpretativa. Essa abordagem permite que algoritmos identifiquem padrões sazonais, tendências de longo prazo e anomalias, extraíndo insights que podem ser úteis para decisões de gestão hídrica e mitigação de desastres. Ao combinar estatística e inteligência artificial, essa visão favorece um entendimento detalhado dos dados, ajudando a reduzir ruídos e a aumentar a clareza dos padrões relevantes para problemas hidrológicos específicos.

2.2.2. Redes Neurais Artificiais (RNA)

As redes neurais artificiais (RNAs) oferecem uma visão abrangente sobre o potencial dessas estruturas para modelar e resolver problemas complexos em diversas áreas corroborado por autores a seguir. Bishop (2006), destaca as RNAs como modelos computacionais que buscam replicar, de forma simplificada, o funcionamento do cérebro humano, o que envolve a construção de camadas de neurônios artificiais interconectados. Cada neurônio realiza cálculos baseados em pesos e funções de ativação, permitindo que as redes capturem relações não lineares entre variáveis de entrada e saída. Essa arquitetura possibilita que as RNAs desempenhem tarefas de classificação e regressão, ajustando seus pesos por meio de algoritmos como o da retropropagação para minimizar o erro nas previsões.

Murphy (2012) contribui para essa visão ao descrever as RNAs como um conjunto de funções paramétricas capazes de modelar relações complexas em dados. Ele enfatiza a capacidade dessas redes de aprender representações em camadas, algo essencial para captar padrões e relações em dados altamente não lineares. Alerta ainda, para o risco de *overfitting* em RNAs com muitas camadas e parâmetros, ou seja, o ajuste excessivo aos dados de treinamento que prejudica a generalização do modelo para novos dados. Para evitar esse problema, ele ressalta a importância de técnicas de regularização, que ajudam a RNAs a se tornarem mais robustas e adequadas a dados desconhecidos.

Figura 10: Arquitetura de uma RNA




Fonte: Elaborado pelo autor

Essas abordagens complementares sublinham a versatilidade das RNAs, destacando sua capacidade de modelar dados complexos por meio de uma estrutura de camadas e de ajustar-se a padrões não triviais. Essa flexibilidade torna as RNAs particularmente valiosas em áreas onde a não linearidade e a complexidade são características predominantes como hidrologia.

2.2.3. *Redes Neurais Recorrentes (RNR)*

As redes neurais recorrentes são uma classe especial de redes neurais projetadas para lidar com dados sequenciais, como séries temporais. A capacidade das RNR de manter uma "memória" do estado anterior é muito importante em contextos onde o tempo e a sequência de eventos desempenham um papel fundamental. No caso da previsão de chuvas, por exemplo, a RNR pode analisar dados históricos de precipitação, temperatura e umidade para identificar padrões que podem prever eventos futuros. Essa habilidade de capturar dependências temporais é um avanço significativo em relação às redes tradicionais, que tratam entradas de forma independente.

Figura 11: Arquitetura de RNR




Fonte: Elaborado pelo autor

Uma das limitações significativas das RNRs tradicionais, é o desaparecimento do gradiente. Esse fenômeno dificulta a aprendizagem de dependências de longo prazo, o que é particularmente problemático em aplicações como a previsão de chuvas, onde eventos passados podem influenciar fortemente as condições futuras. Essa limitação ressalta a necessidade de inovações nas arquiteturas de redes neurais, levando ao desenvolvimento de modelos mais

robustos, como LSTM (*Long Short-Term Memory*) e GRU (*Gated Recurrent Unit*). Murphy (2012) e Bishop (2006) destacam essas questões.

As arquiteturas LSTM foram desenvolvidas para contornar as limitações das RNRs tradicionais, permitindo que as redes capturem dependências de longo prazo de maneira mais eficaz. Na Figura 12 tem-se um modelo de Rede Neural recorrente padrão.


Figura 12: Arquitetura RNR padrão



Fonte: <https://medium.com/@web2ajax/redes-neurais-recorrentes-lstm-b90b720dc3f6>

Na Figura 13, tem-se um modelo de LSTM, a principal diferença desta arquitetura é que existem funções internas de memória de curto e de longo prazo, permitindo melhor previsão para os casos em que a temporalidade é importante. Os retângulos na figura, indicam uma função sigmoide, e indica a quantidade de camadas que esta rede possui. Essas camadas, são portas de informação que podem ser lembradas ou esquecidas a medida que o modelo aprende o padrão das informações.

Figura 13: Rede Neural Recorrente do tipo LSTM



Fonte: <https://medium.com/@web2ajax/redes-neurais-recorrentes-lstm-b90b720dc3f6>

A capacidade de lidar com sequências longas e complexas de dados meteorológicos pode resultar em previsões mais confiáveis, o que é vital para a gestão de recursos hídricos e planejamento urbano. As RNRs têm um amplo espectro de aplicações, que vão além da previsão de chuvas. Mas no contexto da meteorologia, a aplicação de RNR pode ajudar na modelagem de fenômenos climáticos complexos, contribuindo para uma melhor compreensão das mudanças climáticas.

2.3. BIM

De forma simplificada, o BIM pode ser definido como a construção de um protótipo digital da realidade, que incorpora diversas informações, tanto físicas, como a geometria, quanto abstratas, como cor, especificação de materiais, tempo de construção, manutenção, custo, entre outras, que podem ser exploradas em várias etapas do ciclo de vida de uma obra de engenharia.

Para Eastman et al. (2014), o BIM é definido como a construção digital de um modelo virtual que reproduz a edificação de forma precisa. Ao ser concluído, o modelo contém a geometria exata e os dados necessários para suportar as diversas etapas da construção, servindo como base para a execução da obra, fabricação e aquisição de insumos. Além disso, o BIM incorpora informações indispensáveis para modelar o ciclo de vida da edificação, permitindo ajustes e melhorias contínuas no gerenciamento dos recursos humanos e técnicos envolvidos no empreendimento. Quando implementado corretamente, o BIM otimiza todo o processo de projeto e construção, resultando na redução de custos e prazos, além de proporcionar maior qualidade.

O BIM, portanto, permite simular uma situação real antes mesmo de o empreendimento ser efetivamente construído, possibilitando antecipar a tomada de decisões e fornecer informações precisas. Kymmell (2008) explora as diferentes dimensões no contexto do BIM: a dimensão 2D refere-se aos planos, a dimensão 3D representa o espaço tridimensional (comprimento, largura e altura), a dimensão 4D adiciona o elemento do tempo (cronograma), a dimensão 5D refere-se a informações de custo, e a dimensão nD abrange outras variáveis, como energia, sustentabilidade e gestão de instalações. Na Figura 14 pode-se ver que as dimensões do BIM apresentam diversas aplicações de maneira didática e prática. Contudo, deve-se tomar o cuidado de perceber que as dimensões não devem se confundir com ciclo de vida, uma vez que essas dimensões permeiam o ciclo de vida de um empreendimento.

Figura 14: As dimensões do BIM

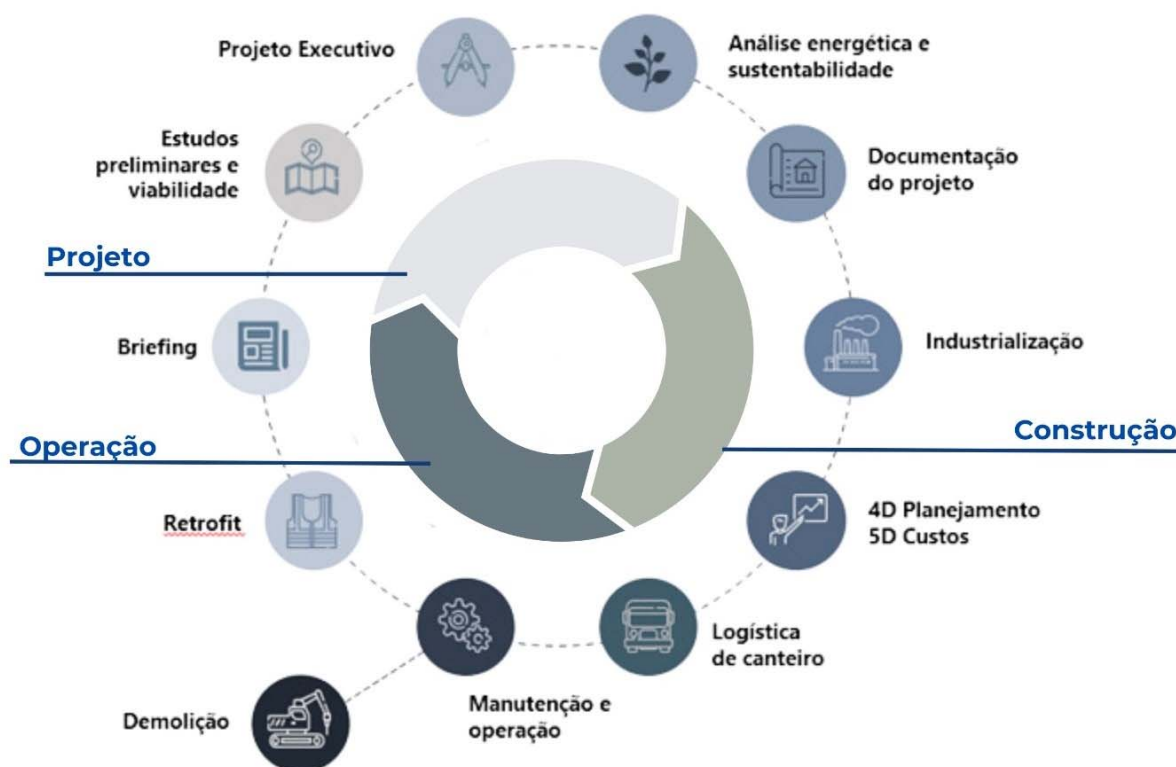


Fonte: Elaborado pelo autor

O BIM se tornou uma tecnologia relevante no setor de infraestrutura. Não se restringe apenas à fase de projeto, mas abrange todo o ciclo de vida das construções, desde a concepção até a demolição. Isso significa que o BIM pode ser utilizado em todas as etapas, incluindo construção, operação e manutenção. As ferramentas BIM permitem que haja troca de informações durante todo o ciclo de vida de um ativo, de forma que as informações de uma etapa anterior ajudem na etapa posterior. (Patacas; Dawod; Kassem, 2020).

O ciclo de vida (Figura 15) de um ativo de infraestrutura é composto por várias fases. O BIM permite a criação de modelos digitais que contêm informações detalhadas sobre cada parte do projeto, o que facilita a tomada de decisões em cada etapa. Segundo Azhar et al. (2021), o uso do BIM pode levar a uma redução significativa nos custos e no tempo de execução, além de melhorar a qualidade do projeto e a colaboração entre as equipes envolvidas.

Figura 15: Ciclo de vida de um ativo



Fonte: Elaborado pelo autor

O BIM oferece uma série de vantagens que vão desde sua excelência técnica e interoperabilidade até a antecipação de informações fundamentais para a construção. Ele acompanha todo o ciclo de vida do empreendimento, integrando aquisições, otimizando o controle de custos, reduzindo conflitos e beneficiando toda a equipe envolvida. Além disso, auxilia na gestão operacional com dados em tempo real, facilitando a manutenção e o gerenciamento de ativos. Outra grande vantagem é sua capacidade de simular e analisar o desempenho energético e ambiental, ajudando a encontrar soluções que reduzam os impactos ambientais das construções. (Ghaffarianhoseini et al., 2017). Isso permite que profissionais explorem diferentes cenários que atendam tanto às necessidades funcionais quanto às preocupações ambientais.

