

REVISÃO SISTEMÁTICA ACERCA DA APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE INUNDAÇÕES

João Vítor Faustini Sonego¹, Kristian Madeira², Merisandra Côrtes de Mattos³

Resumo: Inundações são um dos desastres naturais mais recorrentes e devastadores. Por isso, a capacidade de poder prevêê-las se torna uma ferramenta para a mitigação de riscos e danos. Esta revisão sistemática teve como objetivo analisar o uso de inteligência artificial aplicada à previsão de inundações. A pesquisa seguiu o protocolo Preferred Reporting Items for Systematic Reviews and Meta-Analyses e analisou 174 artigos das bases Scopus, Web of Science e IEEE Xplore. Os resultados indicam o predomínio de modelos baseados em redes neurais artificiais, especialmente a Memória de Curto e Longo Prazo. Observou-se ainda o uso potencial de modelos híbridos, que apresentaram melhor desempenho e menor erro em relação aos modelos tradicionais. Os estudos apontaram avanços na aplicação de inteligência artificial para sistemas de alerta precoce e gestão de recursos hídricos, embora persistam limitações quanto à qualidade dos dados e à generalização entre diferentes bacias. Conclui-se que a inteligência artificial se consolida como uma ferramenta promissora para aprimorar a acurácia e a aplicabilidade das previsões de inundação, contribuindo para o fortalecimento das políticas públicas de mitigação de desastres.

Palavras-chave: inteligência artificial; aprendizado de máquina; inundações; revisão sistemática.

ABSTRACT: Floods are among the most recurrent and devastating natural disasters. Therefore, the ability to predict them becomes a tool for mitigating risks and damages. This systematic review analyze how Artificial Intelligence is being applied to flood prediction. The study followed the Preferred Reporting Items for Systematic Reviews and Meta-Analyses protocol and examined 174 articles from the Scopus, Web of Science, and IEEE Xplore databases. The results indicate the predominance of neural network-based models, especially Long Short-Term Memory. The potential usweref

¹ Ciência da computação, Grupo de Pesquisa em Inteligência Artificial Aplicada, Universidade do Extremo Sul Catarinense. joao.sonego@unesc.net

² Coorientador. Programa de Pós-Graduação em Sistemas Produtivos, Universidade do Extremo Sul Catarinense. kristian@unesc.net

³ Orientadora. Ciência da computação, Grupo de Pesquisa em Inteligência Artificial Aplicada, Universidade do Extremo Sul Catarinense. mem@unesc.net

ensemble models were also observed, which showed better performance and lower error compared to traditional approaches. The studies highlighted advances in applying AI to early warning systems and water resource management, although limitations remain regarding data quality and model generalization across different basins. It is concluded that AI is consolidating as a promising tool to improve the accuracy and applicability of flood forecasting, contributing to the development of disaster mitigation policies.

Keywords: artificial intelligence; machine learning; flood; systematic review.

1 INTRODUÇÃO

Em 2015, a Organização das Nações Unidas (ONU) lançou a Agenda 2030, que estabelece as metas para o desenvolvimento sustentável em nível global. Composta pelos Objetivos de Desenvolvimento Sustentável (ODS), a agenda define 169 metas agrupadas em 17 objetivos interconectados. Entre esses, o Objetivo 13, que trata do combate às mudanças climáticas e seus impactos, inclui metas como o fortalecimento da resiliência e da capacidade de adaptação a riscos e desastres naturais, bem como a promoção de mecanismos para o planejamento climático e sua gestão eficaz, especialmente em países em desenvolvimento (ONU Brasil, 2024).

Conforme evidenciado pelo *Intergovernmental Panel on Climate Change* (IPCC), o aquecimento global e as mudanças climáticas têm se intensificado principalmente devido ao aumento contínuo das emissões de gases de efeito estufa, como dióxido de carbono, óxido nitroso, metano e ozônio. Consequentemente, a frequência e a gravidade de eventos climáticos que representam riscos à humanidade também vêm aumentando. Projeta-se, portanto, que a ocorrência de desastres naturais se eleve de forma significativa nas próximas décadas (IPCC, 2023).

Entre os desastres naturais, as inundações se destacam como um dos fenômenos que mais causam danos à população mundial. Atualmente, 23% da população global vive em áreas suscetíveis a inundações, ou seja, aproximadamente uma a cada quatro pessoas no mundo está exposta a esse tipo de catástrofe. Ademais, 89% das pessoas expostas a inundações residem em países em desenvolvimento, o que evidencia a relação entre vulnerabilidade socioeconômica e risco de desastres naturais (Rentschler, Salhab & Jafino, 2022).

No Brasil, o estado do Rio Grande do Sul vivenciou, em 2024, uma das piores catástrofes por inundações da sua história. Segundo boletins divulgados pelo

estado, o evento resultou em 183 mortes, mais de 2,3 milhões de pessoas afetadas e 478 municípios impactados diretamente (Rio Grande do Sul, 2024). Além disso, de acordo com a Confederação Nacional de Municípios (2024), o prejuízo econômico ultrapassou R\$ 13,3 bilhões, sendo R\$ 2,6 bilhões do setor público, R\$ 6,0 bilhões do setor privado e R\$ 4,7 bilhões se referem aos prejuízos habitacionais.

Em contraste com esta realidade, medidas eficazes podem ser implementadas para reduzir tanto as perdas econômicas quanto as vidas humanas antes que a catástrofe ocorra. Conforme Zahri et al. (2025), serviços de monitoramento hídrico e meteorológico, aliado à elaboração de planos de aviso prévio e evacuação, é crucial para mitigar estas perdas. No contexto de inundações, a capacidade de poder prevêê-las surge como uma ferramenta fundamental para a gestão de eventos extremos e mitigação de danos (Mosavi, Ozturk & Chau, 2018).

As modelagens hidrológicas tradicionais, que envolvem a simulação de processos físico-matemáticos, fornecem resultados próximos da realidade, mas exigem uma grande quantidade de variáveis e dados, o que torna o processo oneroso e demorado (Piadeh, Behzadian & Alani, 2022). No entanto, essa complexidade pode ser mitigada por meio de abordagens orientadas por dados, utilizando técnicas de Inteligência Artificial (IA), sem comprometer a eficácia dos resultados (Wu et al., 2020).

Para as cidades inteligentes, a IA desempenha um papel essencial em áreas como planejamento urbano, gestão de tráfego, segurança pública e mitigação de desastres naturais (Moreno-Ibarra et al., 2024). Em particular, a adoção de modelos de IA para previsão de inundações em tempo real oferece uma solução acessível e precisa para lidar com esses eventos (Skoubrijs & Hloupis, 2023). Dessa forma, informações críticas estariam disponíveis com menor custo e maior precisão, beneficiando especialmente regiões em desenvolvimento e fortalecendo suas capacidades de resposta a desastres (Randhawa, Mahmood & Ahmad, 2018).

Revisões sistemáticas desempenham um papel fundamental ao sintetizar evidências científicas, ajudando a compreender questões complexas com base em estudos anteriores (Linares-Espinós et al., 2018). Em consonância com essa abordagem, Fernandes, Madeira & Mattos (2025) realizaram uma revisão sistemática da literatura com o objetivo de identificar como a IA tem sido aplicada no enfrentamento da crise climática e na promoção da sustentabilidade. A partir da análise de 94 estudos, os autores citam que os modelos Memória de Curto e Longo Prazo (LSTM) e Floresta Aleatória (RF) se destacam em aplicações voltadas à previsão, análise e otimização, auxiliando na gestão de recursos e tomada de decisão.

O estudo de Maspo et al. (2020) também adota uma abordagem de revisão sistemática, embora sem aplicação de protocolos formais como PRISMA. Os autores realizaram a busca na base Scopus, restringindo-se ao período de 2014 a 2018. Foram analisados 29 artigos, com ênfase nos algoritmos de aprendizado de máquina como Máquina de Vetores de Suporte (SVM), RF, Redes Neurais Artificiais (RNA), K-Vizinhos Mais Próximos (KNN) e *Deep Learning*. O trabalho destaca o uso crescente de modelos híbridos e otimizados para melhorar a acurácia preditiva.

A pesquisa de Aljohani et al. (2023) realiza uma revisão abrangente comparando modelos hidrológicos tradicionais com abordagens orientada a dados. A análise foi complementada com uma abordagem bibliométrica utilizando o software VOSviewer, permitindo a identificação de tendências temporais, principais autores, algoritmos e países com maior produção. O estudo evidencia o crescimento no uso de modelos baseados em dados, como RNA, SVM, Árvores de Decisão (DT) e Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS). O estudo ainda discute algumas limitações, como a escassez de dados e a falta de padronização nas métricas de avaliação.

Hakim et al. (2024) conduziram uma revisão sistemática com foco em mineração de dados aplicada a séries temporais para previsão de inundações, seguindo o protocolo PRISMA 2020 na base Scopus. Os autores classificaram os estudos conforme o tipo de algoritmo, horizonte de previsão (curto ou longo prazo), tipo de entrada de dados e região geográfica, além de discutir amplamente as métricas de avaliação. A revisão ainda revelou a concentração de estudos em países asiáticos, sugerindo a necessidade de ampliação para outras regiões.

No desenvolvimento de uma ferramenta de monitoramento e previsão de inundações em tempo real baseado em aprendizado de máquina, é essencial definir um modelo de IA adequado. Dada a diversidade de algoritmos de IA disponíveis, uma revisão sistemática pode auxiliar na compreensão dos cenários mais apropriados para a aplicação de diferentes modelos. Assim, comparar esses modelos, analisando seu desempenho em variados contextos, é fundamental para identificar a abordagem que melhor se adapta a múltiplas situações.

Mediante o exposto, esta pesquisa tem como objetivo analisar o uso potencial de diferentes modelos de Inteligência Artificial aplicados à previsão de inundações. Permitindo, assim, elencar os modelos de IA aplicados à previsão de inundações, descrever suas aplicações e demonstrar, por meio de uma revisão sistemática, as suas soluções para esta problemática. Sendo assim, este artigo está

organizado em quatro seções: Introdução, Materiais e Métodos, Discussão e Resultados e Conclusão.

2 MATERIAIS E MÉTODOS

Esta pesquisa caracteriza-se, quanto à sua natureza, como uma pesquisa aplicada, pois visa reunir, sistematizar e comparar o uso de modelos de IA na previsão de inundações, podendo contribuir para soluções práticas no contexto da gestão de riscos ambientais de origem hídrica. Em relação aos objetivos, trata-se de uma pesquisa exploratória e descritiva. Exploratória por buscar maior familiaridade com o tema por meio do mapeamento das abordagens já utilizadas, e descritiva por apresentar as características, métodos e resultados dos estudos analisados. Quanto aos procedimentos metodológicos, a pesquisa se caracteriza como qualitativa e foi desenvolvida por meio de uma revisão sistemática da literatura, permitindo identificar os modelos de IA mais empregados, suas aplicações, métricas de avaliação e lacunas existentes na literatura.

A metodologia desta revisão sistemática foi organizada em cinco etapas principais: definição da questão de pesquisa, definição da estratégia de busca, elaboração do universo de artigos, extração de dados e análises. Para garantir a reprodutibilidade do processo, seguiu-se o protocolo *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA), amplamente utilizado por orientar revisões por meio de diretrizes padronizadas que garantem o rigor metodológico em todas as etapas da pesquisa.

2.1 QUESTÃO DE PESQUISA

A revisão sistemática inicia-se pela definição de uma questão de pesquisa estruturada. Para isso, modelos como PICOS⁴, PECOS⁵ e SPIDER⁶ são amplamente utilizados, pois orientam a formulação da pergunta central e contribuem para a

⁴ População, Intervenção, Comparação, Resultados/*Outcome* e Estrutura de Estudo/*Study Design* é um modelo para elaboração de questão de pesquisa de revisões sistemáticas. Amplamente utilizados em estudos voltadas à área da saúde (Paul & Leeflang, 2021).

⁵ População, Exposição, Comparação, Desfecho/*Outcome* e Estrutura do estudo/*Study design* é uma adaptação do modelo PICOS substituindo o termo Intervenção por Exposição.

⁶ Amostra, Fenômeno de Interesse, Desenho de Estudo, Avaliação e Tipo de Pesquisa (*Sample, Phenomenon of Interest, Design, Evaluation e Research type*). Geralmente utilizado em revisões que buscam sintetizar evidências relacionadas a experiências, percepções, atitudes e fenômenos sociais ou comportamentais (Amir-Behghadami, 2021).

definição dos critérios de inclusão e exclusão, das estratégias de busca, da extração de dados e da avaliação da qualidade dos estudos (Linares-Espinós et al., 2018).

Neste estudo, adotou-se o modelo PECOS por ser mais indicado para estudos que buscam investigar fatores ambientais, comportamentais ou clínicos (Paul & Leeflang, 2021). Sendo assim, a aplicação do modelo na presente pesquisa foi estruturada da seguinte forma:

- a) População (P): áreas expostas a risco de inundações;
- b) Exposição (E): uso de algoritmos/modelos de IA;
- c) Comparação (C): outros métodos (modelos hidrológicos tradicionais, sem IA, ou diferentes algoritmos de IA);
- d) Desfecho/*Outcome* (O): acurácia e aplicabilidade na previsão de inundações;
- e) Estrutura do estudo/*Study design* (S): estudos de modelagem ou de aplicações em campo.

Com isso, elaborou-se a seguinte questão de pesquisa: Em áreas expostas a risco de inundações (P), o uso de algoritmos e modelos de Inteligência Artificial (E), comparado a modelos hidrológicos tradicionais ou a diferentes algoritmos de IA (C), apresenta melhor acurácia e aplicabilidade na previsão de inundações (O), considerando estudos de modelagem ou de aplicações em campo (S)?

2.2 ESTRATÉGIA DE BUSCA

A estratégia de busca foi estruturada com base em três blocos (fenômeno, técnica e escopo) definidos a partir da questão de pesquisa. Para cada um, foram selecionados conjuntos de palavras-chave em inglês que melhor representassem seus respectivos conceitos:

- a) Fenômeno – inundações: *flood prediction, flood forecasting, flood modeling e risk of flood*;
- b) Técnica – inteligência artificial: *artificial intelligence* e AI;
- c) Escopo – população e estrutura de estudo: *watershed, river basin e hydrology*.

Ao final, os termos foram organizados e combinados por meio de operadores booleanos, resultando na seguinte expressão de busca: (“*flood**”) AND (“*risk*” OR “*forecast**” OR “*model**” OR “*predict**”) AND (“*artificial intelligence*” OR “AI”) AND (“*hydrology*” OR “*watershed*” OR “*basin*” OR “*river*”).

Esta estratégia foi aplicada nas bases científicas Scopus, Web of Science e IEEE Xplore, reconhecidas pela relevância nas áreas ambiental e tecnológica, sendo a busca realizada em 26 de setembro de 2025. Ainda, utilizou-se um filtro de data para artigos publicados na última década (2015 a 2025), devido ao crescimento das aplicações de IA em modelagem ambiental neste período. Além disso, os filtros de pesquisa foram configurados para restringir a busca aos títulos, resumos e palavras-chave dos artigos, de modo a garantir maior precisão e relevância nos resultados.

2.3 UNIVERSO DE ARTIGOS

A elaboração do universo de artigos foi conduzida por meio de uma triagem composta por três etapas principais: remoção de duplicatas, leitura de títulos e resumos e leitura dos artigos na íntegra. Durante as etapas de leitura, aplicaram-se os critérios de inclusão e exclusão, definidos previamente com base na questão de pesquisa. O Quadro 1 apresenta detalhadamente os critérios adotados para a seleção dos estudos nesta revisão.

Quadro 1 - Critérios de inclusão e exclusão

 INCLUSÃO	 EXCLUSÃO
Estudo aplicado em áreas expostas a risco de inundação	Não aplica em áreas suscetíveis a inundações
Aborda previsão ou modelagem de inundações	Não trata de previsão de inundações
Utiliza técnicas de Inteligência Artificial, aprendizado de máquina ou aprendizado profundo	Usa apenas modelos físicos, estatísticos ou hidrológicos tradicionais, sem IA
Avalia e/ou compara desempenho, acurácia ou aplicabilidade do modelo	Trata de gestão, mapeamento, percepção de risco ou políticas públicas, sem foco em previsão ou modelagem
É um estudo empírico (simulação, modelagem ou caso aplicado).	É revisão de literatura, artigo de opinião ou descritivo

Fonte: Elaborado pelo autor.


Como resultado da aplicação da estratégia de busca, foram inicialmente identificados 1.104 artigos, que compuseram o universo inicial de artigos. As informações de identificação e os resumos dos artigos foram exportadas em formato *Research Information Systems* (RIS) e importadas para a ferramenta Rayyan⁷, utilizada para remoção de duplicatas, leitura dos resumos e triagem dos artigos. Por

⁷ Rayyan é uma ferramenta online para revisões sistemáticas. Ela permite importar referências de bases de dados e auxilia no processo de triagem e elaboração do universo de artigos (<https://www.rayyan.ai/>).

meio dessa ferramenta, foram removidos 281 artigos por duplicidade, resultando em 823 artigos incluídos para a próxima etapa de triagem.

Em seguida, a leitura dos títulos e resumos foi conduzida por dois revisores independentes, enquanto um terceiro revisor ficou responsável por resolver eventuais divergências de classificação. Nessa etapa, 571 artigos foram excluídos, sendo 2 por não abordarem áreas suscetíveis a inundação, 234 por não tratarem da previsão de inundações, 14 por não considerarem o uso de IA na modelagem preditiva, 228 por focarem em gestão, mapeamento ou análises não preditivas, e 93 por se tratar de revisões, artigos de opinião ou descritivos. Ao final dessa etapa, 252 artigos foram selecionados para leitura na íntegra.

Antes do início da leitura na íntegra, os artigos incluídos foram coletados e armazenados em formato PDF. Estudos que não foram disponibilizados na íntegra via *open access* ou acesso institucional foram excluídos. Ainda, considerou-se apenas artigos redigidos em português, inglês, espanhol e francês. Em seguida, procedeu-se à leitura integral dos textos, aplicando novamente os critérios de inclusão e exclusão.



Fonte: Adaptado de PRISMA 2020⁸.

Ao final desta etapa, foram excluídos 78 artigos, sendo 3 por não abordarem áreas suscetíveis a inundação, 5 por não tratarem da previsão de

⁸ Fluxograma original disponível em: <https://www.prisma-statement.org/>

inundações, 2 por não considerarem o uso de IA na modelagem preditiva, 28 por focarem em gestão, mapeamento ou análises não preditivas e 5 por se tratar de revisões, artigos de opinião ou descritivos. Além destes, 8 foram excluídos por estarem redigidos em outros idiomas e 27 devido à indisponibilidade de acesso.

O universo final de artigos foi composto por 174 estudos incluídos após o término da leitura na íntegra. Esses trabalhos foram então submetidos às etapas de extração de dados e de análise e síntese dos resultados. A Figura 1a apresenta o fluxograma completo, conforme o protocolo PRISMA, dos artigos incluídos. A Figura 1b apresenta o resumo quantitativo das etapas de triagem, destacando o número de artigos incluídos em cada fase do processo.

2.4 EXTRAÇÃO DE DADOS

A extração de dados foi realizada em todos os artigos incluídos no universo final, de forma padronizada e sistemática. As informações foram organizadas em uma planilha contendo 27 colunas, agrupadas em sete blocos principais, conforme descrito a seguir:

- a) Identificação: título completo do artigo, autores, ano de publicação, nome de revista/conferência/base de publicação, classificação do tipo de estudo, idioma principal, DOI;
- b) Modelagem: modelos/algoritmos de IA utilizados na previsão de inundação, modelos comparativos (hidrológicos tradicionais ou outros modelos de IA), *frameworks* ou ferramentas empregadas, tipo de dado utilizado na previsão;
- c) Avaliação: métricas utilizadas para avaliar o modelo de IA adotado, método de validação do modelo, síntese dos resultados comparativos entre modelos;
- d) Contexto: local ou bacia hidrográfica onde o estudo foi aplicado, país de aplicação, tipo do ambiente analisado;
- e) Dados: parâmetros utilizados como entrada na previsão de inundação, fonte dos dados utilizados, resolução/período dos dados, parâmetro utilizado para indicar a ocorrência de inundação;
- f) Resultados: síntese dos principais achados, limitações relatadas pelos autores, sugestões futuras;

- g) Qualidade: aplicabilidade do modelo, grau de reprodutibilidade do estudo, risco de viés.

A organização estruturada das informações possibilitou a análise comparativa entre os estudos, permitindo identificar padrões metodológicos, tendências de aplicação e lacunas na literatura.

2.4.1 Risco de Viés

A avaliação do risco de viés dos estudos incluídos nesta revisão sistemática foi conduzida de forma qualitativa e adaptada ao contexto de modelagem hidrológica e uso de Inteligência Artificial. O procedimento seguiu princípios das diretrizes do Joanna Briggs Institute (JBI, 2025), considerando aspectos de robustez dos dados, estratégia de validação, comparabilidade, transparência e tratamento da incerteza.

Cada artigo foi classificado como de baixo, médio ou alto risco de viés, com base na qualidade metodológica e na confiabilidade das evidências apresentadas. A classificação foi atribuída a partir da leitura integral dos estudos e justificada individualmente, registrando-se os motivos específicos em planilha própria.

Estudos foram considerados de baixo risco quando apresentavam bases de dados extensas e representativas, utilização de validação cruzada ou externa, múltiplas métricas de desempenho e descrição metodológica detalhada e reprodutível. Foram classificados como de médio risco aqueles que se restringiam a estudos de caso únicos, apresentavam bases de dados limitadas ou ausência de validação externa, ainda que mantivessem coerência metodológica. Por fim, estudos de alto risco foram caracterizados por ausência de validação, insuficiência de dados ou metodologia não replicável.

2.5 ANÁLISE DOS DADOS

A análise dos dados foi conduzida de acordo com o tipo de variável coletada durante a extração, respeitando a natureza das informações e as diretrizes do protocolo PRISMA. Dessa forma, a síntese dos resultados foi desenvolvida de forma descritiva e integrativa, com o objetivo de reunir, comparar e interpretar as evidências obtidas nos estudos incluídos.

Os dados categóricos (por exemplo, país, algoritmo utilizado, métricas de avaliação) foram analisados por meio de estatísticas descritivas, com cálculo de

frequência absoluta e relativa (%). Os resultados foram apresentados em tabelas e gráficos, possibilitando visualizar a distribuição e representatividade das variáveis.

Os dados textuais curtos, como as aplicações práticas dos modelos, foram explorados por análises de frequência de termos, com contagem e agrupamento das palavras mais recorrentes. Para representação visual, foi gerada uma nuvem de palavras, permitindo identificar os conceitos predominantes.

Por fim, os dados textuais longos (principais achados, limitações e sugestões) foram submetidos a análise temática, envolvendo leitura interpretativa, categorização e agrupamento dos temas semelhantes. As análises resultantes foram sintetizadas em categorias interpretativas, permitindo discutir as contribuições e limitações mais recorrentes entre os estudos revisados, os quais são apresentados na seção de resultados e discussão.

3 RESULTADOS E DISCUSSÃO

Os dados extraídos dos 174 artigos incluídos foram organizados em uma planilha⁹, sintetizados em blocos temáticos e dispostos em apêndices. Sendo assim, os resultados e suas discussões são apresentados na seguinte estrutura: Identificação (Apêndice A), Modelagem (Apêndice B), Avaliação (Apêndice C), Contexto (Apêndice D), Dados (Apêndice E), Resultados (Apêndice F) e Qualidade (Apêndice G).

3.1 IDENTIFICAÇÃO

Este conjunto de dados abrange variáveis como ano de publicação, autores, periódicos, idiomas e tipo de estudo. Desta forma, é possível identificar a evolução temporal de publicações acerca do uso de IA na previsão de inundações (Figura 2). Observa-se um crescimento expressivo no número de artigos em 2020 e 2023, mantendo tendência de crescimento ao longo da década. Estes dados fornecem um panorama do avanço das pesquisas e da evolução do interesse acadêmico sobre o tema ao longo da última década. Ressalta-se, ainda, que o número de publicações de 2025 se refere apenas ao período até 26 de setembro, não representando o ano completo.

Além disso, foi possível identificar os principais periódicos e bases com maior número de publicações sobre o tema (Tabela 1). Os mais recorrentes foram

⁹ A planilha pode ser consultada em formato digital pelo [link](#).

IEEE Access (14 – 8,0%), *Journal of Hydrology* (13 – 7,5%), *Water* (12 – 6,9%), *Water Resources Management* (5 – 2,9%), *Earth Science Informatics* (4 – 2,3%) e *Modeling Earth Systems and Environment* (4 – 2,3%). Outras 99 fontes apresentaram menos de quatro registros cada, evidenciando a dispersão das publicações sobre o tema.

Figura 2 - Quantidade de artigos por ano



Fonte: Elaborado pelo autor.

Tabela 1 - Relação de fontes de publicação

Revista	Quantidade	%Total
IEEE Access	14	8,0%
Journal of Hydrology	13	7,5%
Water	12	6,9%
Water Resources Management	5	2,9%
Earth Science Informatics	4	2,3%
Modeling Earth Systems and Environment	4	2,3%
Outras (99 revistas)	122	70,1%

Fonte: Elaborado pelo autor.


3.2 MODELAGEM

O bloco de modelagem permitiu analisar informações referentes aos modelos de IA mais empregados, aos modelos comparativos, aos *frameworks* e ferramentas utilizados, bem como os tipos de dados aplicados. Observou-se que o modelo mais recorrente foi o LSTM, citado em 54 artigos. Outros que apresentaram uma maior frequência foram RNA (31), SVM (23), RF (22) e *Perceptron* Multicamadas (MLP) com 21. A Figura 3 apresenta os modelos mencionados em pelo menos cinco estudos, enquanto os demais 92 algoritmos foram agrupados na categoria “Outros”, por apresentarem menor representatividade na amostra.

A análise dos resultados evidenciou que os algoritmos baseados em redes neurais recorrentes, especialmente o LSTM, destacaram-se na aplicabilidade para previsão de inundações. Isso está em consonância com Fernandes, Madeira & Mattos

(2025), que ressaltam o uso do LSTM em previsões meteorológicas e ambientais, e com Hakim et al. (2024), que destacam sua popularidade e robustez na modelagem de eventos hidrológicos extremos.


Figura 3 - Modelos de IA mais citados



Fonte: Elaborado pelo autor.

Em contrapartida, Aljohani et al. (2023) e Maspo et al. (2020) apontam as redes neurais artificiais convencionais (RNA) como os modelos mais empregados, sem mencionar o uso do LSTM. Essa variação entre estudos sugere a evolução dos diferentes algoritmos de IA e que novos modelos surgem à medida que a disponibilidade de dados e capacidade computacional evoluem.

Figura 4 - Tipos dos dados e algoritmos de comparação
(a) Algoritmos de comparação (b) Tipos dos dados



Fonte: Elaborado pelo autor.

Além disso, os modelos identificados foram comparados a outros métodos em diferentes contextos: 108 estudos realizaram comparações exclusivamente entre

algoritmos de Inteligência Artificial, em 24 com modelos hidrológicos tradicionais (modelos físico-matemáticos) e 27 combinaram ambas as abordagens (Figura 4a). Quanto aos ambientes de desenvolvimento, os frameworks e ferramentas mais recorrentes foram Python (51), MATLAB (39) e TensorFlow (35). Em relação aos tipos de dados utilizados (Figura 4b), predominam os hidrológicos (170), seguidos pelos meteorológicos (114) e pluviométricos (51).