Brandão (2014) evidenciou como a metodologia BIM pode transformar os projetos de infraestrutura viária, apontando seus principais benefícios, especialmente na otimização de processos. Em seu estudo de caso, observou ganhos expressivos de produtividade, melhorias na visualização de modelos 3D e maior precisão nas informações relacionadas, como o levantamento quantitativo de materiais. Contudo, o autor ressalta que o BIM não é uma solução milagrosa, mas sim uma ferramenta estratégica que promove a integração das disciplinas ao longo de todo o ciclo de vida do projeto. Essa integração, além de melhorar a qualidade do trabalho, permite antecipar problemas e minimizar erros, evitando retrabalhos e falhas que poderiam surgir apenas na fase de execução. Assim, o sucesso do BIM está diretamente relacionado à sua aplicação correta e ao alinhamento eficaz entre as equipes envolvidas.

Para Lima (2019), BIM é um facilitador estratégico para a melhoria de tomada de decisões tanto para construções de edificações quanto para obras de infraestrutura. Segundo Eastman et al. (2014), para que um modelo seja considerado BIM, ele deve conter tanto informações geométricas exatas quanto dados relevantes para apoiar todas as fases do ciclo de vida do objeto, desde sua concepção, passando pela construção, operação e manutenção, até o fim de sua vida útil. Para que essas informações possam ser alteradas ao longo do tempo, esses dados devem ser parametrizados, ou seja, não são fixos, mas sim atualizados continuamente durante o ciclo de vida. Isso permite que o modelo seja útil para a gestão e para modificações ao longo do tempo.

Um dos conceitos-chave associados ao BIM é a interoperabilidade, que, segundo Kymmell (2008), refere-se à capacidade de diferentes formatos de arquivo se integrarem e transferirem informações relevantes entre si. Essa interoperabilidade é fundamental para uma comunicação eficaz entre sistemas diferentes, permitindo a colaboração e a troca de dados entre várias aplicações (Eastman et al., 2014). Ela possibilita explorar integrações entre ferramentas para obter um produto mais preciso, ágil e assertivo.

Além das ferramentas convencionais de modelagem de projetos de infraestrutura citadas, existem também ferramentas focadas em análise e previsões, bem como em automação de processos. Dessa forma, ao aplicar o conceito de interoperabilidade, é possível integrar diferentes áreas e funções que se complementem.

No contexto da filosofia BIM, são incluídas ferramentas de programação visual, que serão abordadas a seguir para facilitar a compreensão. Em geral, as ferramentas de programação visual facilitam o acesso dos usuários, permitindo a criação de novas possibilidades no modelo BIM de forma prática. Na perspectiva de NOCERINO e LEONE (2023), as Linguagens de Programação Visual (VPLs), devido à sua alta simplicidade de uso,

permitem que os usuários desenvolvam algoritmos e, assim, implementem seus conhecimentos técnicos com habilidades de programação de computadores, úteis para aprimorar suas ferramentas e mantê-las constantemente atualizadas.

Para Biancardo et al. (2020) o BIM tem demonstrado grande valor para soluções para o setor de engenharia, o BIM tem se expandido para diversos setores, como é o caso de infraestrutura, cuja implementação tem gerado novos desafios. A disponibilidade limitada de componentes e a dificuldade de atribuição de parâmetros as geometrias são consideradas grandes desafios desse setor.

Para Carvalho et al. (2021), o BIM traz um modelo tridimensional com informações associadas, e a programação visual permite aos usuários propor soluções que são quase impossíveis ao utilizar apenas um software de modelagem, exigindo muitas operações. Assim, foi criado um algoritmo para verificar a construtibilidade projetual, a fim de apoiar a tomada de decisão em empreendimentos imobiliários. Extrapolando essa solução para o setor de drenagem, pode-se utilizar os benefícios da construtibilidade em projetos de infraestrutura, mais especificamente em drenagem.

Sena (2019) realizou comparações entre diversos tipos de automação aplicados a projetos, abordando várias linguagens de programação relevantes para o setor de Arquitetura e Construção. As vantagens citadas, como a otimização de arranjos, a criação de formas complexas e a redução de trabalhos repetitivos, reforçam o papel estratégico da automação para alcançar maior eficiência e precisão nos projetos. Neste trabalho, será discutida a lacuna existente em automações voltadas para o setor de infraestrutura, especialmente na área de drenagem com o uso de elementos naturais. Entre as principais vantagens mencionadas por Sena (2019) estão a otimização de arranjos, a criação de formas complexas e a redução de trabalhos repetitivos.


3 METODOLOGIA

A metodologia utilizada, do ponto de vista dos objetivos, será do tipo exploratória, a qual, segundo Gil (2019), na qual envolve pesquisa bibliográfica e estudo de caso. Para este trabalho foi realizado uma revisão da literatura para compreender o estado atual do conhecimento sobre aprendizado de máquina e suas aplicações na modelagem hidrológica, medidas não convencionais de drenagem urbana e a aplicação do BIM nesse contexto. Envolveu também a coleta de dados geoespaciais, hidrológicos e hidráulicos relevantes para a área de estudo, incluindo informações sobre topografia, padrões de chuva e características do solo.

Outro passo é o desenvolvimento de um modelo BIM tridimensional para aplicação da técnica. Posteriormente, serão realizadas simulações hidrológicas e hidráulicas para avaliar o desempenho dessas soluções em diferentes cenários. Os resultados das simulações serão analisados para identificar os benefícios e limitações das medidas não convencionais de drenagem urbana avaliadas com o BIM, considerando aspectos técnicos, econômicos, sociais e ambientais.

Após revisão bibliográfica, foi possível identificar aplicações de *Building Information Modeling* (BIM) em diversos cenários, contudo, existe uma lacuna na aplicação de recursos de modelagem hidrológica por meio de técnicas de aprendizado de máquina associadas a modelos BIM. Tem-se na Figura 16, o fluxograma geral da pesquisa.

Figura 16: Visão macro da pesquisa

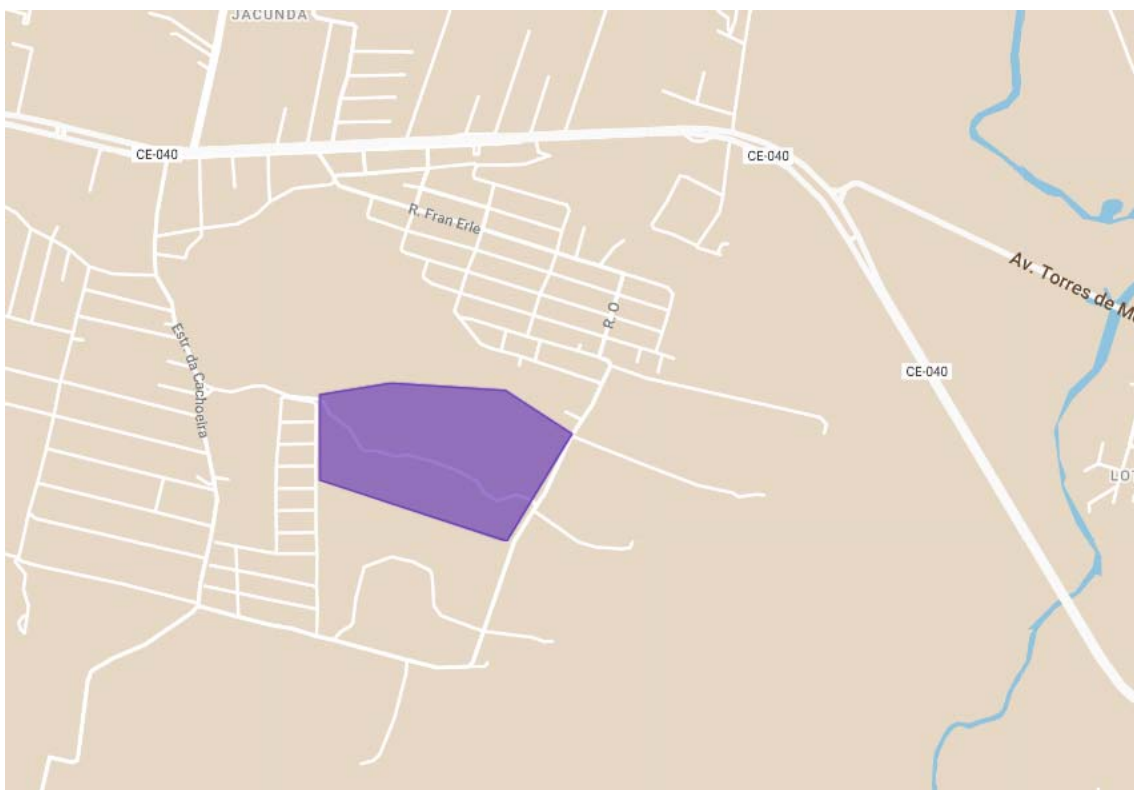


Fonte: elaborado pelo autor

3.1. Área de Estudo

Utilizou-se um terreno localizado no município de Aquiraz-CE conforme mostrado na Figura 17, com área de 30 hectares, onde foi realizado um levantamento topográfico para a obtenção de um modelo digital do terreno. Em seguida, desenvolveu-se um projeto urbanístico, e foram coletadas as características do solo. Com posse dessas informações, deu-se início ao estudo de forma efetiva.

Figura 17: Mapa de localização do terreno.



Fonte: Elaborado pelo autor

3.2. Obtenção dos dados

Foram utilizados dados de chuva extraídos por imagem de satélite.