3.3 AVALIAÇÃO

A análise das métricas de avaliação revelou o predomínio de indicadores baseados em erro e correlação. O Erro Quadrático Médio (RMSE) foi a métrica mais empregada, presente em 120 estudos, seguida pela Eficiência de Nash-Sutcliffe (NSE) em 79, Erro Absoluto Médio (MAE) em 73 e Coeficiente de Determinação (R^2) em 67. Esses resultados (Tabela 2a) evidenciam a preferência por medidas consolidadas na literatura hidrológica e corroboram com os achados de Hakim et al. (2024) e Aljohani et al. (2023), que apontam o uso de RMSE como uma das métricas mais adequada para avaliação de modelos de IA aplicados à previsão de inundações.

A maioria dos estudos utilizou validação simples por divisão treino-teste (124 casos), enquanto abordagens mais robustas, como treino/validação/teste (29) e validação cruzada *k-fold* (18), foram menos frequentes (Tabela 2b).

Tabela 2 - Resultados da métricas e métodos de validação
(a) Métricas (b) Validação


Métrica	Quantidade	% Total	%Artigos	Validação	Quantidade	%Total	%Artigos
RMSE	120	18,5%	69,0%	Treino/Teste	124	72,5%	71,3%
NSE	79	12,2%	45,4%	Treino/Validação/Teste	29	17,0%	16,7%
MAE	73	11,2%	42,0%	k-Fold	18	10,5%	10,3%
R^2	67	10,3%	38,5%				
R	35	5,4%	20,1%				
MSE	28	4,3%	16,1%				
MAPE	23	3,5%	13,2%				
Accuracy	12	1,8%	6,9%				
KGE	12	1,8%	6,9%				
F1-Score	11	1,7%	6,3%				

Fonte: Elaborado pelo autor.

As comparações entre os modelos de Inteligência Artificial aplicados de forma isolada (*standalone*) revelaram ampla diversidade de abordagens e desempenhos. O LSTM destacou-se como o algoritmo mais recorrente entre os melhores resultados, sendo identificado como o de maior desempenho em 17 estudos, seguido por RNA (9), RF (7) e MLP (4). A Figura 5 apresenta os modelos de IA que

obtiveram os resultados mais expressivos quando implementados individualmente, sem integração com outras técnicas ou modelos híbridos.

Figura 5 - Modelos isolados com melhores resultados




Fonte: Elaborado pelo autor.

Além disso, verificou-se que em 81 estudos os modelos híbridos apresentaram desempenho superior tanto em relação aos modelos hidrológicos tradicionais e aos algoritmos de IA aplicados de forma isolada, evidenciando ganhos significativos decorrentes da integração de técnicas. Isso vai ao encontro com os achados de Hakim et al. (2024) que destaca o potencial de combinação de diferentes modelos com o LSTM a fim de melhorar a sua capacidade preditiva no contexto de inundações.

Entretanto, dois estudos relataram desempenho equivalente entre modelos de IA e hidrológicos tradicionais, enquanto em um único caso o modelo hidrológico superou a abordagem baseada em IA. A Figura 6 apresenta a distribuição proporcional observada.

Figura 6 - Comparação de resultados entre modelos isolados, híbridos e hidrológicos




Fonte: Elaborado pelo autor.

3.4 CONTEXTO

Quanto ao contexto de aplicação das previsões, foram identificadas 176 bacias hidrográficas e 13 reservatórios distintos contemplados pelos estudos analisados. Esses trabalhos abrangeram 18 tipos de ambientes, com destaque para regiões montanhosas (63), urbanas (29) e semiáridas (12), o que demonstra a versatilidade dos modelos de IA em diferentes contextos hidrológicos e geográficos.

Observou-se uma ampla distribuição geográfica das pesquisas, com destaque para a China, que concentrou o maior número de aplicações de IA na previsão de inundações (36 ocorrências), seguida por Índia (17), Irã (14), Estados Unidos (13) e Malásia (12). O Brasil é o próximo país da lista, com 7 citações, mesmo número da Austrália. Outros 37 países também foram contemplados, embora que em menor frequência de estudos publicados. A Figura 7 demonstra a distribuição geográfica dos estudos e que evidencia que a preocupação com os impactos causados por inundações constitui um desafio de escala global.

Figura 7 - Distribuição geográfica dos estudos



Fonte: Elaborado pelo autor.

3.5 DADOS

A análise dos parâmetros de entrada utilizados nos modelos revelou predominância de variáveis hidrometeorológicas tradicionais, refletindo a influência dos processos físicos no ciclo hidrológico. A precipitação foi o parâmetro mais recorrente, presente em 129 estudos, seguida pela vazão (93), nível d'água (59) e

temperatura (49). Outros fatores relevantes incluíram umidade relativa (27), evapotranspiração (21) e dados relativos ao vento (20), além de outras 131 com menor frequência. Esses resultados (Tabela 3) evidenciam a complexidade inerente à previsão de inundações, tendo em vista a pluralidade de parâmetros de entrada adotados.

Tabela 3 - Parâmetros de entrada mais citados

Variável	Qtd.	%Total	%Artigos	Variável	Qtd.	%Total	%Artigos
Precipitação	129	18,80%	74,14%	Características do solo	7	1,02%	4,02%
Vazão	93	13,56%	53,45%	Declividade	7	1,02%	4,02%
Nível d'água	59	8,60%	33,91%	Temperatura máxima	7	1,02%	4,02%
Temperatura	49	7,14%	28,16%	Uso do solo	7	1,02%	4,02%
Umidade relativa	27	3,94%	15,52%	Temperatura mínima	7	1,02%	4,02%
Evapotranspiração	21	3,06%	12,07%	Elevação média	6	0,87%	3,45%
Vazão defasada	20	2,92%	11,49%	Escoamento superficial	6	0,87%	3,45%
Vento	20	2,92%	11,49%	Umidade do solo	6	0,87%	3,45%
Radiação solar	12	1,75%	6,90%	Sensoriamento remoto	5	0,73%	2,87%
Pressão atmosférica	8	1,17%	4,60%	Intensidade de chuva	5	0,73%	2,87%

Fonte: Elaborado pelo autor.

Esses resultados corroboram o observado por Maspo et al. (2020), que identificaram a precipitação e o nível d'água como os principais parâmetros empregados em modelos de previsão de inundações. Entretanto, nos artigos incluídos nesta pesquisa, já se observou a inclusão de variáveis socioeconômicas, como população, citado em 2 artigos, presença de atividades humanas (2) e agrícolas (1).

Quanto a origem destes dados, evidenciou-se uma ampla diversidade com 156 fontes distintas, abrangendo desde bases globais até bancos de dados regionais. O *European Centre for Medium-Range Weather Forecasts* (ECMWF) foi a fonte mais recorrente, citada em 12 estudos, seguido pelo *India Meteorological Department* (IMD) em 9, o *Department of Irrigation* da Índia (DID) em 8 e o *United States Geological Survey* (USGS) em 5.


Além disso, observou-se uma resolução temporal dos conjuntos com média de 21,4 anos, sendo a máxima de 131 anos e a mínima de apenas 1 dia. Em relação à granularidade, observou-se predominância de séries temporais diárias (77) e horárias (53). Estes resultados evidenciam a heterogeneidade dos períodos amostrais entre os estudos e reflete a necessidade de dados com alta resolução.

Quanto aos parâmetros indicadores de inundação, observou-se predominância da vazão, utilizada em 94 estudos, e o nível d'água, presente em 50. Outras abordagens categóricas foram observadas que utilizavam variáveis binárias (Sim/Não) ou de status de risco.

3.6 RESULTADOS

Os principais achados observados nos estudos analisados indicam avanços significativos na aplicação da Inteligência Artificial para previsão de inundações. A maior parte das pesquisas relatou ganhos consistentes em desempenho e precisão, especialmente com o uso de modelos baseados em aprendizado profundo e abordagens híbridas. Além disso, o uso de técnicas de otimização e metaheurísticas¹⁰ melhoram o processo de calibração dos modelos e reduzem erros, resultando em maior capacidade de generalização.

Figura 8 - Principais achados



Fonte: Elaborado pelo autor.

Outros achados relevantes reforçam a importância da integração entre métodos e da escolha adequada dos parâmetros de entrada. Modelos híbridos com decomposição e atenção (*transformers*) também demonstraram maior precisão e estabilidade, especialmente em cenários com dados limitados. Estratégias voltadas à


¹⁰ Metaheurísticas são técnicas de otimização inspiradas em fenômenos naturais, biológicos ou físicos, utilizadas para resolver problemas complexos de busca soluções. Elas priorizam a busca por soluções ótimas visando a eficiência computacional em detrimento da busca pela melhor solução (Sharma & Tripathi, 2022).

minimização da subestimação de picos e reduções expressivas de viés e erro confirmam o avanço metodológico da área. A Figura 8 apresenta os dados referentes aos principais achados dos estudos.

Dentre as principais limitações relatadas destaca-se a qualidade e disponibilidade dos dados, evidenciando que a escassez, inconsistência e ausência de padronização nas séries históricas impactam diretamente o desempenho dos modelos. Outros relatos recorrentes incluem a baixa capacidade de generalização, aumento do erro em eventos extremos e a necessidade de altos recursos computacionais. A Figura 9a apresenta a distribuição das principais limitações observadas nos estudos analisados.

As principais recomendações (Figura 9b) concentraram-se na melhoria da qualidade e diversidade dos dados utilizados (110 estudos) e na aplicação dos modelos em diferentes contextos (77). Além disso, destacou-se a necessidade de avaliar novos algoritmos e combinações de técnicas (83) e de aprimorar sua eficiência e capacidade de otimização (24). Outras sugestões recorrentes incluíram a ampliação do horizonte de previsão (17) e a integração com dados coletados em tempo real (15) e a sistemas de monitoramento (14).

Figura 9 - Principais limitações e recomendações observadas
(a) Limitações (b) Recomendações



Fonte: Elaborado pelo autor.

reprodutibilidade, com documentação parcial dos procedimentos, enquanto e apenas 2,87% como baixa, devido à ausência de dados e códigos. O risco de viés prevaleceu a classificação de baixo a moderado, com 47,13% classificados como de baixo risco e 52,87% como médio, não havendo casos de alto risco. Esses resultados indicam que a maior parte dos trabalhos apresentou metodologias consistentes, embora com limitações pontuais, especialmente quanto à validação externa e à descrição detalhada dos processos de calibração.

4 CONCLUSÃO

A partir da análise dos resultados, é possível observar que o uso de IA na previsão de inundações tem apresentado resultados promissores podendo complementar os modelos hidrológicos tradicionais. A predominância de algoritmos baseados em redes neurais profundas, especialmente o LSTM, evidencia sua eficiência em lidar com séries temporais complexas e em capturar padrões não lineares associados aos processos hidrológicos.

Observou-se, também, a utilização recorrente de modelos híbridos, que combinam técnicas de aprendizado de máquina com modelos tradicionais ou outras técnicas de IA, indicando ganhos significativos e reduções de erro. Os estudos apontam melhoras expressivas em acurácia, embora persistam limitações relacionadas à qualidade dos dados e à generalização entre diferentes bacias.

Além disso, a pesquisa confirmou que as aplicações de IA em previsão de inundações pode contribuir para o desenvolvimento de sistemas de alerta precoce, gestão de recursos hídricos e operações de reservatórios. Esses avanços consolidam a IA como uma ferramenta de apoio à gestão pública e à mitigação de desastres.

Com isso, este estudo apresenta subsídios para o aprimoramento e desenvolvimento destes sistemas baseados em IA, podendo viabilizar o gerenciamento integrado de recursos hídricos de cidades e países. Ademais, podem auxiliar no atingimento das metas do objetivo 13 das ODS, bem como dos objetivos 9 e 11 por meio de soluções tecnológicas que fortalecem a resiliência climática e urbana.

Por fim, recomenda-se realizar uma análise quantitativa complementar dos dados extraídos, investigando possíveis correlações entre características físicas das bacias hidrográficas e o desempenho dos modelos de IA. Esta abordagem permitiria identificar se determinados algoritmos se adequam melhores a diferentes contextos hidrológicos, contribuindo na seleção de modelos a partir da área a ser estudada.

REFERÊNCIAS

ALJOHANI, Fares Hamad et al. **Flood Prediction using Hydrologic and ML-based Modeling: A Systematic Review**. International Journal of Advanced Computer Science & Applications, v. 14, n. 11, 2023.

AMIR-BEHGHADAMI, Mehrdad. **SPIDER as a framework to formulate eligibility criteria in qualitative systematic reviews**. BMJ Supportive & Palliative Care, v. 14, n. e1, p. e312-e313, 2021.

BRASIL. Ministério da Integração Nacional, Secretaria Nacional de Defesa Civil. **Portaria Conjunta n.º 148, de 18 de dezembro de 2013**. Diário Oficial da União, Seção 1, n. 249, p. 58, 24 dez. 2013.

CONFEDERAÇÃO NACIONAL DE MUNICÍPIOS. **CNM atualiza prejuízos dos Municípios com as chuvas no RS; impacto é de R\$ 13,3 bilhões**. Confederação Nacional de Municípios, 20 de agosto de 2024. Disponível em: <<https://cnm.org.br/comunicacao/noticias/cnm-atualiza-prejuizos-dos-municipios-com-as-chuvas-no-rs-impacto-e-de-r-13-3-bilhoes>>. Acesso em: 04 out. 2024.

FERNANDES, Luana Nietto; MADEIRA, Kristian; DE MATTOS, Merisandra Côrtes. **Acervo da Biblioteca Central da Unesc**. 2025. Disponível em: <<http://repositorio.unesc.net/handle/1/11907>>. Acesso em: 08 nov. 2025.

HAKIM, Dimara Kusuma; GERNOWO, Rahmat; NIRWANSYAH, Anang Widhi. **Flood prediction with time series data mining: Systematic review**. Natural Hazards Research, v. 4, n. 2, p. 194-220, 2024.

IPCC. Sections. **Climate Change 2023: Synthesis Report**. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]. IPCC, Geneva, Switzerland, p. 35-115, 2023.