Figura 18: Site para acesso aos dados de chuva

Select Date Range (UTC) 1998 - 01 - 01 00 : 00 to 2019 - 12 - 31 23 : 59
Valid Range: 1998-01-01 to 2019-12-31

Select Region (Bounding Box or Shape) -38.4415,-3.9276,-38.3763,-3.8723

Number of matching Variables: 12 of 2064 Total Variable(s) included in Plot: 1

Keyword: precipitation Search Clear

| Variable | Units | Source | Temp. Res. | Spat. Res. | Begin Date | End Date | Vert. Slice |
|---|------------------|--------|------------|------------|------------|------------|-------------|
| <input type="checkbox"/> Precipitation Rate (TRMM_3B42_Daily.v7) | mm/day | TRMM | Daily | 0.25 * | 1998-01-01 | 2019-12-31 | - |
| <input type="checkbox"/> Near-Real-Time Precipitation Rate (TRMM_3B42RT.v7) | mm/hr | TRMM | 3-Hourly | 0.25 * | 2003-03-01 | 2019-12-31 | - |
| <input type="checkbox"/> Near-Real-Time Precipitation Rate (TRMM_3B42RT_Daily.v7) | mm/day | TRMM | Daily | 0.25 * | 2000-03-01 | 2019-12-31 | - |
| <input type="checkbox"/> Precipitation (TRMM_3B42.v7) | mm/hr | TRMM | 3-Hourly | 0.25 * | 1997-12-31 | 2019-12-31 | - |
| <input checked="" type="checkbox"/> Precipitation Rate (TRMM_3B43.v7) | mm/hr | TRMM | Monthly | 0.25 * | 1998-01-01 | 2019-12-31 | - |
| <input type="checkbox"/> Surface Convective Precipitation Rate (TRMM_3A12.v7) | mm/hr | TRMM | Monthly | 0.5 * | 1997-12-01 | 2015-03-31 | - |
| <input type="checkbox"/> Graupel (TRMM_3A12.v7) | g/m ³ | TRMM | Monthly | 0.5 * | 1997-12-01 | 2015-03-31 | 0.5 km |
| <input type="checkbox"/> Precipitation (Snow) (TRMM_3A12.v7) | g/m ³ | TRMM | Monthly | 0.5 * | 1997-12-01 | 2015-03-31 | 0.5 km |
| <input type="checkbox"/> Precipitation Rate (TRMM_3A12.v7) | mm/hr | TRMM | Monthly | 0.5 * | 1997-12-01 | 2015-03-31 | - |
| <input type="checkbox"/> Precipitation (Rain) (TRMM_3A12.v7) | g/m ³ | TRMM | Monthly | 0.5 * | 1997-12-01 | 2015-03-31 | 0.5 km |
| <input type="checkbox"/> Rain Rate (TRMM_3A12.v7) | mm/hr | TRMM | Monthly | 0.5 * | 1997-12-01 | 2015-03-31 | - |
| <input type="checkbox"/> Cloud Ice (TRMM_3A12.v7) | g/m ³ | TRMM | Monthly | 0.5 * | 1997-12-01 | 2015-03-31 | 0.5 km |


Privacy Policy Data Policy Accessibility Powered By Contact Us

Reset Plot Data

Fonte: giovanni.gsfc.nasa.gov/

Para a região delimitada por coordenadas no sistema Giovanni da NASA, cujo o polígono de intervenção possui as coordenadas (-38.4415,-3.9276,-38.3763,-3.8723), tem-se os seguintes dados de precipitação mensais, Figura 19.


Figura 19: Dados de chuva mensal extraídos via satélite



Fonte: giovanni.gsfc.nasa.gov/

Na Figura 20, tem-se dados diários, que serão também tratados para na modelagem hidrológica.

Figura 20: Dados diários de chuva extraídos via satélite



Fonte: giovanni.gsfc.nasa.gov/

Para a área de estudo (Figura 21), foi fornecido levantamento topográfico do

terreno, estudos geotécnicos e projeto urbanísticos a fim de estudar as possibilidades de drenagem sustentável.

Figura 21: Vista aérea do objeto de estudo



Fonte: <https://earth.google.com/web/@-3.90546598,-38.41351124>

3.3. Indicadores de desempenho RNR

Os indicadores de desempenho em modelagens computacionais são relevantes para que se tenha parâmetros e faixas de análise dentre eles tem-se, o Erro Absoluto Médio (MAE), Erro Quadrático Médio (RMSE), Coeficiente de Determinação (R^2) e Eficiência de Nash-Sutcliffe (NSE), assim, são fundamentais para avaliar a precisão e a eficácia dos modelos preditivos em prever fenômenos, especialmente no contexto da hidrologia. Esses indicadores fornecem uma visão completa de quão bem o modelo, baseado em *autoencoders* e *LSTM*, está em representando as variações dos dados de entrada e de saída. A seguir, detalha-se cada um deles e discute-se o uso da validação cruzada, uma prática importante para garantir a robustez do modelo.

O Erro Absoluto Médio (MAE) mede a média das diferenças absolutas entre as previsões do modelo e os valores reais, e é comumente expresso na mesma unidade dos dados, o que facilita sua interpretação. No caso de cenários de drenagem, um MAE menor indica que as previsões do modelo estão próximas dos valores reais. Essa métrica é especialmente útil por ser menos sensível a valores discrepantes, oferecendo uma representação direta e intuitiva do erro médio das previsões do modelo (Willmott & Matsuura, 2005).

$$MAE = \left[n^{-1} \sum_{i=1}^n |e_i| \right] \quad (8)$$

O Erro Quadrático Médio (MSE) calcula a média dos quadrados das diferenças entre as previsões e os valores reais. O MSE é mais sensível a grandes erros do que o MAE, uma vez que o erro é elevado ao quadrado, fazendo com que valores discrepantes tenham um impacto mais significativo. Um MSE menor sugere uma melhor performance do modelo, mas, devido ao fato de estar em unidades quadradas, pode ser menos intuitivo que o MAE. No entanto, o MSE é importante porque ele revela se há previsões muito distantes do valor real, o que poderia indicar áreas onde o modelo precisa de ajuste para uma precisão melhor (Chai & Draxler, 2014).

$$MSE = \left[n^{-1} \sum_{i=1}^n |e_i|^2 \right] \quad (9)$$

O Coeficiente de Determinação (R^2) indica a proporção da variância nos dados que é explicada pelo modelo, variando de 0 a 1. Um valor de R^2 mais alto significa que o modelo explica melhor a variabilidade dos dados e está mais ajustado ao padrão observado. Um R^2 próximo a 1 sugere que o modelo consegue capturar de maneira eficaz a variabilidade dos fatores envolvidos, sendo uma métrica relevante para identificar o quanto o modelo representa a realidade dos dados de entrada (Chicco et al., 2021).

$$R^2 = 1 - \frac{[n^{-1} \sum_{i=1}^n |X_i - Y_i|^2]}{[n^{-1} \sum_{i=1}^n |\bar{Y}_i - Y_i|^2]} \quad (10)$$

A Eficiência de Nash-Sutcliffe (NSE) é uma métrica que compara a precisão do modelo com a média dos dados, variando de $-\infty$ a 1. Um NSE de 1 indica que o modelo é perfeito, enquanto um NSE de 0 indica que o modelo não é melhor do que a média dos dados. Valores negativos indicam que o modelo é pior do que utilizar a média simples. No contexto hidrológico, o NSE é amplamente utilizado para avaliar a qualidade de modelos de previsão de escoamento e de séries temporais, pois considera o desempenho do modelo em comparação a um modelo básico, tornando-se uma métrica essencial na validação de modelos para sistemas de drenagem (Moriassi et al., 2007).

$$NSE = 1 - \left[\frac{\sum_{i=1}^n |Y_i^{obs} - Y_i^{sim}|^2}{\sum_{i=1}^n |Y_i^{obs} - Y_i^{med}|^2} \right] \quad (11)$$

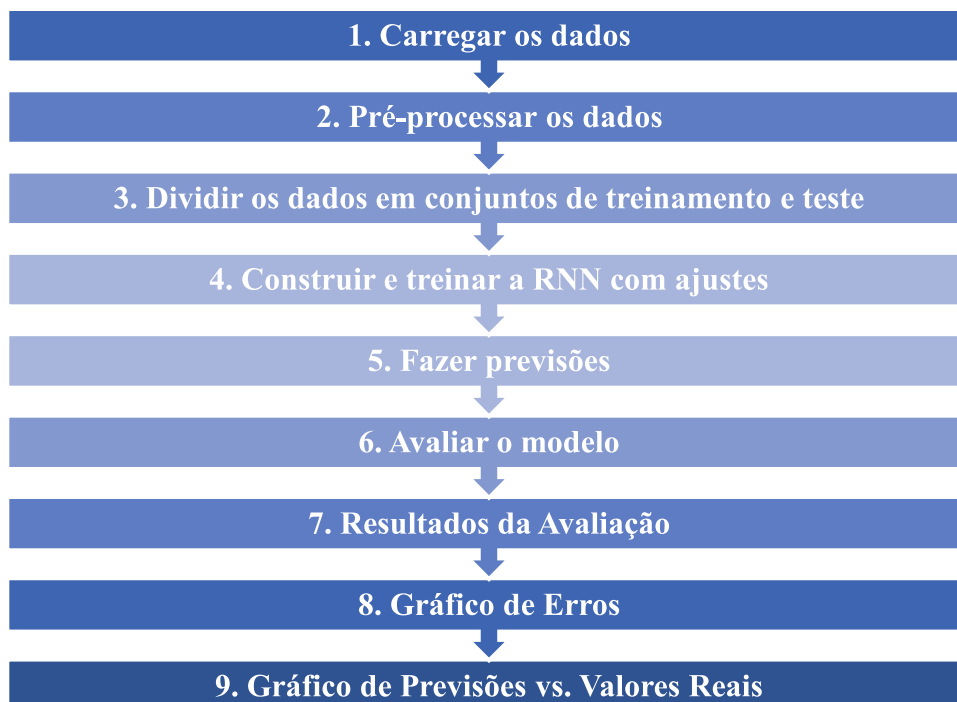
3.4. Método de treino-teste

A validação cruzada é uma técnica importante para avaliar a capacidade de generalização do modelo, especialmente ao trabalhar com dados de entrada de precipitação. Ao dividir os dados em diferentes subconjuntos, o modelo é treinado e testado em múltiplas partições, o que permite estimar o erro de previsão em dados não vistos e evita o sobreajuste (Browne, 2000). Isso é essencial em aprendizado de máquina, pois ajuda a garantir que o modelo não está apenas memorizando os dados de treinamento, mas sim capturando padrões reais que podem ser aplicados em novos conjuntos de dados, como diferentes microbacias de um empreendimento.

3.5. Fluxo do algoritmo desenvolvido

Foi desenvolvido um algoritmo em python com os passos a seguir:

Figura 22: Fluxo do algoritmo em python




Fonte: Elaborado pelo autor

Após a realização deste algoritmo se tem a possibilidade de gerar dados de chuva tanto para preenchimento de dados que faltem, como para previsão de chuva futura. Para a utilização dos dados de precipitação foi utilizados os dados diários máximos e pelo método da desagregação das isozonas foram encontrados os valores para o período de retorno de 20 anos e tempos de concentração de 5min e 60min. Com essas informações parte-se para o desenvolvimento do estudo hidrológico nas ferramentas BIM.

3.6. Fluxo desenvolvido para modelagem BIM

Para a análise dos cenários de dispositivos de drenagem sustentável se faz necessário preparar os dados de entrada. Inicialmente, analisa-se o modelo digital do terreno projetado, em seguida as microbacias do empreendimento são traçadas, bem como informações relacionados a coeficiente de escoamento.

Figura 23: Masterplan do objeto de estudo

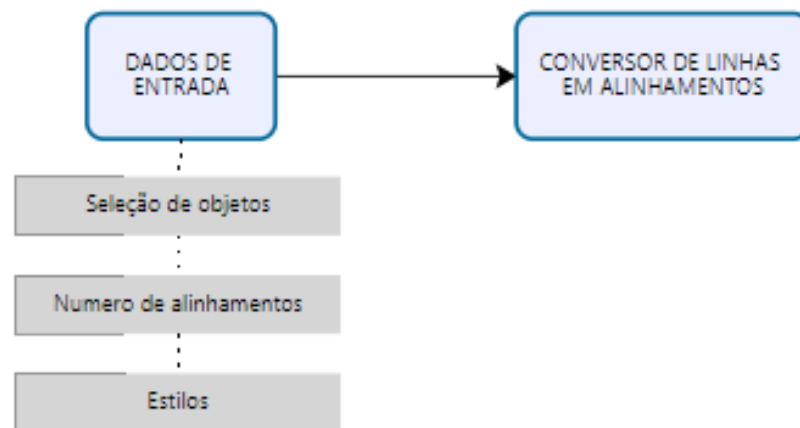


Fonte: Elaborado pelo autor

Para a melhoria do processo de projeto, foram desenvolvidos algoritmos para otimizar a criação de alguns elementos na ferramenta de modelagem de projetos tridimensionais

denominada Civil 3D. Inicialmente, tem-se a criação de alinhamentos em série, que possibilita criar todos os alinhamentos do empreendimento em segundo (Figura 24).

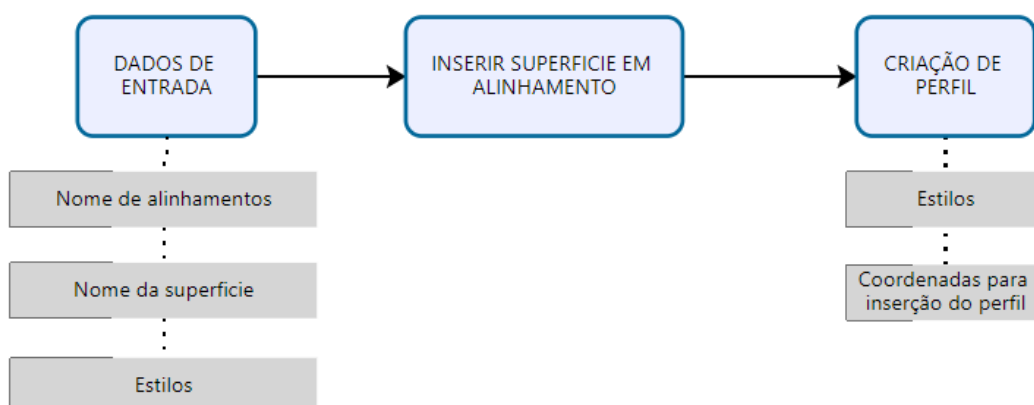
Figura 24 Automação para criação de alinhamentos em série



Fonte: Elaborado pelo autor

Após a criação dos alinhamentos, outro elemento que deve ser criado na modelagem é o perfil. Nele, têm-se as superfícies incluídas em um corte longitudinal na superfície do terreno em cada eixo de alinhamento, o que permite realizar manipulações posteriores e criar superfícies projetadas. Para acompanhar a agilidade na criação dos alinhamentos, segue um algoritmo (Figura 25) para a criação de perfis de forma automática. Nele, é possível listar todos os alinhamentos criados e gerar perfis utilizando a mesma nomenclatura, inserindo neste perfil as superfícies escolhidas.


Figura 25 Automação para criação de perfis



Fonte: Elaborado pelo autor

Após a criação dos perfis, manualmente deve ser traçado o greide projetado conforme Figura 26.

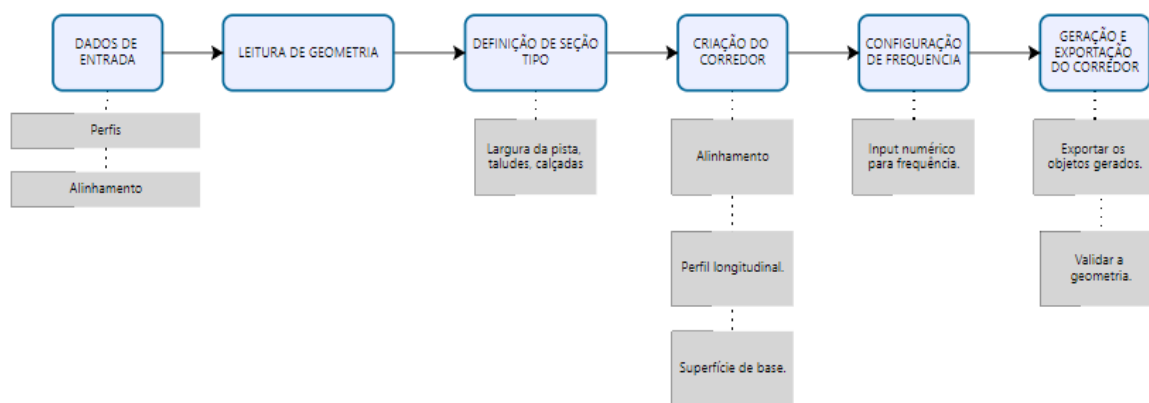
Figura 26 Perfil longitudinal projetado



Fonte: Elaborado pelo autor

Após as criações dos perfis projetados, se faz necessário criar os corredores que são os elementos efetivos da modelagem tridimensional das vias do empreendimento. Para a otimização dos corredores, foi desenvolvido um algoritmo (Figura 27) para a criação automatizada dos corredores selecionados, de posse dos alinhamentos e dos perfis já criados inicialmente.


Figura 27 Algoritmo para criação de corredores



Fonte: Elaborado pelo autor


Na Figura 28 tem-se a modelagem dos corredores efetivos e na Figura 29 tem-se a modelagem final do terreno projetado incluindo os lotes obtido por meio da triangulação dos corredores.

Figura 28 Modelagem dos corredores do empreendimento



Fonte: Elaborado pelo autor


Figura 29 Modelagem tridimensional do terreno projetado



Fonte: Elaborado pelo autor

Após criação do modelo inicial, foram traçadas as bacias de contribuição do empreendimento, mostrada na Figura 30.

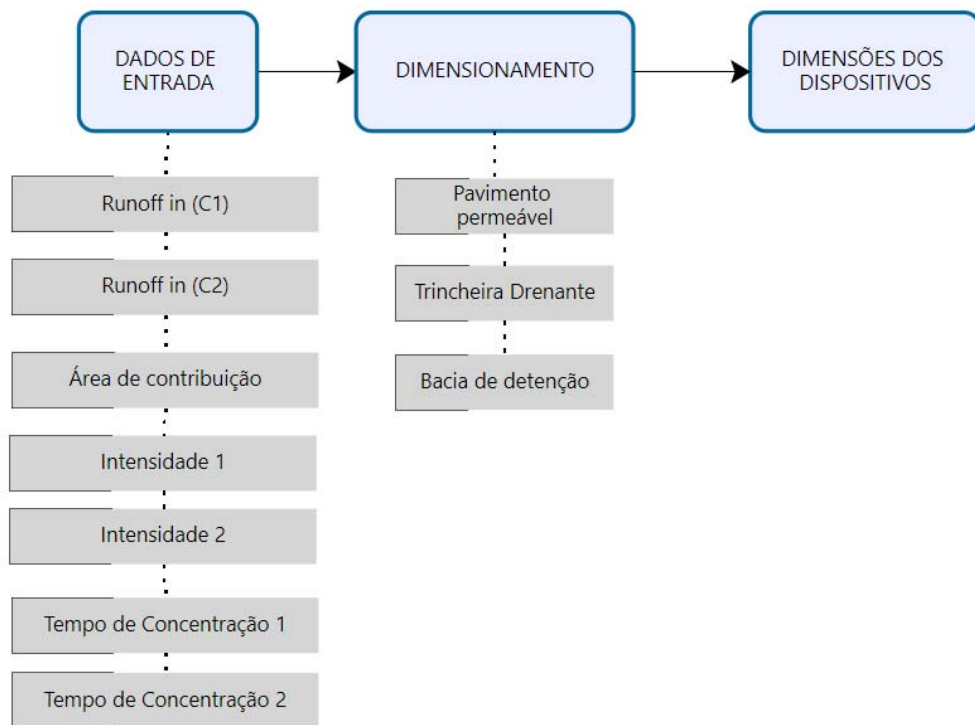
Figura 30 Microbacias de contribuição



Fonte: Elaborado pelo autor

De posse das informações das bacias de contribuição foram feitos dimensionamentos iniciais da capacidade de condução de águas superficiais pela sarjeta. Com isso, pode-se verificar os pontos críticos de drenagem, onde teria pontos de prováveis alagamentos. Assim, com as informações relacionadas ao empreendimento em conjunto com as bacias de contribuição se faz possível fazer verificações de possibilidades de dimensionamento de dispositivos de amortecimento de vazões na fonte. Assim, foi criado um algoritmo para o dimensionamento automatizado de dispositivos de amortecimento de vazões, (Figura 31).

Figura 31 Algoritmo em BIM de dimensionamento de multiplas soluções de drenagem



Fonte: Elaborado pelo autor

Com o uso do algoritmo é possível verificar múltiplas soluções ao mesmo tempo, facilitando no processo de tomada de decisão da solução mais adequada para cada caso.

4 ANÁLISE DOS RESULTADOS

4.1. Redes neurais recorrentes

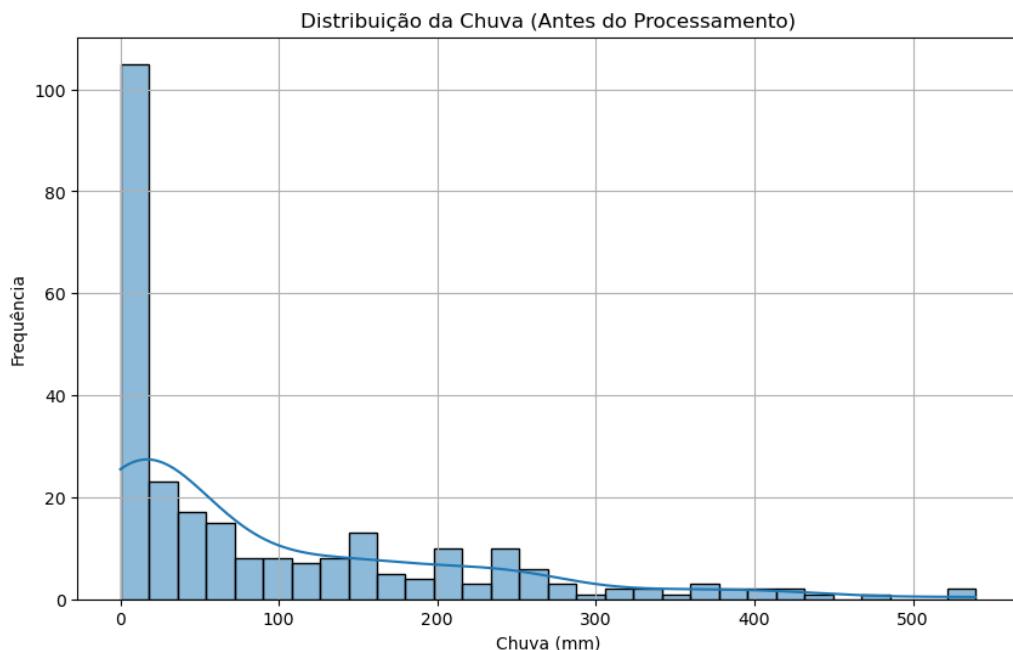
Inicialmente, de posse dos dados de chuva obtidos pelo sítio eletrônico Giovanni, foram feitos o carregamento dos dados via linguagem de programação python. Este código é um modelo de previsão de séries temporais usando uma rede neural LSTM (*Long Short-Term Memory*) para prever a precipitação mensal. Ele utiliza dados históricos de precipitação de um arquivo Excel e segue os seguintes passos:

1. Carregar e preparar os dados:
 - Carregar os dados do arquivo Excel e converter a coluna "Data" em formato *datetime*.
 - Converter a coluna "Chuva" para *float* após trocar vírgulas por pontos.
 - Interpolar os valores ausentes usando a interpolação por tempo.
 - Realizar análises dos dados antes do processamento, como histogramas, boxplots e gráficos de dispersão.
2. Criar conjuntos de dados para o LSTM:
 - Definir a função *create_dataset* para criar conjuntos de dados de entrada (X) e saída (y) para o LSTM.
3. Pré-processamento e normalização:
 - Normalizar os dados usando *MinMaxScaler* com um intervalo de 0 a 1.
4. Divisão entre treino e teste:
 - Dividir os dados normalizados em conjuntos de treino (70%) e teste (30%).
5. Criar datasets para treino e teste:
 - Definir o tamanho do passo de tempo (12 meses) e criar os *datasets* de treino e teste.
6. Criar o modelo LSTM:
 - Criar uma rede neural LSTM com duas camadas LSTM, *Dropout* para prevenir *overfitting* e uma camada de saída densa.
 - Compilar o modelo com o otimizador Adam e a função de perda MSE (*Mean Squared Error*).
7. Treinar o modelo:
 - Treinar o modelo usando os dados de treino.