JBI. **Critical Appraisal Tools**. 2025. Disponível em: <<https://jbi.global/critical-appraisal-tools>>. Acesso em: 01 nov. 2025.

LINARES-ESPINÓS, E. et al. **Methodology of a systematic review**. Actas Urológicas Españolas (English Edition), v. 42, n. 8, p. 499-506, 2018.

MASPO, Nur-Adib et al. **Evaluation of Machine Learning approach in flood prediction scenarios and its input parameters: A systematic review**. IOP Conference Series: Earth and Environmental Science. IOP Publishing, 2020. p. 012038.

MORENO-IBARRA, Marco et al. **Generative AI (GenAI) and smart cities: Efficiency, cohesion, and sustainability**. Smart Cities. Routledge, 2024. p. 118-129.

MOSAVI, Amir; OZTURK, Pinar; CHAU, Kwok-wing. **Flood prediction using machine learning models: Literature review**. Water, v. 10, n. 11, p. 1536, 2018.

ONU BRASIL. **Objetivo 13: Ação contra a mudança global do clima**. ONU Brasil, 2024. Disponível em: <<https://brasil.un.org/pt-br/sdgs/13>>. Acesso em: 26 set. 2024.

PAUL, Mical; LEEFLANG, Mariska M. **Reporting of systematic reviews and meta-analysis of observational studies**. Clinical Microbiology and Infection, v. 27, n. 3, p. 311-314, 2021.

PIADEH, Farzad; BEHZADIAN, Kourosh; ALANI, Amir M. **A critical review of real-time modelling of flood forecasting in urban drainage systems**. Journal of Hydrology, v. 607, p. 127476, 2022.

RANDHAWA, Rizwan Hamid; MAHMOOD, Rashid; AHMAD, Tahir. **AquaEye: a low cost flood early warning system for developing countries**. International Conference on Frontiers of Information Technology (FIT). IEEE, 2018. p. 345-349, 2018

RENTSCHLER, Jun; SALHAB, Melda; JAFINO, Bramka Arga. **Flood exposure and poverty in 188 countries**. Nature communications, v. 13, n. 1, p. 3527, 2022.

RIO GRANDE DO SUL. **Defesa Civil atualiza balanço das enchentes no RS – 20/8**. Rio Grande do Sul, 20 de agosto de 2024. Disponível em: <<https://www.estado.rs.gov.br/defesa-civil-atualiza-balanco-das-enchentes-no-rs-20-8>>. Acesso em: 04 out. 2024.

SHARMA, Vivek; TRIPATHI, Ashish Kumar. **A systematic review of meta-heuristic algorithms in IoT based application**. Array, v. 14, p. 100164, 2022

SKOUBRIS, Evangelos; HLOUPIS, George. **An AI-Powered, Low-Cost IoT Node Oriented to Flood Early Warning Systems**. Engineering Proceedings, v. 58, n. 1, p. 44, 2023.

WU, Yirui et al. **Complexity to forecast flood: Problem definition and spatiotemporal attention LSTM solution**. Complexity, v. 2020, n. 1, p. 7670382, 2020.

ZAHRI, R. et al. **Flood early warning systems (fews) in enhancing disaster risk reduction and community resilience: a systematic review**. International Journal of Law, Government and Communication, v. 10, n. 40, p. 425–445, 10 jun. 2025.