8. Fazer previsões:
 - Fazer previsões usando os dados de teste.
 - Reverter a normalização das previsões e dos dados de teste.
9. Calcular métricas de avaliação:
 - Calcular as métricas MAE (*Mean Absolute Error*), MSE (*Mean Squared Error*), R^2 (*Coeficiente de Determinação*), Pbias (*Percentual de Bias*) e NSE (*Nash-Sutcliffe Efficiency*).
10. Gráficos de comparação entre dados reais e previsões:
 - Plotar gráficos de comparação entre os dados reais e as previsões.
11. Análise dos dados após o processamento:
 - Realizar análises dos dados após o processamento, como histogramas, boxplots e gráficos de dispersão.
12. Visualizar a tendência da chuva ao longo do tempo:
 - Plotar a tendência da chuva ao longo do tempo, comparando os dados reais e as previsões.
13. Visualizar a correlação entre as variáveis:
 - Plotar um mapa de calor da correlação entre as variáveis do conjunto de dados.

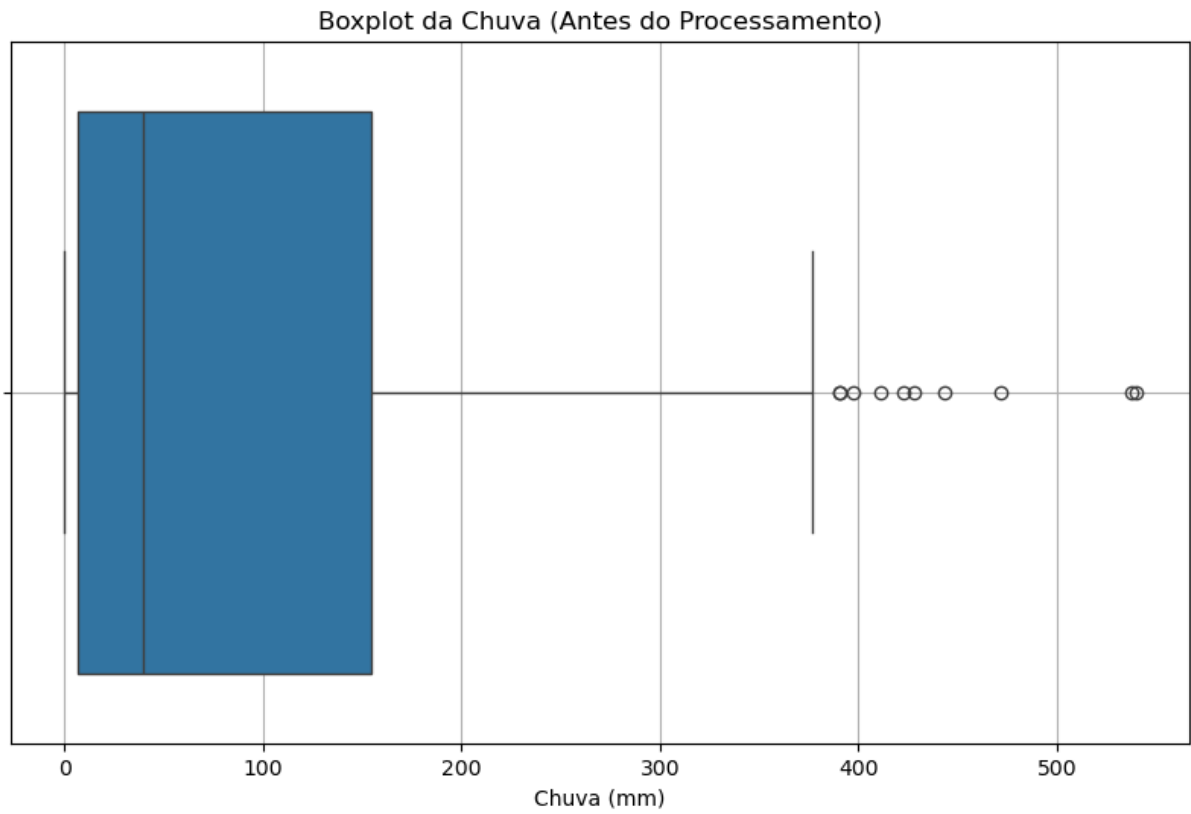
4.1.1. Pré-processamento

Figura 32: Histograma de distribuição de chuva pré-processamento



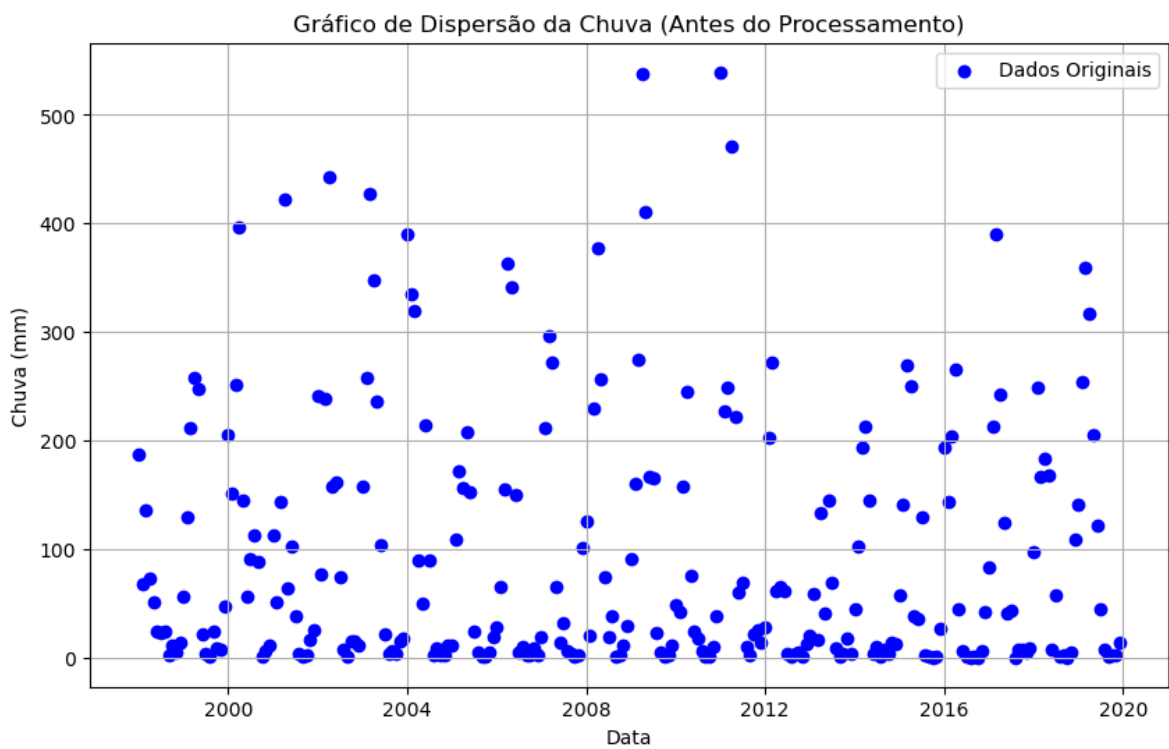
Fonte: Elaborado pelo autor

Figura 33: Boxplot de chuva pré-processamento



Fonte: Elaborado pelo autor

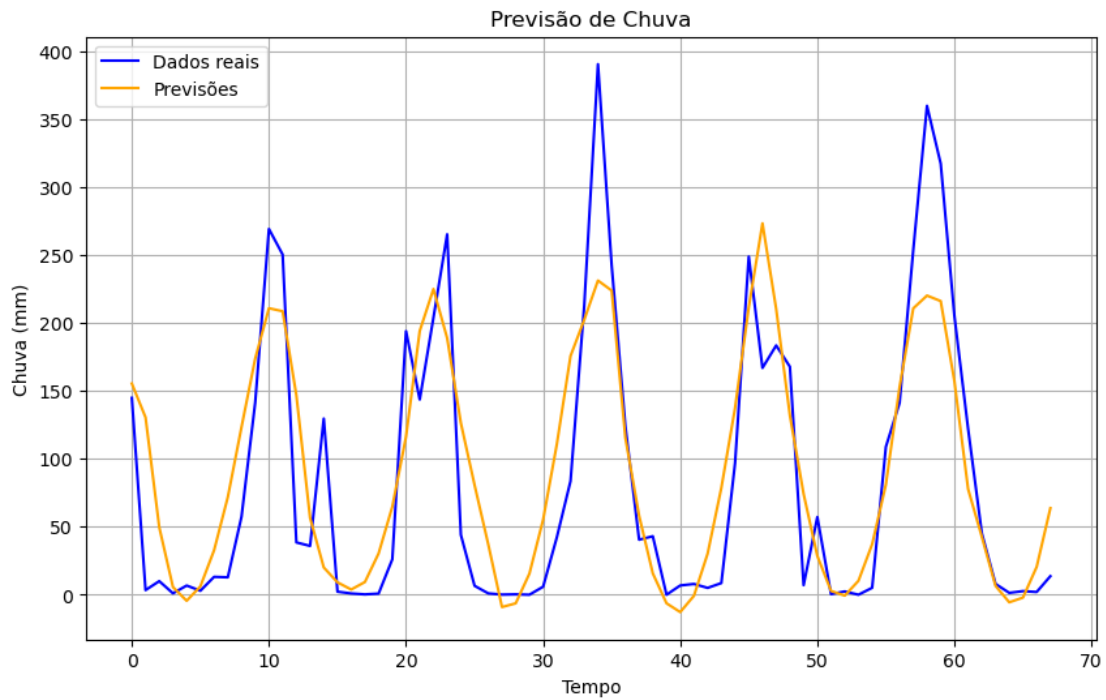
Figura 34: Gráfico de dispersão de chuva pré-processamento



Fonte: Elaborado pelo autor


4.1.2. Pós processamento:

Figura 35: Previsão de chuva x dados reais



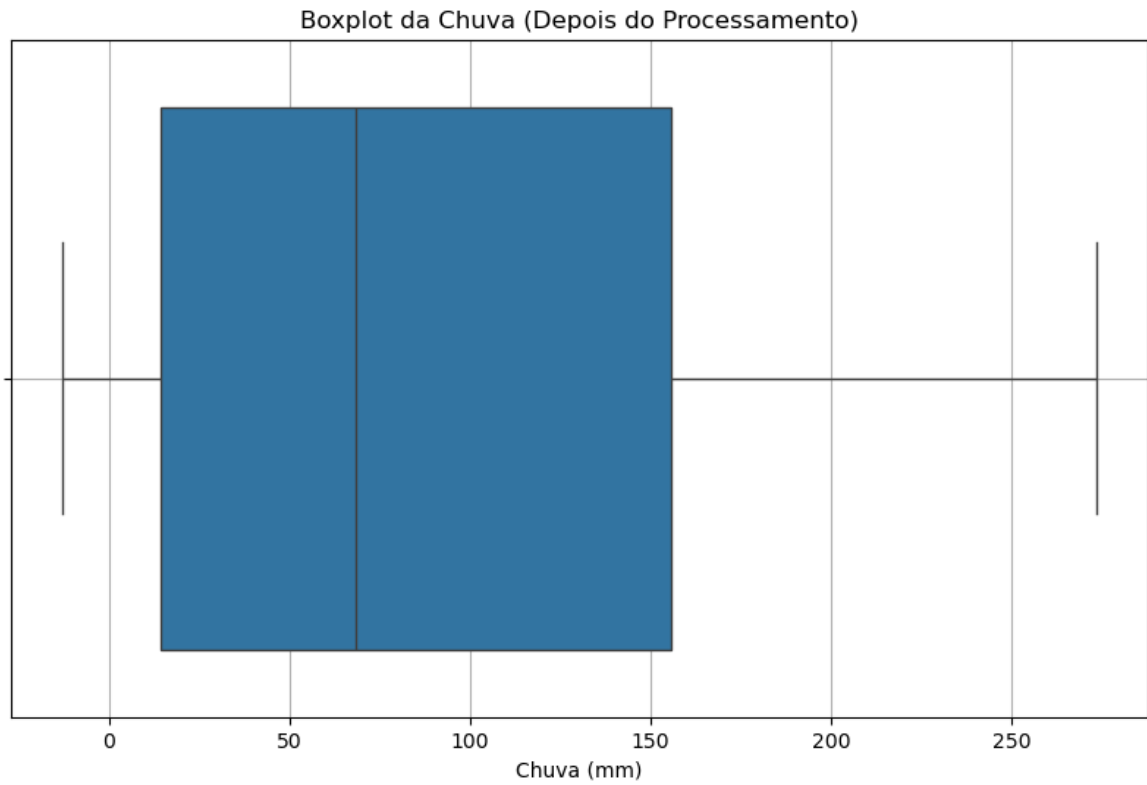
Fonte: Elaborado pelo autor

Figura 36: Histograma de distribuição de chuva pós-processamento



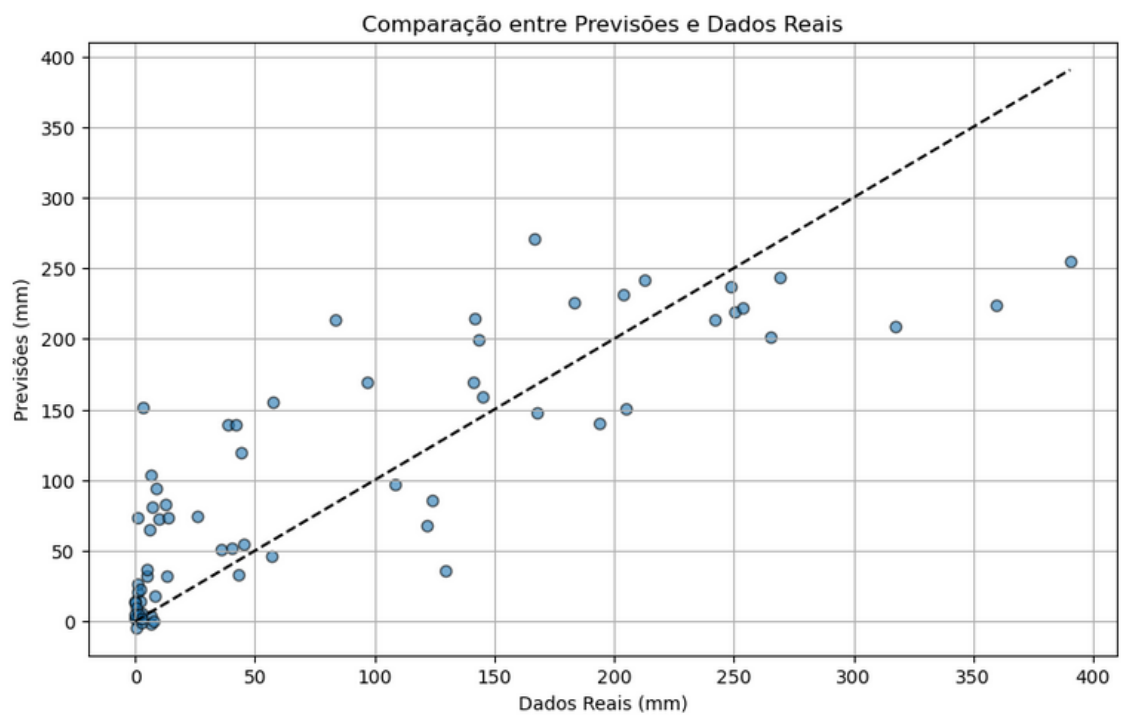
Fonte: Elaborado pelo autor

Figura 37: Boxplot pós-processamento




Fonte: Elaborado pelo autor

Figura 38: Comparação entre dados reais e previsões



Fonte: Elaborado pelo autor

Figura 39: Chuva ao longo do tempo (Modelo x real)



Fonte: Elaborado pelo autor

4.1.3. Indicadores de desempenho

Tabela 1: Indicadores de desempenho

| INDICADORES DE DESEMPENHO DO MODELO | | | |
|--|------------------|---------|-----------------------------------|
| Mean Absolute Error - Erro Absoluto Médio (mm) | MAE: | 40.00 | Enquanto menor melhor |
| Mean Squared Error - Erro Quadrático Médio | MSE: | 2925.90 | Enquanto menor melhor |
| Coefficiente de Determinação | R ² : | 0.72 | Melhor enquanto mais próximo de 1 |
| Percentual de Biais | Pbias: | -6.49% | Melhor enquanto mais próximo de 0 |
| Nash-Sutcliffe Efficiency | NSE: | 0.72 | Melhor enquanto mais próximo de 1 |

Fonte: Elaborado pelo autor

O MAE representa a média das diferenças absolutas entre as previsões do modelo e os valores reais. Um MAE de 40.00 significa que, em média, as previsões do modelo estão a 40 mm de distância dos valores reais. Quanto menor o MAE, melhor é o desempenho do modelo.

O MSE é a média dos quadrados das diferenças entre as previsões e os valores reais. Um MSE de 2925.90 indica que as previsões do modelo têm um erro quadrático médio de 2925.90 mm². O MSE penaliza mais os erros maiores, pois as diferenças são elevadas ao quadrado. Assim, um MSE menor é desejável, pois indica que o modelo está fazendo previsões mais precisas.

O R² mede a proporção da variabilidade nos dados que é explicada pelo modelo. Um R² de 0.72 significa que 72% da variabilidade nos dados de chuva pode ser explicada pelo modelo. Um R² próximo de 1 indica um bom ajuste do modelo aos dados, enquanto um R² próximo de 0 indica que o modelo não explica bem a variabilidade dos dados.

O Pbias indica a tendência do modelo em superestimar ou subestimar os valores reais. Um Pbias de -6.49% sugere que o modelo tende a subestimar a precipitação em cerca de 6.49% em média. Um Pbias próximo de 0% indica que o modelo não tem viés significativo. No caso do resultado encontrado, no contexto de drenagem urbana não são valores recomendados, devido a geração de valores subestimados.

O NSE é uma medida de eficiência que compara a variabilidade das previsões do modelo com a variabilidade dos dados reais. Um NSE de 0.72 indica que o modelo é eficiente e que as previsões são razoavelmente boas em comparação com a média dos dados reais. Um NSE de 1 indica um modelo perfeito, enquanto um NSE menor que 0 indica que o modelo é pior do que simplesmente usar a média dos dados.

Com isso, é possível verificar que o modelo LSTM consegue capturar as variabilidades de forma representativa corroborado pelo NSE, e ainda mostrado no gráfico de tendência de chuva ao longo do tempo com os dados previstos.

4.2. Modelagem BIM

Para a modelagem BIM do empreendimento foi utilizada a ferramenta Civil 3D. Foi realizado um processo manual e um processo automatizado. Para compreender melhor a velocidade foi feitos alguns testes. Para a rotina desenvolvida de criação de alinhamentos temos os seguintes dados:

Tabela 2: Comparativo método manual e método automatizado


| Automático x Manual (Comparativo) | | |
|-----------------------------------|-----------------------|---------------------------|
| Número de alinhamentos | Tempo processo manual | Tempo processo com dynamo |
| 6 | 57 segundos | 12 segundos |
| 12 | 1 min 26 segundos | 12.6 segundos |
| 24 | 2 min 44 segundos | 13.2 segundos |

Fonte: Elaborado pelo autor

Diante do comparativo mostrado na Tabela 2, pode-se ver que o processo automatizado possui maior ganho enquanto maior a quantidade de atividades repetitivas for feita. Partindo deste princípio, o processo automatizado traz ganhos significativos no processo de desenvolvimento de projetos e na antecipação da tomada de decisão.

Seguindo os passos posteriores, com a criação dos perfis e corredores chegamos ao modelo tridimensional projetado (Figura 40)

Figura 40: Modelagem da superfície projetada



Fonte: Elaborado pelo autor

A partir do modelo projetado, tem-se informações suficientes para a verificação das possíveis soluções de drenagem no empreendimento. Na Tabela 3 tem-se os dados de entrada, nesses dados temos algumas peculiaridades a depender do dispositivo a ser dimensionado. Para o pavimento permeável por exemplo, de acordo com a NBR 16416, o tempo de concentração mínimo é de 60 min, o que faz sentido uma vez que no caso do pavimento permeável normalmente se possui grandes áreas de infiltração retardando a velocidade de escoamento das águas pluviais.