APÊNDICE A - DADOS DO BLOCO DE IDENTIFICAÇÃO

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
1	A Deep Learning Framework for Flash-Flood-Runoff Prediction: Integrating CNN-RNN with Neural Ordinary Differential Equations (ODEs)	2025	WATER	Alkaabi, K; Sarfraz, U; Al Darmaki, S	10.3390/w17091283	Experimental	Inglês
2	A distributed approach to flood prediction using a WSN and ML: A comparative study of ML techniques in a WSN deployed in Brazil	2015	Lecture Notes in Computer Science	Furquim, G.; Pessin, G.; Gomes, P.H.; Mendiando, E.M.; Ueyama, J.	10.1007/978-3-319-24834-9_56	Experimental	Inglês
3	A flood Impact-Based forecasting system by fuzzy inference techniques	2023	JOURNAL OF HYDROLOGY	Wee, G; Chang, LC; Chang, FJ; Amin, MZM	10.1016/j.jhydrol.2023.130117	Experimental	Inglês
4	A Location-Independent Flood Prediction Model for Bangladesh's Rivers	2023	2023 IEEE 35th International Conference on Tools with Artificial Intelligence (ICTAI)	M. A. Hasan; N. T. Rouf; M. S. Hossain; L. B. Latif; A. Tasnim; M. Grzegorzec	10.1109/ICTAI59109.2023.00028	Experimental	Inglês
5	A novel 24- Hour deep neural network based Streamflow Forecasting method in Data-Scarce Regions	2023	2023 13th Smart Grid Conference (SGC)	P. Taheri; S. Taheri; M. Taheri; G. Taheri	10.1109/SGC61621.2023.10459303	Experimental	Inglês
6	A Scalable River Flow Forecast and Basin Optimization System for Hydropower Plants	2020	IEEE TRANSACTIONS ON SUSTAINABLE ENERGY	Buhan, S; Küçük, D; Çinar, MS; Güvengir, U; Demirci, T; Yilmaz, Y; Malkoç, F; Eminoglu, E; Yildirim, MU	10.1109/TSTE.2019.2952450	Experimental	Inglês
7	A simple and efficient rainfall-runoff model based on supervised brain emotional learning	2022	NEURAL COMPUTING & APPLICATIONS	Parvinizadeh, S; Zakermoshfegh, M; Shakiba, M	10.1007/s00521-021-06475-9	Experimental	Inglês
8	A smart sustainable system for flood damage management with the application of artificial intelligence and multi-criteria decision-making computations	2023	INTERNATIONAL JOURNAL OF DISASTER RISK REDUCTION	Zabihi, O; Siamaki, M; Gheibi, M; Akrami, M; Hajiaghahi-Keshteli, M	10.1016/j.ijdr.2022.103470	Experimental	Inglês
9	A Stacking Ensemble Model of Various Machine Learning Models for Daily Runoff Forecasting	2023	WATER	Lu, MS; Hou, QY; Qin, SJ; Zhou, LH; Hua, D; Wang, XX; Cheng, L	10.3390/w15071265	Experimental	Inglês
10	A stream prediction model based on attention-LSTM	2021	EARTH SCIENCE INFORMATICS	Yan, L; Chen, CW; Hang, TT; Hu, YC	10.1007/s12145-021-00571-z	Experimental	Inglês
11	A system based on an artificial neural network of the second generation for decision support in especially significant situations	2023	JOURNAL OF HYDROLOGY	Palchevsky, E; Antonov, V; Enikeev, R; Breikin, T	10.1016/j.jhydrol.2022.128844	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
12	Advanced Hydro-Informatic Modeling Through Feedforward Neural Network, Federated Learning, and Explainable AI for Enhancing Flood Prediction	2025	IEEE OPEN JOURNAL OF THE COMPUTER SOCIETY	Mahir, SH; Tashrif, MTA; Karim, MA; Kundu, D; Rahman, A; Hamza, MA; Al Farid, F; Miah, AM; Mansor, S	10.1109/OJCS.2025.3556424	Experimental	Inglês
13	AI-Based Ensemble Flood Forecasts and Its Implementation in Multi-Objective Robust Optimization Operation for Reservoir Flood Control	2024	WATER RESOURCES RESEARCH	Guo, YX; Xu, YP; Yu, XT; Liu, L; Gu, HT	10.1029/2023WR035693	Experimental	Inglês
14	AI-driven forecasting of river discharge: the case study of the Himalayan mountainous river	2025	EARTH SCIENCE INFORMATICS	Rather, SA; Patel, M; Kapoor, K	10.1007/s12145-025-01737-9	Experimental	Inglês
15	AI-enhanced flood forecasting: Harnessing upstream data for downstream protection	2023	Journal of Applied Research in Water and Wastewater	Ebtehaj, I.; Bonakdari, H.; Gharabaghi, B.	10.22126/arww.2024.10226.1322	Experimental	Inglês
16	Alternative Hydraulic Modeling Method Based on Recurrent Neural Networks: From HEC-RAS to AI	2025	HYDROLOGY	Rugina, AM	10.3390/hydrology12080207	Experimental	Inglês
17	An Ensemble Decomposition-Based Artificial Intelligence Approach for Daily Streamflow Prediction	2019	WATER	Rezaie-Balf, M; Nowbandegani, SF; Samadi, SZ; Fallah, H; Alaghmand, S	10.3390/w11040709	Experimental	Inglês
18	Application of a novel technique of the multi-discrete wavelet transforms in hybrid with artificial neural network to forecast the daily and monthly streamflow	2022	Modeling Earth Systems and Environment	Momeneh, S.; Nourani, V.	10.1007/s40808-022-01387-6	Experimental	Inglês
19	Application of AI-Based Models for Flood Water Level Forecasting and Flood Risk Classification	2023	KSCE JOURNAL OF CIVIL ENGINEERING	Kim, D; Park, J; Han, HC; Lee, HE; Kim, HS; Kim, S	10.1007/s12205-023-2175-5	Experimental	Inglês
20	Application of artificial intelligence algorithms for hourly river level forecast: A case study of Muda River, Malaysia	2021	ALEXANDRIA ENGINEERING JOURNAL	Zakaria, MNA; Malek, MA; Zolkepli, M; Ahmed, AN	10.1016/j.aej.2021.02.046	Experimental	Inglês
21	Application of Hybrid Support Vector Machine model for Streamflow Prediction in Barak valley, India	2022	IOP Conference Series: Earth and Environmental Science	Sahoo, A.; Ghose, D.K.	10.1088/1755-1315/1032/1/012016	Experimental	Inglês
22	Application of Soft Computing Techniques in River Flow Modeling	2023	Sakarya University Journal of Science	Yesilyurt, S.N.; Dalkiliç, H.Y.; Samui, P.	10.16984/aufenbilder.1152982	Experimental	Inglês
23	Applying iTransformer for Saigon River Water Level Forecasting	2024	2024 International Conference on Advanced Technologies for Communications (ATC)	A. T. Nguyen Dai; T. T. Vo Thi; T. B. Nguyen	10.1109/ATC63255.2024.10908259	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
24	Applying Upstream Satellite Signals and a 2-D Error Minimization Algorithm to Advance Early Warning and Management of Flood Water Levels and River Discharge	2019	IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING	Zaji, AH; Bonakdari, H; Gharabaghi, B	10.1109/TGRS.2018.2862640	Experimental	Inglês
25	Artificial intelligence and machine learning performance assessment for flood forecasting: a case study of the Ill watershed	2024	Techniques - Sciences - Methodes	Reiminger, N.; Jurado, X.; Saunier, L.; Maurer, L.; Reiminger, E.; Weber, L.; Nguyen, T.H.L.; Wemmert, C.	10.36904/tsm/20241153	Experimental	Français
26	Artificial Intelligence Based Flood Forecasting for River Hunza at Danyor Station in Pakistan	2022	Archives of Hydroengineering and Environmental Mechanics	Yaseen, M.W.; Awais, M.; Riaz, K.; Rasheed, M.B.; Waqar, M.; Rasheed, S.	10.2478/heem-2022-0005	Experimental	Inglês
27	Artificial intelligence for streamflow prediction in river basins: a use case in Mar Menor	2025	SCIENTIFIC REPORTS	Cisterna-García, A; González-Vidal, A; Martínez-Ibarra, A; Ye, Y; Guillén-Teruel, A; Bernal-Escobedo, L; Skarmeta, AF	10.1038/s41598-025-04524-0	Experimental	Inglês
28	Artificial Intelligence Techniques in Hydrology and Water Resources Management and Their Applicability to Sri Lankan River Basins	2024	2024 Moratuwa Engineering Research Conference (MERCon)	S. D. Karunarathna; R. L. H. L. Rajapakse	10.1109/MERCon63886.2024.10688604	Experimental	Inglês
29	Assessing the effectiveness of artificial intelligence approaches for streamflow modeling in the Indravathi subbasin, India	2025	ENVIRONMENT DEVELOPMENT AND SUSTAINABILITY	Saravanan, S; Reddy, NM	10.1007/s10668-025-06092-9	Experimental	Inglês
30	Assessment of neuro-fuzzy approach based different wavelet families for daily flow rates forecasting	2021	Modeling Earth Systems and Environment	Abda, Z.; Chettih, M.; Zerouali, B.	10.1007/s40808-020-00855-1	Experimental	Inglês
31	Combining Multiple Machine Learning Methods Based on CARS Algorithm to Implement Runoff Simulation	2024	WATER	Fan, YY; Fu, XD; Kan, GY; Liang, K; Yu, HJ	10.3390/w16172397	Experimental	Inglês
32	Comparative Analysis of ARIMA and LSTM Approaches for Monthly River Flow Forecasting in Terengganu	2024	2024 5th International Conference on Artificial Intelligence and Data Sciences (AiDAS)	N. Ibrahim; N. Ahmad; N. Amalina Mat Jan; Z. Zainudin; N. Syafidah Jamil; A. Azlan	10.1109/AiDAS63860.2024.10730554	Experimental	Inglês
33	Comparative Performance of Rainfall-Runoff Models: Conceptual, Machine Learning, and Hybrid Approaches, Case Study of Côtiers Algérois Watershed, Algeria	2025	WATER RESOURCES	Daif, N; Hebal, A; Boucetta, B; Metarah, A	10.1134/S0097807824604850	Experimental	Inglês
34	Comparative presentation of machine learning algorithms in flood prediction using spatio-temporal data	2016	Lecture Notes in Electrical Engineering	Jangyodsuk, P.; Seo, D.-J.; Elmasri, R.; Gao, J.	10.1007/978-3-662-49831-6_105	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
35	Comparing Performance of ANN and SVM Methods for Regional Flood Frequency Analysis in South-East Australia	2022	WATER	Zalnezhad, A; Rahman, A; Nasiri, N; Vafakhah, M; Samali, B; Ahamed, F	10.3390/w14203323	Experimental	Inglês
36	Comparison and integration of physical and interpretable AI-driven models for rainfall-runoff simulation	2024	RESULTS IN ENGINEERING	Asadi, S; Jimeno-Sáez, P; López-Ballesteros, A; Senent-Aparicio, J	10.1016/j.rineng.2024.103048	Experimental	Inglês
37	Comparison of Deep Learning Techniques for River Streamflow Forecasting	2021	IEEE Access	X. -H. Le; D. -H. Nguyen; S. Jung; M. Yeon; G. Lee	10.1109/ACCESS.2021.3077703	Experimental	Inglês
38	Comparison of Different Artificial Intelligence Techniques to Predict Floods in Jhelum River, Pakistan	2022	WATER	Ahmed, F; Loc, HH; Park, E; Hassan, M; Joyklad, P	10.3390/w14213533	Experimental	Inglês
39	Comparison of physical models and artificial intelligence for prediction of flood levels	2018	TECNOLOGIA Y CIENCIAS DEL AGUA	Agudelo-Otálora, LM; Moscoso-Barrera, WD; Paipa-Galeano, LA; Mesa-Sciarrotta, C	10.24850/j-tyca-2018-04-09	Experimental	Inglês
40	Comprehensive Analysis of Flood Risk Using Regression Models and Interpretable Machine Learning Techniques	2024	2024 International Conference on Integrated Intelligence and Communication Systems (ICIICS)	K. Vigneswara Reddy; C. Mounika Begum; A. Neeraja; B. U. Maheswari; S. Amulyashree	10.1109/ICIICS63763.2024.10859855	Experimental	Inglês
41	Constraint Free Early Warning System for Flood Using Multivariate LSTM Network	2022	2022 2nd International Conference on Artificial Intelligence (ICAI)	T. Gohar; L. Hasan; G. M. Khan; M. Mubashir	10.1109/ICAI55435.2022.9773495	Experimental	Inglês
42	Coupling SWAT plus with LSTM for enhanced and interpretable streamflow estimation in arid and semi-arid watersheds, a case study of the Tagus Headwaters River Basin, Spain	2025	ENVIRONMENTAL MODELLING & SOFTWARE	Asadi, S; Jimeno-Sáez, P; López-Ballesteros, A; Senent-Aparicio, J	10.1016/j.envsoft.2025.106360	Experimental	Inglês
43	CRML: A Convolution Regression Model With Machine Learning for Hydrology Forecasting	2019	IEEE ACCESS	Chen, C; Hui, Q; Pei, QQ; Zhou, Y; Wang, B; Lv, N; Li, J	10.1109/ACCESS.2019.2941234	Experimental	Inglês
44	Daily River Flow Forecasting with Hybrid Support Vector Machine - Particle Swarm Optimization	2018	4TH INTERNATIONAL CONFERENCE ON CIVIL AND ENVIRONMENTAL ENGINEERING FOR SUSTAINABILITY (ICONCEES 2017)	Zaini, N; Malek, MA; Yusoff, M; Mardi, NH; Norhisham, S; IOP	10.1088/1755-1315/140/1/012035	Experimental	Inglês
45	Daily scale streamflow forecasting in multiple stream orders of Cauvery River, India: Application of advanced ensemble and deep learning models	2023	Journal of Hydrology	Naganna, S.R.; Marulasiddappa, S.B.; Balreddy, M.S.; Yaseen, Z.M.	10.1016/j.jhydrol.2023.130320	Experimental	Inglês
46	Daily streamflow prediction using support vector machine-artificial flora (SVM-AF) hybrid model	2020	ACTA GEOPHYSICA	Dehghani, R; Poudeh, HT; Younesi, H; Shahinejad, B	10.1007/s11600-020-00472-7	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
47	Deep learning model on rates of change for multi-step ahead streamflow forecasting	2023	JOURNAL OF HYDROINFORMATICS	Tan, WY; Lai, SH; Pavitra, K; Teo, FY; El-Shafie, A	10.2166/hydro.2023.001	Experimental	Inglês
48	Deep Learning Prediction of Streamflow in Portugal	2024	HYDROLOGY	Francisco, R; Matos, JP	10.3390/hydrology11120217	Experimental	Inglês
49	Deep Learning-Based River Flow Forecasting with MLPs: Comparative Exploratory Analysis Applied to the Tejo and the Mondego Rivers	2025	SENSORS	Jesus, G; Mardani, Z; Alves, E; Oliveira, A	10.3390/s25072154	Experimental	Inglês
50	Deep transfer learning based on transformer for flood forecasting in data-sparse basins	2023	JOURNAL OF HYDROLOGY	Xu, YH; Lin, KR; Hu, CH; Wang, SL; Wu, Q; Zhang, L; Ran, G	10.1016/j.jhydrol.2023.129956	Experimental	Inglês
51	Deep-learning-based sub-seasonal precipitation and streamflow ensemble forecasting over the source region of the Yangtze River	2025	HYDROLOGY AND EARTH SYSTEM SCIENCES	Dong, NP; Hao, HR; Yang, MX; Wei, JH; Xu, SQ; Kunstmann, H	10.5194/hess-29-2023-2025	Experimental	Inglês
52	DEVELOPMENT AND OPERATIONAL TESTING OF A SUPER-ENSEMBLE ARTIFICIAL INTELLIGENCE FLOOD-FORECAST MODEL FOR A PACIFIC NORTHWEST RIVER	2015	JOURNAL OF THE AMERICAN WATER RESOURCES ASSOCIATION	Fleming, SW; Bourdin, DR; Campbell, D; Stull, RB; Gardner, T	10.1111/jawr.12259	Experimental	Inglês
53	Development of a model for forecasting the inflow to the site of a hydroelectric power plant using neural models for information processing	2023	IOP Conference Series: Earth and Environmental Science	Grebnev, Y.V.; Moskalev, A.K.; Petrunina, A.E.; Lazutin, D.T.	10.1088/1755-1315/1231/1/012074	Experimental	Inglês
54	Development of a predictive model for on-demand remote river level nowcasting: Case study in Cagayan River Basin, Philippines	2017	IEEE Region 10 Annual International Conference, Proceedings/TENCON	Garcia, F.C.C.; Retamar, A.E.; Javier, J.C.	10.1109/TENCON.2016.7848657	Experimental	Inglês
55	Development of an Extreme Gradient Boosting Model Integrated With Evolutionary Algorithms for Hourly Water Level Prediction	2021	IEEE Access	D. H. Nguyen; X. Hien Le; J. -Y. Heo; D. -H. Bae	10.1109/ACCESS.2021.3111287	Experimental	Inglês
56	Development of predictive model for flood routing using genetic expression programming	2018	JOURNAL OF FLOOD RISK MANAGEMENT	Bagatur, T; Onen, F	10.1111/jfr3.12232	Experimental	Inglês
57	Discharge forecasting using an Online Sequential Extreme Learning Machine (OS-ELM) model: A case study in Neckar River, Germany	2016	MEASUREMENT	Yadav, B; Ch, S; Mathur, S; Adamowski, J	10.1016/j.measurement.2016.06.042	Experimental	Inglês
58	Early warning system for floods at estuarine areas: combining artificial intelligence with process-based models	2025	NATURAL HAZARDS	de Melo, WW; Iglesias, I; Pinho, J	10.1007/s11069-024-06957-8	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
59	Efficacy of ANFIS-GOA technique in flood prediction: a case study of Mahanadi river basin in India	2021	H2OPEN JOURNAL	Sahoo, A; Samantaray, S; Paul, S	10.2166/h2oj.2021.090	Experimental	Inglês
60	Efficient forecasting model technique for river stream flow in tropical environment	2019	URBAN WATER JOURNAL	Khairuddin, N; Aris, AZ; Elshafie, A; Narany, TS; Ishak, MY; Isa, NM	10.1080/1573062X.2019.1637906	Experimental	Inglês
61	Enhanced streamflow forecasting using attention-based neural network models: a comparative study in MOPEX basins	2024	MODELING EARTH SYSTEMS AND ENVIRONMENT	Muhammad, AU; Muazu, T; Ying, HH; Ba, AF; Tijjani, S; Adam, JM; Bello, AU; Bala, MM; Ali, MH; Dabai, US; Yahaya, MS	10.1007/s40808-024-02088-y	Experimental	Inglês
62	Enhancing community resilience in arid regions: A smart framework for flash flood risk assessment	2023	ECOLOGICAL INDICATORS	Nakhaei, M; Nakhaei, P; Gheibi, M; Chahkandi, B; Waclawek, S; Behzadian, K; Chen, AS; Campos, LC	10.1016/j.ecolind.2023.110457	Experimental	Inglês
63	Enhancing Disaster Preparedness in Chiba, Japan: The Role of Artificial Neural Networks in Flood Prediction	2024	2024 IEEE/ACIS 9th International Conference on Big Data, Cloud Computing, and Data Science (BCD)	K. Balasubramanian; I. Motoi	10.1109/BCD61269.2024.10743089	Experimental	Inglês
64	Enhancing flood forecasting performance using effective and transparent explainable hybrid deep learning model	2025	Earth Science Informatics	Hasan, M.; Rabbi, M.F.; Hamja, M.A.; Fatema, K.; Hassan, M.M.	10.1007/s12145-025-01930-w	Experimental	Inglês
65	Enhancing lake water level forecasting with attention-based LSTM: a data-driven approach to hydrology and tourism dynamics	2025	AIN SHAMS ENGINEERING JOURNAL	Chapon, M; Ozdemir, S	10.1016/j.asej.2025.103723	Experimental	Inglês
66	Ensemble Forecasts of Extreme Flood Events with Weather Forecasts, Land Surface Modeling and Deep Learning	2024	WATER	Liu, YX; Yuan, X; Jiao, Y; Ji, P; Li, CQ; An, XD	10.3390/w16070990	Experimental	Inglês
67	Ensemble Machine Learning Framework for Accurate Flood Prediction	2024	10TH INTERNATIONAL CONFERENCE ON ELECTRONICS, COMPUTING AND COMMUNICATION TECHNOLOGIES, CONECCT 2024	Varghese, A; Gupta, VB; Saxena, M; IEEE	10.1109/CONECCT62155.2024.10677233	Experimental	Inglês
68	Evaluating different strategies for machine learning training applied to flow forecasting based on clustering of flood events	2025	RBRH-REVISTA BRASILEIRA DE RECURSOS HIDRICOS	Steffen, PC; Gomes, J; Kaviski, E; Detzel, DHM	10.1590/2318-0331.302520240087	Experimental	Inglês
69	Evaluation of artificial intelligence models for flood and drought forecasting in arid and tropical regions	2021	Environmental Modelling and Software	Adikari, K.E.; Shrestha, S.; Ratnayake, D.T.; Budhathoki, A.; Shanmugam, S.; Dailey, M.N.	10.1016/j.envsoft.2021.105136	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
70	Evaluation of statistical models and modern hybrid artificial intelligence in the simulation of precipitation runoff process	2022	Sustainable Water Resources Management	Dehghani, R.; Babaali, H.; Zeydalinejad, N.	10.1007/s40899-022-00743-9	Experimental	Inglês
71	Evaluation of stochastic and artificial intelligence models in modeling and predicting of river daily flow time series	2020	STOCHASTIC ENVIRONMENTAL RESEARCH AND RISK ASSESSMENT	Aghelpour, P; Varshavian, V	10.1007/s00477-019-01761-4	Experimental	Inglês
72	Evaluation of WRF and artificial intelligence models in short-term rainfall, temperature and flood forecast (case study)	2020	JOURNAL OF EARTH SYSTEM SCIENCE	Shirali, E; Shahbazi, AN; Fathian, H; Zohrabi, N; Hassan, EM	10.1007/s12040-020-01450-9	Experimental	Inglês
73	Event-based Bayesian causal modelling for flood hydrograph prediction, Upper Andarax intermittent stream, Spain	2022	JOURNAL OF HYDROLOGY-REGIONAL STUDIES	Hamitouche, M; Molina, JL	10.1016/j.ejrh.2022.101260	Experimental	Inglês
74	Event-based rainfall-runoff modeling using adaptive network-based fuzzy inference system	2016	Jurnal Teknologi	Nawaz, N.; Harun, S.; Talei, A.; Chang, T.K.	10.11113/jt.v78.9693	Experimental	Inglês
75	Explore an evolutionary recurrent ANFIS for modelling multi-step-ahead flood forecasts	2019	JOURNAL OF HYDROLOGY	Zhou, YL; Guo, SL; Chang, FJ	10.1016/j.jhydrol.2018.12.040	Experimental	Inglês
76	Extreme learning machine coupled with Heuristic algorithms for daily streamflow modeling at Lake Ziway Watershed, Ethiopia	2025	JOURNAL OF HYDROLOGY	Gelete, G; Gökçekus, H; Yaseen, ZM; Gichamo, T	10.1016/j.jhydrol.2025.133345	Experimental	Inglês
77	Flood discharge prediction using improved ANFIS model combined with hybrid particle swarm optimisation and slime mould algorithm	2023	ENVIRONMENTAL SCIENCE AND POLLUTION RESEARCH	Samantaray, S; Sahoo, P; Sahoo, A; Satapathy, DP	10.1007/s11356-023-27844-y	Experimental	Inglês
78	Flood estimation in ungauged catchments: application of artificial intelligence based methods for Eastern Australia	2017	STOCHASTIC ENVIRONMENTAL RESEARCH AND RISK ASSESSMENT	Aziz, K; Haque, MM; Rahman, A; Shamseldin, AY; Shoaib, M	10.1007/s00477-016-1272-0	Experimental	Inglês
79	Flood Forecasting Method Based on Improved VMD-FOS-QR-RBL	2023	IEEE Access	Y. Liu; L. Wang; S. Du; L. Zhao; X. Liu	10.1109/ACCESS.2022.3232405	Experimental	Inglês
80	Flood Forecasting of Malaysia Kelantan River using Support Vector Regression Technique	2021	COMPUTER SYSTEMS SCIENCE AND ENGINEERING	Faruq, A; Marto, A; Abdullah, SS	10.32604/csse.2021.017468	Experimental	Inglês