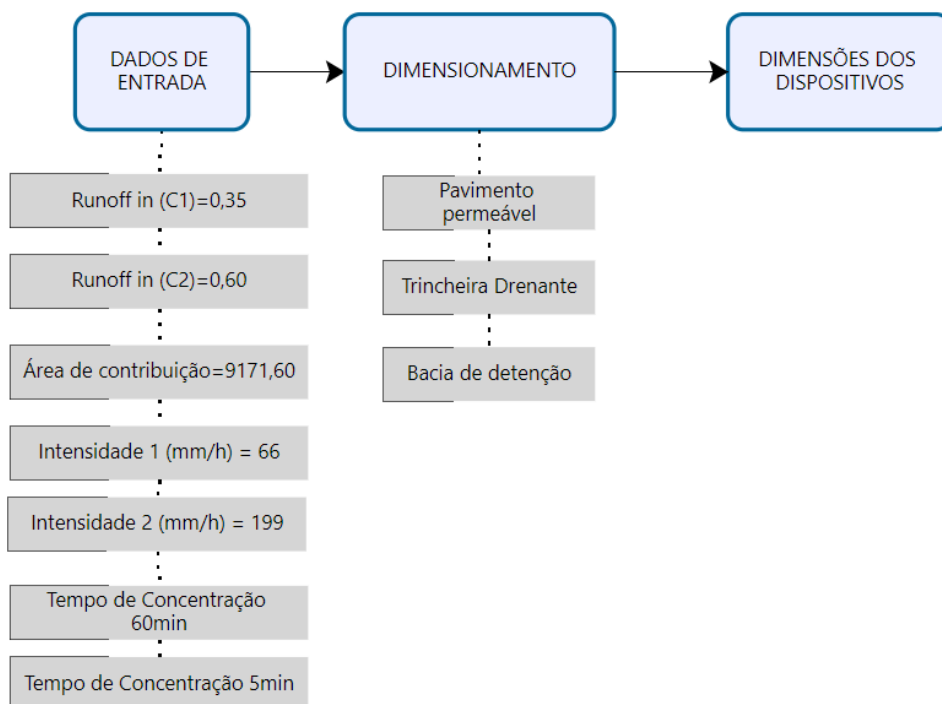
Tabela 3: Dados de entrada

| Dados de Entrada | |
|--------------------------------------|---|
| Runoff in (C1) | 0,35 |
| Runoff in (C2) | 0,60 |
| Área de contribuição | 9171,60 |
| Intensidade (mm/h) (tc=5min) | 66 |
| Intensidade (mm/h) (tc=60min) | 199 |
| Tempo de concentração | 60 min (Pav. Permeável), 5min (Trincheira e Bacia de detenção). |
| Porosidade | 45% |

Fonte: Elaborado pelo autor

Na Figura 41, apresenta-se o algoritmo de programação visual para o dimensionamento de vários dispositivos simultaneamente. A alta velocidade de cálculo da ferramenta possibilita realizar o dimensionamento por meio da inserção de dados de entrada para cada dispositivo. Além disso, a integração com a linguagem Python permitiu a criação de nós customizados para cada aplicação específica.

Figura 41 Rotina de dimensionamento de múltiplas soluções de SUDS



Fonte: Elaborado pelo autor

Na

Tabela 4, são apresentados os resultados do dimensionamento de uma bacia de contribuição e do pavimento correspondente, os quais influenciam diretamente no escoamento das águas pluviais no empreendimento estudado. Entre os dados exibidos, estão o volume dimensionado, as dimensões de cada dispositivo e a área superficial necessária para a implantação. Em empreendimentos dessa tipologia, frequentemente há limitações de espaço, com o objetivo de evitar prejuízos decorrentes da perda de terrenos que inicialmente poderiam ser destinados à venda. Nesse contexto, destaca-se o pavimento permeável, pois pode ser utilizado sem comprometer espaços previamente destinados a outras finalidades.

Tabela 4: Resultados de dimensionamento.

| Dados de Saída | | | |
|---------------------|-------------------------|---------------------|---------------------|
| Dispositivo | Volume (água acumulada) | Dimensões | Área sup. ocupada |
| Bacia de detenção | 43 m ³ | 10m x 4m x 1m | 40m ² |
| Pavimento permeável | 452,25 m ³ | 10m x 150m x 0.67 m | 1.500m ² |

| | | | |
|---------------------|----------------------|-------------------|--------------------|
| Trincheira drenante | 97,20 m ³ | 30m x 6m x 1,20 m | 180 m ² |
|---------------------|----------------------|-------------------|--------------------|

Fonte: Elaborado pelo autor

Além do explorado até aqui, o BIM permite ainda a manipulação geométrica dos elementos, acréscimo e manipulação de informações, simulações dentre outras potencialidades.

5 CONSIDERAÇÕES FINAIS

Esta dissertação teve como objetivo principal desenvolver um fluxo de trabalho integrando o uso do *Building Information Modeling* (BIM), aprendizado de máquina com Redes Neurais Recorrentes (RNR) e dados hidrológicos extraídos de satélites, visando a modelagem hidrológica de sistemas urbanos de drenagem sustentável. Com base nos objetivos estabelecidos, as conclusões são apresentadas a seguir:

A aplicação das RNR mostrou-se com potencial para prever dados hidrológicos, como precipitação, utilizando séries temporais de dados históricos combinados com informações de satélite. Os modelos desenvolveram boas capacidades de captura de padrões temporais e espaciais, contribuindo significativamente para a precisão das previsões, apesar dos melhores indicadores terem sido o NSE e R^2 .

O BIM destacou-se como uma ferramenta essencial para a modelagem e análise de soluções sustentáveis de drenagem urbana. Sua capacidade de integrar informações geométricas, hidrológicas e de desempenho contribuiu para o desenvolvimento de projetos otimizados, permitindo análises detalhadas e visualizações avançadas. Além disso, a interoperabilidade com outros softwares e a centralização de dados consolidam o BIM como um componente estratégico no planejamento urbano sustentável.

A integração das previsões hidrológicas geradas pelas RNR com o ambiente BIM demonstrou ter limitações, pois a ferramenta dynamo de programação visual que faz a interface entre a linguagem python e o modelo tridimensional ainda não possui capacidade de trabalhar com bibliotecas voltadas ao aprendizado de máquina. Por essa razão, a integração de forma automática não foi possível. Contudo, pode-se trabalhar em python e manipular dados via excel e este resultado ser importado para o dynamo a fim de possibilitar a integração entre as ferramentas. Apesar dos avanços, a necessidade de criar padrões de comunicação entre diferentes ferramentas e bases de dados foi identificada como um ponto de aprimoramento.

O fluxo de trabalho automatizado desenvolvido nesta pesquisa mostrou-se funcional, mas com limitações em relação ao uso de redes neurais recorrentes. Contudo as automações desenvolvidas resultaram em maior agilidade no processo de decisão e aumentou a confiabilidade dos resultados ao reduzir a intervenção manual.

O desenvolvimento deste trabalho reforça a importância de combinar tecnologias emergentes e BIM, para enfrentar desafios na gestão de recursos hídricos e no planejamento urbano sustentável. A proposta de integrar previsões hidrológicas com modelagem tridimensional e análise preditiva abre novas perspectivas para o setor de engenharia civil,

promovendo projetos adaptáveis às mudanças climáticas e à urbanização crescente.

Acredita-se que este trabalho contribui para a evolução do conhecimento nas áreas de hidrologia, BIM e aprendizado de máquina, além de estabelecer bases para futuras pesquisas que explorem aplicações práticas dessa integração por outros caminhos, ou ainda, por meio de criação de pacotes que permitam esta integração. Como sugestões de trabalhos a serem desenvolvidos: Criação de um modelo de aprendizado de máquina para integrar variáveis censitárias para previsão de chuvas e vazões com aprendizado de máquina. Modelagem múltiplas de soluções para obras de barragem com BIM e aprendizado de máquina.

REFERÊNCIAS

- BIANCARDO, Salvatore Antonio; CAPANO, Alessandra; GUERRA DE OLIVEIRA, Sara; TIBAUT, Andrej. **Integration of BIM and Procedural Modeling Tools for Road Design**. Infrastructures. Basel, 2020. Disponível em: <https://doi.org/10.3390/infrastructures5040037>. Acesso em: 04 nov. 2024.
- BISHOP, C. M. **Pattern recognition and machine learning**. New York: Springer, 2006.
- BRANDÃO, R. D. A. **Avaliação do uso do BIM para o estudo de obras**. Salvador, 2014. Disponível em: <http://www.gpsustentavel.ufba.br/downloads/BIM%20Infraestrutura.pdf>. Acesso em: 30 out. 2024.
- BROWNE, M. W. **Cross-validation methods**. Journal of Mathematical Psychology. Amsterdã v. 44, n. 1, p. 108-132, 2000. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0022249699912798>. Acesso em: 03 nov. 2024.
- CANHOLI, A. P. **Drenagem urbana e controle de enchentes**. 2. ed. São Paulo: Oficina de Textos, 2005. 302 p.
- CARVALHO, Yan Mota Veras de; OLIMPIO, Luiz Carlos Magalhães; LIMA, Matheus Gomes; LIMA, Mariana Monteiro Xavier de; BARROS NETO, José de Paula. **BIM and Visual Programming Language Supporting Project Constructability**, 29ª Conferência Anual do International Group for Lean Construction (IGLC). Lima, 2021. Disponível em: <https://doi.org/10.24928/2021/0199>. Acesso em: 04 nov. 2024.
- CHAI, T.; DRAXLER, R. R. **Root mean square error (RMSE) or mean absolute error (MAE) – Arguments against avoiding RMSE in the literature**. Geoscientific Model Development. Göttingen, v. 7, p. 1247–1250, 2014. Disponível em: <https://doi.org/10.5194/gmd-7-1247-2014>. Acesso em: 03 nov. 2024.
- CHICCO, D.; WARRENS, M. J.; JURMAN, G. **The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation**. Peer J Computer Science. online, v. 7, e623, 2021. Disponível em: <https://doi.org/10.7717/peerj-cs.623>. Acesso em: 03 nov. 2024.
- EASTMAN, C. et al. **Manual de BIM**. Porto Alegre: Bookman, 2014.
- FERREIRA, Ximena Cardozo. **Sistemas urbanos de drenagem sustentável como meio de controle de inundações**. Revista do Ministério Público do RS. Porto Alegre, n. 90, p. 1-20, jul./dez. 2021. Disponível em: <https://www.revistadomprs.org.br/index.php/amprs/article/view/253>. Acesso em: 03 nov. 2024.
- FLETCHER, T. D. et al. **SUDS, LID, BMPs, WSUD and more – The evolution and application of terminology surrounding urban drainage**. Urban Water Journal. Londres, v. 12, n. 7, p. 525–542, 2014. DOI: 10.1080/1573062X.2014.916314. Acesso em: 03 nov. 2024.
- GARCIA, Fabricio Ribeiro et al. **Regionalização de Vazões de Permanência a partir de Parâmetros Morfométricos da Bacia Hidrográfica do Rio Grande – Bahia**. Revista Brasileira de Geografia Física. Recife, [S. l.], v. 16, n. 5, p. 2420–2434, 2023. DOI: 10.26848/rbgf.v16.5.p2420-2434. Disponível em: <https://periodicos.ufpe.br/revistas/index.php/rbgfe/article/view/257615>. Acesso em: 03 nov. 2024.
- GAVAHI, K.; FOROUMANDI, E.; MORADKHANI, H. **A deep learning-based framework**

for multi-source precipitation fusion. Remote Sensing of Environment. Amsterdã, v. 295, 2023, p. 113723. Disponível em: <https://doi.org/10.1016/j.rse.2023.113723>. Acesso em: 03 nov. 2024.

GHAFFARIANHOSEINI, Ali; TOOKEY, John; GHAFFARIANHOSEINI, Amirhosein; NAISMITH, Nicola; AZHAR, Salman; EFIMOVA, Olia; RAAHEMIFAR, Kaamran. **Building Information Modelling (BIM) uptake: Clear benefits, understanding its implementation, risks and challenges.** Renewable and Sustainable Energy Reviews. Oxford, v. 75, p. 1046-1053, 2017. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032116308413>. Acesso em: 06 nov. 2024.

GIL, Antonio Carlos. **Métodos e técnicas de pesquisa social.** 4. São Paulo: Atlas, 2019.

GRACIOSA, M. C. P.; MEDIONDO, E. M.; CHAUDHRY, F. H. **Metodologia Para Dimensionamento de Trincheiras de Infiltração Para o Controle do Escoamento Superficial na Origem.** Revista Brasileira de Recursos Hídricos. Porto Alegre, v. 13, n. 2, p. 207-214, 2008. Disponível em: <http://dx.doi.org/10.21168/rbrh.v13n2.p207-214>. Acesso em: 06 nov. 2024.

KORUS, K.; CZERNIAWSKI, T.; SALAMAK, M. **Visual programming simulator for producing realistic labeled point clouds from digital infrastructure models.** Automation in Construction. Amsterdã, v. 156, 2023, p. 105126. Disponível em: <https://doi.org/10.1016/j.autcon.2023.105126>. Acesso em: 23 nov. 2024.

KYMMELL, Willem. **Building Information Modeling: Planning and Managing Construction Projects with 4D CAD and Simulations.** New York: McGraw-Hill Construction Series, 2008.

WILLMOTT, C. J.; MATSUURA, K. **Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance.** Climate Research. v. 30, n. 1, p. 79–82, 2005. Disponível em: <http://www.jstor.org/stable/24869236>.

YIN, Hanlin et al. **Rainfall-runoff modeling using long short-term memory based step-sequence framework.** Journal of Hydrology. Amsterdã, v. 610, p. 127901, 2022. ISSN 0022-1694. Disponível em: <https://doi.org/10.1016/j.jhydrol.2022.127901>.

APENDICE A - DADOS DE PRECIPITAÇÃO TRMM

| Data | Precipitação |
|------------|--------------|
| 31/01/1998 | 48,08929 |
| 28/02/1998 | 15,12072 |
| 31/03/1998 | 30,82193 |
| 30/04/1998 | 22,96515 |
| 31/05/1998 | 24,15968 |
| 30/06/1998 | 11,29349 |
| 31/07/1998 | 9,535939 |
| 31/08/1998 | 9,09128 |
| 30/09/1998 | 0,807366 |
| 31/10/1998 | 5,474142 |
| 30/11/1998 | 3,948965 |
| 31/12/1998 | 5,116737 |
| 31/01/1999 | 31,5 |
| 28/02/1999 | 70,64124 |
| 31/03/1999 | 63,92294 |
| 30/04/1999 | 74,54705 |
| 31/05/1999 | 66,83765 |
| 30/06/1999 | 7,801625 |
| 31/07/1999 | 2,203898 |
| 31/08/1999 | 0,422648 |
| 30/09/1999 | 1,35 |
| 31/10/1999 | 4,59205 |
| 30/11/1999 | 2,34 |
| 31/12/1999 | 25,98669 |
| 31/01/2000 | 81,32148 |
| 29/02/2000 | 42,73965 |
| 31/03/2000 | 133,2238 |
| 30/04/2000 | 99,14653 |
| 31/05/2000 | 52,96616 |
| 30/06/2000 | 16,72664 |

| | |
|------------|----------|
| 31/07/2000 | 34,16037 |
| 31/08/2000 | 93,70966 |
| 30/09/2000 | 49,21325 |
| 31/10/2000 | 0,62374 |
| 30/11/2000 | 3,195586 |
| 31/12/2000 | 9,368255 |
| 31/01/2001 | 16,11 |
| 28/02/2001 | 14,30667 |
| 31/03/2001 | 69,48154 |
| 30/04/2001 | 59,68089 |
| 31/05/2001 | 20,07 |
| 30/06/2001 | 17,73 |
| 31/07/2001 | 11,88 |
| 31/08/2001 | 2,577349 |
| 30/09/2001 | 0,970187 |
| 31/10/2001 | 1,26 |
| 30/11/2001 | 7,858388 |
| 31/12/2001 | 6,258819 |
| 31/01/2002 | 50,20233 |
| 28/02/2002 | 27,4037 |
| 31/03/2002 | 55,90407 |
| 30/04/2002 | 99,68781 |
| 31/05/2002 | 37,11121 |
| 30/06/2002 | 59,45726 |
| 31/07/2002 | 55,23279 |
| 31/08/2002 | 3,390126 |
| 30/09/2002 | 0,297739 |
| 31/10/2002 | 2,34 |
| 30/11/2002 | 15,49572 |
| 31/12/2002 | 3,712506 |
| 31/01/2003 | 34,86006 |

| Data | Precipitação |
|-------------|---------------------|
| 28/02/2003 | 80,61906 |
| 31/03/2003 | 107,0072 |
| 30/04/2003 | 99,39626 |
| 31/05/2003 | 98,70757 |
| 30/06/2003 | 34,84212 |
| 31/07/2003 | 16,22642 |
| 31/08/2003 | 0,18 |
| 30/09/2003 | 0,99 |
| 31/10/2003 | 2,330705 |
| 30/11/2003 | 5,13 |
| 31/12/2003 | 5,802858 |
| 31/01/2004 | 85,87795 |
| 29/02/2004 | 77,78484 |
| 31/03/2004 | 142,1984 |
| 30/04/2004 | 41,88962 |
| 31/05/2004 | 37,24912 |
| 30/06/2004 | 96,55122 |
| 31/07/2004 | 69,72958 |
| 31/08/2004 | 1,182064 |
| 30/09/2004 | 1,26 |
| 31/10/2004 | 1,248892 |
| 30/11/2004 | 1,785381 |
| 31/12/2004 | 4,715633 |
| 31/01/2005 | 4,302377 |
| 28/02/2005 | 80,36944 |
| 31/03/2005 | 30,11331 |
| 30/04/2005 | 50,13 |
| 31/05/2005 | 87,39 |
| 30/06/2005 | 59,1529 |
| 31/07/2005 | 8,23937 |
| 31/08/2005 | 2,16 |
| 30/09/2005 | 0,78639 |

| Data | Precipitação |
|-------------|---------------------|
| 31/10/2005 | 0,449466 |
| 30/11/2005 | 1,93145 |
| 31/12/2005 | 7,178371 |
| 31/01/2006 | 18,06477 |
| 28/02/2006 | 38,78371 |
| 31/03/2006 | 34,33819 |
| 30/04/2006 | 59,857 |
| 31/05/2006 | 191,349 |
| 30/06/2006 | 79,25178 |
| 31/07/2006 | 0,9 |
| 31/08/2006 | 3,569283 |
| 30/09/2006 | 0,895514 |
| 31/10/2006 | 0,891312 |
| 30/11/2006 | 3,591885 |
| 31/12/2006 | 0,977737 |
| 31/01/2007 | 5,663179 |
| 28/02/2007 | 128,1928 |
| 31/03/2007 | 112,8791 |
| 30/04/2007 | 113,9994 |
| 31/05/2007 | 30,96 |
| 30/06/2007 | 8,351078 |
| 31/07/2007 | 6,944469 |
| 31/08/2007 | 4,496242 |
| 30/09/2007 | 3,69 |
| 31/10/2007 | 0,590416 |
| 30/11/2007 | 2,32861 |
| 31/12/2007 | 94,01041 |
| 31/01/2008 | 75,50999 |
| 29/02/2008 | 4,139999 |
| 31/03/2008 | 33,73859 |
| 30/04/2008 | 80,59104 |
| 31/05/2008 | 71,19992 |

| Data | Precipitação |
|-------------|---------------------|
| 30/06/2008 | 29,47407 |
| 31/07/2008 | 6,700317 |
| 31/08/2008 | 9,900001 |
| 30/09/2008 | 1,723576 |
| 31/10/2008 | 0 |
| 30/11/2008 | 10,21393 |
| 31/12/2008 | 9,701498 |
| 31/01/2009 | 55,7714 |
| 28/02/2009 | 88,07529 |
| 31/03/2009 | 46,9901 |
| 30/04/2009 | 95,61785 |
| 31/05/2009 | 80,16882 |
| 30/06/2009 | 58,45074 |
| 31/07/2009 | 140,5708 |
| 31/08/2009 | 5,31 |
| 30/09/2009 | 2,202197 |
| 31/10/2009 | 1,274288 |
| 30/11/2009 | 1,982963 |
| 31/12/2009 | 4,485971 |
| 31/01/2010 | 22,95174 |
| 28/02/2010 | 20,87085 |
| 31/03/2010 | 70,46413 |
| 30/04/2010 | 83,21825 |
| 31/05/2010 | 58,68313 |
| 30/06/2010 | 6,75 |
| 31/07/2010 | 11,32429 |
| 31/08/2010 | 2,727499 |
| 30/09/2010 | 1,447342 |
| 31/10/2010 | 2,911463 |
| 30/11/2010 | 2,392983 |
| 31/12/2010 | 15,38482 |
| 31/01/2011 | 174,5869 |

| Data | Precipitação |
|-------------|---------------------|
| 28/02/2011 | 78,57274 |
| 31/03/2011 | 58,72469 |
| 30/04/2011 | 178,3109 |
| 31/05/2011 | 90,47452 |
| 30/06/2011 | 36,89056 |
| 31/07/2011 | 38,27519 |
| 31/08/2011 | 4,695925 |
| 30/09/2011 | 1,808799 |
| 31/10/2011 | 11,85751 |
| 30/11/2011 | 12,74649 |
| 31/12/2011 | 7,022211 |
| 31/01/2012 | 8,298239 |
| 29/02/2012 | 129,8747 |
| 31/03/2012 | 106,619 |
| 30/04/2012 | 34,9484 |
| 31/05/2012 | 49,77199 |
| 30/06/2012 | 45,09588 |
| 31/07/2012 | 1,469032 |
| 31/08/2012 | 0,908459 |
| 30/09/2012 | 2,218573 |
| 31/10/2012 | 2,52 |
| 30/11/2012 | 0,332121 |
| 31/12/2012 | 3,783633 |
| 31/01/2013 | 5,428533 |
| 28/02/2013 | 25,24019 |
| 31/03/2013 | 6,987369 |
| 30/04/2013 | 45,92117 |
| 31/05/2013 | 6,84 |
| 30/06/2013 | 69,46104 |
| 31/07/2013 | 42,35342 |
| 31/08/2013 | 4,232182 |
| 30/09/2013 | 0,558978 |

| Data | Precipitação |
|-------------|---------------------|
| 31/10/2013 | 1,887221 |
| 30/11/2013 | 9,893454 |
| 31/12/2013 | 2,100437 |
| 31/01/2014 | 17,46 |
| 28/02/2014 | 44,03011 |
| 31/03/2014 | 60,7233 |
| 30/04/2014 | 37,45902 |
| 31/05/2014 | 33,66354 |
| 30/06/2014 | 2,957291 |
| 31/07/2014 | 2,629008 |
| 31/08/2014 | 0,396 |
| 30/09/2014 | 1,8 |
| 31/10/2014 | 1,090971 |
| 30/11/2014 | 0 |
| 31/12/2014 | 0 |