81	Flood Forecasting through Spatiotemporal Rainfall in Hilly Watersheds	2024	Atmosphere	Liu, Y.; Liu, Y.; Liu, Y.; Liu, Z.; Yang, W.; Li, K.	10.3390/atmos15070820	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
82	Flood forecasting using Internet of things and artificial neural networks	2016	IEEE	Mitra, P.; Ray, R.; Chatterjee, R.; Basu, R.; Saha, P.; Raha, S.; Barman, R.; Patra, S.; Biswas, S.S.; Saha, S.	10.1109/IEMCON.2016.7746363	Experimental	Inglês
83	Flood forecasting with Machine Learning in a scarce data layout	2023	IOP Conference Series: Earth and Environmental Science	Defontaine, T.; Ricci, S.; Lapeyre, C.; Marchandise, A.; Le Pape, E.	10.1088/1755-1315/1136/1/012020	Experimental	Inglês
84	Flood Modelling and Prediction Using Artificial Neural Network	2018	2018 IEEE INTERNATIONAL CONFERENCE ON INTERNET OF THINGS AND INTELLIGENCE SYSTEM (IOTAIS)	Sanubari, AR; Kusuma, PD; Setianingsih, C; IEEE	-	Experimental	Inglês
85	Flood Peak Prediction of Three Gorges Reservoir in China: Evidence from Artificial Intelligence and Observation Data	2025	JOURNAL OF HYDROLOGIC ENGINEERING	Wang, XP; Hua, HP; Meng, FW; Wu, BQ; Cao, H; Tang, ZY	10.1061/JHYEFF.HEENG-6359	Experimental	Inglês
86	Flood Prediction Using Rainfall-Flow Pattern in Data-Sparse Watersheds	2020	IEEE Access	Y. Zhu; J. Feng; L. Yan; T. Guo; X. Li	10.1109/ACCESS.2020.2971264	Experimental	Inglês
87	Flood warning system using internet of things, artificial intelligence and hydraulic modeling (case study: Behesht-Abad Watershed, Iran)	2024	ACTA GEOPHYSICA	Ghanbari, A; Tahmasebipour, N; Zeinivand, H; Heidari, MI; Abdollahi, S	10.1007/s11600-023-01174-6	Experimental	Inglês
88	Floods Prediction Using Radial Basis Function (RBF) Based on Internet of Things (IoT)	2019	2019 IEEE International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology (IAICT)	N. K. Ega Kartika; M. A. Murti; C. Setianingsih	10.1109/ICIAICT.2019.8784839	Experimental	Inglês
89	Forecast flows in a section of the Bogota River by Artificial Intelligent Systems	2015	2015 XLI LATIN AMERICAN COMPUTING CONFERENCE (CLEI)	Moscoso, WD; Agudelo-Otálora, LM	-	Experimental	Espanhol
90	Forecasting Daily Flood Water Level Using Hybrid Advanced Machine Learning Based Time-Varying Filtered Empirical Mode Decomposition Approach	2022	WATER RESOURCES MANAGEMENT	Jamei, M; Ali, M; Malik, A; Prasad, R; Abdulla, S; Yaseen, ZM	10.1007/s11269-022-03270-6	Experimental	Inglês
91	Forecasting Floods Using Deep Learning Models: A Longitudinal Case Study of Chenab River, Pakistan	2024	IEEE Access	K. Aatif; M. A. Fahiem; F. Tahir	10.1109/ACCESS.2024.3445586	Experimental	Inglês
92	Forecasting for Haditha reservoir inflow in the West of Iraq using Support Vector Machine (SVM)	2024	PLOS ONE	Mahmood, O.A.; Sulaiman, S.O.; Al-Jumeily OBE, D.	10.1371/journal.pone.0308266	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
93	Forecasting Multi-Step-Ahead Street-Scale Nuisance Flooding using a seq2seq LSTM Surrogate Model for Real-Time Application in a Coastal-Urban City	2025	JOURNAL OF HYDROLOGY	Roy, B; Goodall, JL; Mcspadden, D; Goldenberg, S; Schram, M	10.1016/j.jhydrol.2025.132697	Experimental	Inglês
94	Forecasting of compound ocean-fluvial floods using machine learning	2024	JOURNAL OF ENVIRONMENTAL MANAGEMENT	Moradian, S; Aghakouchak, A; Gharbia, S; Broderick, C; Abgh, AIO	10.1016/j.jenvman.2024.121295	Experimental	Inglês
95	Forecasting Time Series Water Levels on Mekong River Using Machine Learning Models	2016	2015 Seventh International Conference on Knowledge and Systems Engineering	Tung, T.-T.; Huu, Q.N.; Li, M.J.	10.1109/KSE.2015.53	Experimental	Inglês
96	Game-Theoretic Consensus Deep Learning for Adaptive Flood Prediction in Digital Twin Environments	2025	IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING	Djenouri, Y; Godziszewski, MT;;rade, F; Srivastava, G; Belbachir, AN; Murano, A	10.1109/JSTARS.2025.3596008	Experimental	Inglês
97	Global prediction of extreme floods in ungauged watersheds	2024	NATURE	Nearing, G; Cohen, D; Dube, V; Gauch, M; Gilon, O; Harrigan, S; Hassidim, A; Klotz, D; Kratzert, F; Metzger, A; Nevo, S; Pappenberger, F; Prudhomme, C; Shalev, G; Shenzis, S; Tekalign, TY; Weitzner, D; Matias, Y	10.1038/s41586-024-07145-1	Experimental	Inglês
98	GWO-driven adaptive runoff forecasting via hybrid deep learning networks of VMD-RPV and GRU-KAN	2025	JOURNAL OF HYDROINFORMATICS	Zhang, AB; Wang, ZC; Kang, NC; Wang, P	10.2166/hydro.2025.029	Experimental	Inglês
99	High Perplexity Mountain Flood Level Forecasting in Small Watersheds Based on Compound Long Short-Term Memory Model and Multimodal Short Disaster-Causing Factors	2025	IEEE Access	S. Wang; O. Xu	10.1109/ACCESS.2025.3567640	Experimental	Inglês
100	Hourly River Flow Forecasting: Application of Emotional Neural Network Versus Multiple Machine Learning Paradigms	2020	WATER RESOURCES MANAGEMENT	Yaseen, ZM; Naganna, SR; Sa'adi, Z; Samui, P; Ghorbani, MA; Salih, SQ; Shahid, S	10.1007/s11269-020-02484-w	Experimental	Inglês
101	How to improve fault tolerance in disaster predictions: A case study about flash floods using IoT, ML and real data	2018	Sensors	Furquim, G.; P R Filho, G.P.R.; Jalali, R.; Pessin, G.; Pazzi, R.W.; Ueyama, J.	10.3390/s18030907	Experimental	Inglês
102	Hybrid double ensemble empirical mode decomposition and K-Nearest Neighbors model with improved particle swarm optimization for water level forecasting	2025	ALEXANDRIA ENGINEERING JOURNAL	Someetheram, V; Marsani, MF; Kasihmuddin, MSM; Jamaludin, SZM; Mansor, MA; Zamri, NE	10.1016/j.aej.2024.12.035	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
103	Hydro-Informatic Modeling for Flood Prediction Through Explainable AI to Interpret Water Dynamics in Bangladesh Perspective	2024	2024 6th International Conference on Electrical Engineering and Information & Communication Technology (ICEEICT)	S. H. Mahir; M. T. AN TASHRIF; M. A. Hamza; T. H. Tamim; D. Kundu; A. Rahman	10.1109/ICEEICT62016.2024.10534521	Experimental	Inglês
104	HydroPredicT_Extreme: A probabilistic method for the prediction of extremal high-flow hydrological events	2022	JOURNAL OF HYDROLOGY	Molina, JL; Espejo, F; Zazo, S; Molina, MC; Hamitouche, M; Garcia-Arostegui, JL	10.1016/j.jhydrol.2022.127929	Experimental	Inglês
105	Identifying the Sensitivity of Ensemble Streamflow Prediction by Artificial Intelligence	2018	WATER	Chiang, YM; Hao, RN; Zhang, JQ; Lin, YT; Tsai, WP	10.3390/w10101341	Experimental	Inglês
106	Improving flood forecast accuracy based on explainable convolutional neural network by Grad-CAM method	2024	JOURNAL OF HYDROLOGY	Xiang, X; Guo, SL; Cui, Z; Wang, L; Xu, CY	10.1016/j.jhydrol.2024.131867	Experimental	Inglês
107	Improving Short-term Daily Streamflow Forecasting Using an Autoencoder Based CNN-LSTM Model	2024	WATER RESOURCES MANAGEMENT	Kumshe, UMM; Abdulhamid, ZM; Mala, BA; Muazu, T; Muhammad, AU; Sangary, O; Ba, AF; Tijjani, S; Adam, JM; Ali, MAH; Bello, AU; Bala, MM	10.1007/s11269-024-03937-2	Experimental	Inglês
108	Improving the accuracy of a flood forecasting model by means of machine learning and chaos theory: A case study involving a real wireless sensor network deployment in Brazil	2016	Neural Computing and Applications	Furquim, G.; Pessin, G.; Façal, B.S.; Mendiondo, E.M.; Ueyama, J.	10.1007/s00521-015-1930-z	Experimental	Inglês
109	Integration of Genetic Algorithm and Support Vector Machine for Water Discharge Prediction in River Basin System	2025	2025 3rd International Conference on Disruptive Technologies (ICDT)	A. Yadav; H. Mishra; A. K. Pradhan; B. Sah; D. Joshi	10.1109/ICDT63985.2025.10986493	Experimental	Inglês
110	Interpretable spatio-temporal attention LSTM model for flood forecasting	2020	Neurocomputing	Ding, Y.; Zhu, Y.; Feng, J.; Zhang, P.; Cheng, Z.	10.1016/j.neucom.2020.04.110	Experimental	Inglês
111	Interpreting runoff forecasting of long short-term memory network: An investigation using the integrated gradient method on runoff data from the Han River Basin	2023	JOURNAL OF HYDROLOGY-REGIONAL STUDIES	Jing, X; Luo, JA; Zuo, GG; Yang, X	10.1016/j.ejrh.2023.101549	Experimental	Inglês
112	IoT-Enabled Flood Severity Prediction via Ensemble Machine Learning Models	2020	IEEE Access	M. Khalaf; H. Alaskar; A. J. Hussain; T. Baker; Z. Maamar; R. Buyya; P. Liatsis; W. Khan; H. Tawfik; D. Al-Jumeily	10.1109/ACCESS.2020.2986090	Experimental	Inglês
113	Leveraging Recurrent Neural Networks for Flood Prediction and Assessment	2025	Hydrology	Heidari, E.; Samadi, V.; Khan, A.A.	10.3390/hydrology12040090	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
114	Long Short-Term Memory for Discharge Estimation in Coastal Neretva River	2023	2023 8th International Conference on Smart and Sustainable Technologies (SpliTech)	A. M. Mihel; N. Kravica; J. Lerga	10.23919/SpliTech58164.2023.10193648	Experimental	Inglês
115	Machine learning techniques for flood forecasting	2024	JOURNAL OF HYDROINFORMATICS	Hadi, FA; Sidek, LM; Salih, GHA; Basri, H; Sammen, SS; Dom, NM; Ali, ZM; Ahmed, AN	10.2166/hydro.2024.208	Experimental	Inglês
116	Machine Learning Techniques for River Discharge Prediction Using ERA5 and GloFAS Data	2022	2022 IEEE 13TH ANNUAL UBIQUITOUS COMPUTING, ELECTRONICS & MOBILE COMMUNICATION CONFERENCE (UEMCON)	Rahman, MH; Zaman, IU; Ahmed, K; Bushra, F; Khan, NZ; Rahman, RM	10.1109/UEMCON54665.2022.9965629	Experimental	Inglês
117	Machine Learning-based Prediction of Maximum Inundation Depth and Maximum Inundation Flow Rate for Flooding	2024	2024 5th International Conference on Computer, Big Data and Artificial Intelligence (ICCBD+AI)	T. Tian; L. Jiang; Z. Zhang; L. Yang; X. Cheng	10.1109/ICCBD-AI65562.2024.00116	Experimental	Inglês
118	Modeling streamflow in non-gauged watersheds with sparse data considering physiographic, dynamic climate, and anthropogenic factors using explainable soft computing techniques	2024	JOURNAL OF HYDROLOGY	Madhushani, C; Dananjaya, K; Ekanayake, IU; Meddage, DPP; Kantamaneni, K; Rathnayake, U	10.1016/j.jhydrol.2024.130846	Experimental	Inglês
119	Modelling for Improved Flood Forecasting in the Bow River Basin Using Prophet	2025	Journal of Environmental Informatics Letters	Dash, A.A.; Castro, K.; McBean, E.	10.3808/jeil.202400143	Experimental	Inglês
120	Mountain Flood Level Forecasting in Small Watersheds Based on Recurrent Neural Networks and Multi-Dimensional Data	2024	IEEE Access	S. Wang; O. Xu	10.1109/ACCESS.2024.3412948	Experimental	Inglês
121	Multiscale homogenized predictive modelling of flooding surface in urban cities using physics-induced deep AI with UPC	2022	Journal of Cleaner Production	Chew, A.W.; He, R.; Zhang, L.	10.1016/j.jclepro.2022.132455	Experimental	Inglês
122	Multi-source rainfall merging and reservoir inflow forecasting by ensemble technique and artificial intelligence	2022	Journal of Hydrology: Regional Studies	Chiang, Y.-M.; Hao, R.-N.; Xu, Y.-P.; Liu, L.	10.1016/j.ejrh.2022.101204	Experimental	Inglês
123	Multi-step ahead probabilistic runoff forecasting with SHAP interpretability: a GPR-enhanced deep learning ensemble approach integrating teleconnection factors	2025	ENVIRONMENTAL MODELLING & SOFTWARE	Zhu, FL; Hou, TT; Zhu, O; Sun, YT; Liu, WF; Zhao, LQ; Guo, XN; Li, M; Zhong, PA	10.1016/j.envsoft.2025.106647	Experimental	Inglês
124	Nowcast flood predictions in the Amazon watershed based on the remotely sensed rainfall product PDIRnow and artificial neural networks	2024	ENVIRONMENTAL MONITORING AND ASSESSMENT	Ramos, HA; Uliana, EM; Aires, URV; da Cruz, IF; Lisboa, L; da Silva, DD; Viola, MR; Duarte, VBR	10.1007/s10661-024-12396-6	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
125	Optimized Model Inputs Selections for Enhancing River Streamflow Forecasting Accuracy Using Different Artificial Intelligence Techniques	2022	Water Resources Management	Tofiq, Y.M.; Latif, S.D.; Ahmed, A.N.; Kumar, P.; El-Shafie, A.	10.1007/s11269-022-03339-2	Experimental	Inglês
126	Optimized simulation of river flow rate using regression-based models	2023	Acta Geophysica	Bahramifar, A.; Afshin, H.; Emami Tabrizi, M.	10.1007/s11600-022-00976-4	Experimental	Inglês
127	Particle swarm optimization based LSTM networks for water level forecasting: A case study on Bangladesh river network	2023	RESULTS IN ENGINEERING	Ruma, JF; Adnan, MSG; Dewan, A; Rahman, RM	10.1016/j.rineng.2023.100951	Experimental	Inglês
128	Performance analysis of physically-based (HEC-RAS, CADDIES) and AI-based (LSTM) flood models for two case studies	2024	RIVER BASIN DISASTER RESILIENCE AND SUSTAINABILITY BY ALL, ICFM 9, 2023	de Macedo, MB; Mangukiya, NK; Fava, MC; Sharma, A; da Silva, RF; Agarwal, A; Razzolini, MT; Mendiando, EM; Goel, NK; Kurian, M; Nardocci, AC	10.5194/piahs-386-41-2024	Experimental	Inglês
129	Performance evaluation of artificial intelligence paradigms-artificial neural networks, fuzzy logic, and adaptive neuro-fuzzy inference system for flood prediction	2021	ENVIRONMENTAL SCIENCE AND POLLUTION RESEARCH	Tabbussum, R; Dar, AQ	10.1007/s11356-021-12410-1	Experimental	Inglês
130	Performance improvement of the linear muskingum flood routing model using optimization algorithms and data assimilation approaches	2023	NATURAL HAZARDS	Salvati, A; Nia, AM; Salajegheh, A; Moradi, P; Batmani, Y; Najafi, S; Shirzadi, A; Shahabi, H; Sheikh-Akbari, A; Jun, C; Clague, JJ	10.1007/s11069-023-06113-8	Experimental	Inglês
131	Physics-Informed Neural Networks for Modeling Water Flows in a River Channel	2024	IEEE Transactions on Artificial Intelligence	L. F. Nazari; E. Camponogara; L. O. Seman	10.1109/TAI.2022.3200028	Experimental	Inglês
132	Predicting flood stages in watersheds with different scales using hourly rainfall dataset: A high-volume rainfall features empowered machine learning approach	2024	Science of the Total Environment	Qiao, L.; Livsey, D.; Wise, J.; Kadavy, K.; Hunt, S.; Wagner, K.	10.1016/j.scitotenv.2024.175231	Experimental	Inglês
133	Predicting River Flow Using an AI-Based Sequential Adaptive Neuro-Fuzzy Inference System	2020	WATER	Belvederesi, C; Dominic, JA; Hassan, QK; Gupta, A; Achari, G	10.3390/w12061622	Experimental	Inglês
134	Prediction of Flood Discharge Using Hybrid PSO-SVM Algorithm in Barak River Basin	2023	MethodsX	Samantaray, S.; Sahoo, A.; Agnihotri, A.	10.1016/j.mex.2023.102060	Experimental	Inglês
135	Prediction of the monthly river water level by using ensemble decomposition modeling	2025	SCIENTIFIC REPORTS	Pande, CB; Sidek, LM; Halder, B; Katipoglu, OM; Rajput, J; Alshehri, F; Chakraborty, R; Pal, SC; Dom, NM; Scholz, M	10.1038/s41598-025-10893-3	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
136	Probabilistic Diffusion Models Advance Extreme Flood Forecasting	2025	GEOPHYSICAL RESEARCH LETTERS	Ou, ZG; Nai, C; Pan, BX; Zheng, Y; Shen, CP; Jiang, PS; Liu, XC; Tang, QH; Li, WQ; Pan, M	10.1029/2025GL115705	Experimental	Inglês
137	Project Apaw: Spatiotemporal Forecasting of River Flood Using Deep Learning	2023	2023 IEEE 15th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)	J. J. S. Oñate; C. D. Omorog; R. O. Onesa; K. M. N. Fortuno; B. D. Benosa; K. M. R. Tabal; I. P. Benitez; P. A. M. Serrano; F. B. Prianes; I. F. Baluis	10.1109/HNICEM60674.2023.10589082	Experimental	Inglês
138	Projected Water Levels and Identified Future Floods: A Comparative Analysis for Mahaweli River, Sri Lanka	2023	IEEE Access	N. Rathnayake; U. Rathnayake; I. Chathuranika; T. L. Dang; Y. Hoshino	10.1109/ACCESS.2023.3238717	Experimental	Inglês
139	Real-time Neural-network-based Ensemble Typhoon Flood Forecasting Model with Self-organizing Map Cluster Analysis: A Case Study on the Wu River Basin in Taiwan	2022	WATER RESOURCES MANAGEMENT	Jhong, YD; Lin, HP; Chen, CS; Zhong, BC	10.1007/s11269-022-03197-y	Experimental	Inglês
140	Research on Flood Forecasting Model Based on Artificial Intelligence Technology	2025	2025 10th International Conference on Cloud Computing and Big Data Analytics (ICCCBDA)	X. -j. Yu; J. Meng; L. Sha; L. -h. Liu	10.1109/ICCCBDA64898.2025.11030434	Experimental	Inglês
141	Research on particle swarm optimization in LSTM neural networks for rainfall-runoff simulation	2022	JOURNAL OF HYDROLOGY	Xu, YH; Hu, CH; Wu, Q; Jian, SQ; Li, ZC; Chen, YQ; Zhang, GD; Zhang, ZX; Wang, SL	10.1016/j.jhydrol.2022.127553	Experimental	Inglês
142	Research on prediction model of mountain flood level in small watershed based on deep learning	2022	2022 4th International Conference on Intelligent Control, Measurement and Signal Processing (ICMSP)	S. Wang; J. Wang	10.1109/ICMSP55950.2022.9859047	Experimental	Inglês
143	RFM_Trans: Runoff forecasting model for catchment flood protection using strategies optimized Transformer	2025	EXPERT SYSTEMS WITH APPLICATIONS	Bao, NN; Li, CY; Yan, XT; Liu, MY	10.1016/j.eswa.2025.127228	Experimental	Inglês
144	River discharge simulation using variable parameter McCarthy-Muskingum and wavelet-support vector machine methods	2020	NEURAL COMPUTING & APPLICATIONS	Yadav, B; Mathur, S	10.1007/s00521-018-3745-1	Experimental	Inglês
145	River Flow Estimation Using Artificial Intelligence and Fuzzy Techniques	2020	WATER	Ünes, F; Demirci, M; Zelenakova, M; Çalisici, M; Tasar, B; Vranay, F; Kaya, YZ	10.3390/w12092427	Experimental	Inglês
146	Robust Runoff Prediction With Explainable Artificial Intelligence and Meteorological Variables From Deep Learning Ensemble Model	2023	WATER RESOURCES RESEARCH	Wu, JH; Wang, ZC; Dong, JH; Cui, XF; Tao, S; Chen, X	10.1029/2023WR035676	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
147	Runoff Prediction Method Based on Pangu-Weather	2025	WATER	Yang, WT; Qin, H; Jie, YS; Qu, YH; Zhang, TH; Li, CH; Tan, L	10.3390/w17091405	Experimental	Inglès
148	Runoff simulation based on granular computing by introducing terrain factors to construct climate characteristic index	2025	JOURNAL OF HYDROLOGY	Zhao, YM; Dong, NP; Ma, C; Wang, H	10.1016/j.jhydrol.2025.133614	Experimental	Inglès
149	Short- and long-term streamflow forecasting using wavelet neural networks for complex watersheds: A case study in the Mahanadi River, India	2023	ECOLOGICAL INFORMATICS	Santos, CAG; do Nascimento, GR; de Farias, CAS; da Silva, RM; Mishra, M	10.1016/j.ecoinf.2022.101945	Experimental	Inglès
150	Short-Term Flood Prediction Model Based on Pre-Training Enhancement	2024	ELECTRONICS	Xia, Y; Lu, JM	10.3390/electronics13112203	Experimental	Inglès
151	Short-term prediction of flood events in a small urbanized watershed using multi-year hydrological records	2015	21ST INTERNATIONAL CONGRESS ON MODELLING AND SIMULATION (MODSIM2015)	Saffarpour, S; Erechtkoukova, MG; Khaite, PA; Chen, SY; Herallal, M	-	Experimental	Inglès
152	Short-Term River Flood Forecasting Using Composite Models and Automated Machine Learning: The Case Study of Lena River	2021	WATER	Sarafanov, M; Borisova, Y; Maslyayev, M; Revin, I; Maximov, G; Nikitin, NO	10.3390/w13243482	Experimental	Inglès
153	Short-term River streamflow modeling using Ensemble-based additive learner approach	2021	JOURNAL OF HYDRO-ENVIRONMENT RESEARCH	Khosravi, K; Miraki, S; Saco, PM; Farmani, R	10.1016/j.jher.2021.07.003	Experimental	Inglès
154	Short-term water level prediction using different artificial intelligent models	2016	2016 Fifth International Conference on Agro-Geoinformatics (Agro-Geoinformatics)	S. Zhang; L. Lu; J. Yu; H. Zhou	10.1109/Agro-Geoinformatics.2016.7577678	Experimental	Inglès
155	Simulating rainfall-runoff process with a new combined artificial intelligence	2024	Environmental Resources Research	Bababali, H.; Dehghani, R.	10.22069/ijerr.2024.22134.1424	Experimental	Inglès
156	Streamflow Prediction in the Mekong River Basin Using Deep Neural Networks	2023	IEEE Access	T. -T. -H. Nguyen; D. -Q. Vu; S. T. Mai; T. D. Dang	10.1109/ACCESS.2023.3301153	Experimental	Inglès
157	Streamflow prediction using an integrated methodology based on convolutional neural network and long short-term memory networks	2021	SCIENTIFIC REPORTS	Ghimire, S; Yaseen, ZM; Farooque, AA; Deo, RC; Zhang, J; Tao, XH	10.1038/s41598-021-96751-4	Experimental	Inglès
158	Streamflow Prediction Using Deep Learning Neural Network: Case Study of Yangtze River	2020	IEEE Access	D. Liu; W. Jiang; L. Mu; S. Wang	10.1109/ACCESS.2020.2993874	Experimental	Inglès

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
159	Streamflow prediction using support vector regression machine learning model for Tehri Dam	2024	APPLIED WATER SCIENCE	Sharma, B; Goel, NK	10.1007/s13201-024-02135-0	Experimental	Inglês
160	Streamflow prediction with large climate indices using several hybrid multilayer perceptrons and copula Bayesian model averaging	2021	ECOLOGICAL INDICATORS	Panahi, F; Ehteram, M; Ahmed, AN; Huang, YF; Mosavi, A; El-Shafie, A	10.1016/j.ecolind.2021.108285	Experimental	Inglês
161	Streamlining River Flood Prevention with an Integrated AIoT Framework	2023	2023 20TH ACS/IEEE INTERNATIONAL CONFERENCE ON COMPUTER SYSTEMS AND APPLICATIONS, AICCSA	Boulouard, Z; Ouaisa, M; Ouaisa, M; Krichen, M; Almutiq, M; Algarni, M; IEEE	10.1109/AICCSA59173.2023.10479264	Experimental	Inglês
162	Support vector regression optimized by meta-heuristic algorithms for daily streamflow prediction	2020	STOCHASTIC ENVIRONMENTAL RESEARCH AND RISK ASSESSMENT	Malik, A; Tikhamarine, Y; Souag-Gamane, D; Kisi, O; Pham, QB	10.1007/s00477-020-01874-1	Experimental	Inglês
163	Testing the Feasibility of an Agent-Based Model for Hydrologic Flow Simulation	2024	INFORMATION	Simmonds, J; Gómez, JA; Ledezma, A	10.3390/info15080448	Experimental	Inglês
164	Towards a better consideration of rainfall and hydrological spatial features by a deep neural network model to improve flash floods forecasting: case study on the Gardon basin, France	2023	MODELING EARTH SYSTEMS AND ENVIRONMENT	Saint-Fleur, BE; Allier, S; Lassara, E; Rivet, A; Artigue, G; Pistre, S; Johannet, A	10.1007/s40808-022-01650-w	Experimental	Inglês
165	Transfer learning for streamflow forecasting using unguaged MOPEX basins data set	2023	EARTH SCIENCE INFORMATICS	Muhammad, AU; Abba, SI	10.1007/s12145-023-00952-6	Experimental	Inglês
166	Tree-based machine learning algorithms in the Internet of Things environment for multivariate flood status prediction	2021	Journal of Intelligent Systems	Aswad, F.M.; Noori, A.N.; Khudhur, A.M.; Khalaf, B.A.; Mostafa, S.A.	10.1515/jisys-2021-0179	Experimental	Inglês
167	Uncertainty Forecasting Model for Mountain Flood Based on Bayesian Deep Learning	2024	IEEE Access	S. Wang; O. Xu	10.1109/ACCESS.2024.3384066	Experimental	Inglês
168	Understanding Catchment Impacts: Enhanced Water Level Prediction with LSTM and Explainable AI	2024	2024 6th International Conference on Advancements in Computing (ICAC)	J. L. Wijayaraja; N. D. U. Gamage; P. V. N. U. Pallegangoda; N. Priyashantha; W. B. M. R. Weerasekara; P. K. W. Abeygunawardhana	10.1109/ICAC64487.2024.10851183	Experimental	Inglês
169	Urban Pluvial Flood Forecasting using Open Data with Machine Learning Techniques in Pattani Basin	2017	Procedia Computer Science	Noymanee, J.; Nikitin, N.O.; Kalyuzhnaya, A.V.	10.1016/j.procs.2017.11.187	Experimental	Inglês
170	Use of computational intelligence techniques to predict flooding in places adjacent to the Magdalena River	2020	HELIYON	Moreno, JM; Sánchez, JM; Espitia, HE	10.1016/j.heliyon.2020.e04872	Experimental	Inglês

ID	Título	Ano	Revista/Base	Autores	DOI	Tipo	Idioma
171	Using a physics-based hydrological model and storm transposition to investigate machine-learning algorithms for streamflow prediction	2024	JOURNAL OF HYDROLOGY	Gurbuz, F; Mudireddy, A; Mantilla, R; Xiao, SP	10.1016/j.jhydrol.2023.130504	Experimental	Inglês
172	Using machine learning and satellite data to improve flood forecasting: the case of the Ouémé basin at the Bétérout outlet	2025	HYDROLOGY RESEARCH	Obada, E; Biao, EI; Zohou, PJ; Yarou, H; Hounnondaho, FZ; Alamou, EA	10.2166/nh.2025.133	Experimental	Inglês
173	Water Level Prediction Model Based on GRU and CNN	2020	IEEE Access	M. Pan; H. Zhou; J. Cao; Y. Liu; J. Hao; S. Li; C. -H. Chen	10.1109/ACCESS.2020.2982433	Experimental	Inglês
174	Water resource management and flood mitigation: hybrid decomposition EMD-ANN model study under climate change	2024	SUSTAINABLE WATER RESOURCES MANAGEMENT	Ahmad, N; Yi, X; Tayyab, M; Zafar, MH; Akhtar, N	10.1007/s40899-024-01048-9	Experimental	Inglês

APÊNDICE B - DADOS DO BLOCO DE MODELAGEM

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
1	CNN; RNN (LSTM); Neural ODE	CNN-RNN; Neural ODE	Python v0.2.5 (torchdiffeq); ArcGIS v10.8.2	Meteorológico; Hidrológico
2	Support Vector Machine (SVM); Gaussian Process (GP); Multilayer Perceptron (MLP)	SVM (epsilon-SVR; nu-SVR)	WEKA (Waikato Environment for Knowledge Analysis)	Hidrológico; Pluviométrico
3	SOM-R-NARX; Fuzzy Inference System (FIS)	-	Microsoft SQL Server; Google Maps	Hidrológico; Meteorológico
4	Random Forest; Logistic Regression; K-Nearest Neighbors; Support Vector Classifier	Random Forest; Logistic Regression; K-Nearest Neighbors; Support Vector Classifier	Scikit-Learn; TensorFlow 2	Meteorológico
5	Deep Neural Network (DNN)	LSTM; GRU	-	Hidrológico; Meteorológico
6	Artificial Neural Network (ANN); Support Vector Machine (SVM); Hydrologiska Byråns Vattenbalansavdelning (HBV); WRF-Hydro; Ensemble model	Artificial Neural Network (ANN); Support Vector Machine (SVM); Hydrologiska Byråns Vattenbalansavdelning (HBV); WRF-Hydro; Ensemble model	-	Hidrológico; Meteorológico
7	Supervised Brain Emotional Learning (SBEL)	Multilayer Perceptron (MLP)	MATLAB R2014b	Hidrológico; Pluviométrico
8	Logistic Regression; Neural Network; Support Vector Machine	Logistic Regression; Neural Network; Support Vector Machine	Python (Jupyter Notebook); Excel 2016	Hidrológico; Meteorológico
9	Random Forest (RF); Adaptive Boosting (AdaBoost); Extreme Gradient Boosting (XGB); attention-based stacking (ATE)	Simple Averaging Ensemble (SAE); Weighted Averaging Ensemble (WAE); RF; AdaBoost; XGB	Python; Hyperopt	Hidrológico; Pluviométrico
10	Attention-LSTM; LSTM; BPNN; SVM	BPNN; SVM; LSTM	Python 3.6; Keras; Matplotlib; Pandas; Ubuntu 16.04	Meteorológico; Hidrológico; Pluviométrico
11	Artificial Neural Network (ANN) de segunda geração (com backpropagation modificado)	Single-layer perceptron; Multilayer perceptron; CNN; RNN; métodos estatísticos e hidrológicos	TensorFlow (API); Python; GIS	Hidrológico; Meteorológico; Pluviométrico
12	Feedforward Neural Network (FNN); Long Short-Term Memory Recurrent Neural Network (LSTM-RNN); Temporal Fusion Transformer-Convolutional Neural Network (TFT-CNN)	MK11; MGSVM; Egrp; LWLR-RF; RandomForestClassifier; LightGBM	TensorFlow; PyTorch; Flower Framework	Hidrológico; Meteorológico; Pluviométrico
13	LSTM; GRU; XGBoost; Cloud model (combinação); SE-Cloud (Cloud + Copula)	BMA; S-BMA; modelos determinísticos (Cloud)	-	Hidrológico; Meteorológico; Pluviométrico
14	Random Forest (RF); Artificial Neural Network (ANN); Support Vector Regression (SVR); K-Nearest Neighbors (KNN); Gradient Boosting (GB); Extreme Gradient Boosting (XGBoost); Hybrid RF-SARIMA	SARIMA; RF; ANN; SVR; KNN; GB; XGBoost	-	Hidrológico
15	Generalized Structure of Group Method of Data Handling (GSGMDH)	Modelos hidrológicos convencionais; comparações com AI anteriores	-	Hidrológico; Meteorológico
16	S-RNN; LSTM; GRU; Bi-LSTM; Bi-GRU	HEC-RAS (modelo hidráulico clássico)	TensorFlow; Keras; Python 3.12	Hidrológico

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
17	Gene Expression Programming (GEP); Random Forest Regression (RFR); Ensemble Empirical Mode Decomposition (EEMD); Variational Mode Decomposition (VMD)	GEP; RFR (modelos standalone)	-	Hidrológico; Pluviométrico
18	ANN; DWT-ANN; M-DWT-ANN	ANN; DWT-ANN	MATLAB R2018	Hidrológico; Pluviométrico; Meteorológico
19	Deep Neural Network (DNN); Long Short-Term Memory (LSTM); Extreme Gradient Boosting (XGBoost); Random Forest (RF); Decision Tree (Tree)	DNN; LSTM; RF; Tree; XGBoost	-	Hidrológico; Meteorológico
20	Adaptive Neuro-Fuzzy Inference System (ANFIS); Multi-Layer Perceptron Neural Network (MLP-NN)	Support Vector Machine (SVM); Boosted Decision Tree (citados em comparação externa)	MATLAB	Hidrológico; Pluviométrico
21	Support Vector Machine (SVM); Hybrid SVM-Whale Optimization Algorithm (SVM-WOA)	SVM	-	Hidrológico; Meteorológico; Pluviométrico
22	Adaptive Neuro-Fuzzy Inference System (ANFIS); Extreme Learning Machine (ELM); Emotional Neural Network (ENN); Support Vector Machine (SVM); Gaussian Process Regression (GPR)	Adaptive Neuro-Fuzzy Inference System (ANFIS); Extreme Learning Machine (ELM); Emotional Neural Network (ENN); Support Vector Machine (SVM); Gaussian Process Regression (GPR)	-	Hidrológico
23	iTransformer	ARIMA; XGBoost; LSTM	pmdarima; GridSearchCV; Google Colab; Nvidia T4 GPU	Hidrológico; Pluviométrico
24	Proposed Method (PM) — 2-D Error Minimization with upstream pixels; Multilayer Perceptron (MLP); Extreme Learning Machine (ELM); Radial Basis Function (RBF); Linear Regression (LR)	Linear Regression; MLP; ELM; RBF	MATLAB	Hidrológico; Sensoriamento remoto
25	Multi-Linear Regression (MLR); Random Forest (RF); Gradient Boosting (GB); Multi-Layer Perceptron (MLP); Recurrent Neural Network (RNN); Convolutional Neural Network (CNN)	Multi-Linear Regression (MLR); Random Forest (RF); Gradient Boosting (GB); Multi-Layer Perceptron (MLP); Recurrent Neural Network (RNN); Convolutional Neural Network (CNN)	Python 3.7; scikit-learn 1.0.2; Keras 2.9.0; TensorFlow 2.9.1	Hidrológico
26	Random Forest (RF); Support Vector Classifier (SVC); Multi-Layer Perceptron (MLP); Support Vector Regression (SVR)	Most Common Category (MCC) baseline; comparação entre MLP e SVR	Python; Scikit-learn; MATLAB (para execução de ANN)	Hidrológico; Meteorológico
27	Random Forest (RF); Long Short-Term Memory (LSTM)	Gradient Boosting (GB); K-Nearest Neighbors (KNN); Linear Regression (LR); Decision Tree (DT); Ridge (L2); Extreme Gradient Boosting (XGB)	Python 3.11.4; Scikit-learn; Keras (LSTM); XGBoost	Hidrológico; Pluviométrico; Piezométrico
28	RNN-LSTM; GRU	HEC-HMS	-	Hidrológico; Meteorológico
29	Feed-Forward Backpropagation Neural Network (FFBP); Adaptive Neuro-Fuzzy Inference System (ANFIS); Random Forest (RF); XGBoost; LightGBM; CatBoost	FFBP; ANFIS; RF; XGBoost; LightGBM; CatBoost (comparativos entre si)	MATLAB R2021a (nntool); Python (Scikit-learn; XGBoost; LightGBM; CatBoost)	Hidrológico; Meteorológico; Pluviométrico

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
30	Adaptive Neuro-Fuzzy Inference System (ANFIS); Wavelet-ANFIS (Neuro-fuzzy-wavelet)	Wavelet-ANN; ANN	MATLAB	Hidrológico; Meteorológico
31	CatBoost; XGBoost; LightGBM; LSTM; Backpropagation (BP) neural network; KNN; SVR	CatBoost; XGBoost; LightGBM; LSTM; BP; KNN; SVR (intercomparação entre si)	-	Hidrológico; Pluviométrico
32	Long Short-Term Memory (LSTM)	ARIMA	-	Hidrológico; Meteorológico
33	GR5J; HBV; MLPNN; RFR; VMD-MLPNN; VMD-RFR	GR5J; HBV; MLPNN; RFR	-	Hidrológico; Meteorológico
34	Support Vector Machine (SVM); Decision Tree; Lasso (Least Absolute Shrinkage and Selection Operator)	SVM; Decision Tree; Lasso	-	Hidrológico; Pluviométrico; Meteorológico
35	ANN; SVM	ARR RFFA model (comparativo externo)	-	Hidrológico; Pluviométrico
36	SWAT+; Support Vector Regression (SVR); Feed Forward Neural Network (FFNN); Long Short-Term Memory (LSTM); Ensemble Machine Learning	SWAT+; Support Vector Regression (SVR); Feed Forward Neural Network (FFNN); Long Short-Term Memory (LSTM); Ensemble Machine Learning	Python 3.6 (TensorFlow; Scikit-learn; Keras; Pyrenn; SHAP)	Hidrológico; Meteorológico; Pluviométrico
37	Feed-Forward Neural Network (FFNN); Convolutional Neural Network (CNN); Long Short-Term Memory (LSTM); Gated Recurrent Unit (GRU); Stacked LSTM; Bidirectional LSTM (BiLSTM)	FFNN; CNN; LSTM; GRU; Stacked LSTM; BiLSTM (comparação entre si)	Python; TensorFlow; Keras	Hidrológico
38	Local Linear Regression (LLR); Dynamic Local Linear Regression (DLLR); Two Layer Back Propagation (TLBP); Conjugate Gradient (CG); Broyden-Fletcher-Goldfarb-Shanno (BFGS)-based ANN	Nenhum modelo hidrológico tradicional; comparação entre IA	-	Hidrológico; Meteorológico
39	Artificial Neural Network (ANN)	HEC-RAS (modelo físico)	MATLAB Neural Network Toolbox; HEC-RAS	Hidrológico; Meteorológico; Pluviométrico
40	Linear Regression; Ridge Regression; Lasso Regression; Polynomial Regression; Support Vector Regression; Decision Tree Regression; Random Forest Regression; Gradient Boosting Regression; Bayesian Ridge Regression	Linear Regression; Ridge Regression; Lasso Regression; Polynomial Regression; Support Vector Regression; Decision Tree Regression; Random Forest Regression; Gradient Boosting Regression; Bayesian Ridge Regression	Python; Scikit-learn; LIME; SHAP	Hidrológico; Meteorológico; Ambiental
41	Long Short-Term Memory (LSTM); Recurrent Neural Network (RNN)	Modelos comparados: RNN tradicional	Python; TensorFlow; NumPy; Pandas; Matplotlib	Hidrológico; Meteorológico; Pluviométrico
42	LSTM; SWAT+-LSTM (modelo acoplado)	SWAT+ (standalone); LSTM (standalone); SWAT+-LSTM com parâmetros default; SWAT+-LSTM com SWAT+ calibrado	Python 3.6; TensorFlow; scikit-learn; SHAP (DeepExplainer); SWATplusCUP	Hidrológico; Meteorológico; Pluviométrico
43	Convolution Regression based on Machine Learning (CRML)	HEC-HMS; XAJ; TOPKAPI; ANN; SVM; Decision Tree; Logistic Regression	-	Hidrológico; Meteorológico
44	Support Vector Machine (SVM); Particle Swarm Optimization (PSO)	Artificial Neural Network (ANN); Modelos estatísticos convencionais	-	Hidrológico; Meteorológico
45	Convolutional Neural Network (CNN); Random Forest (RF); Gradient Tree Boosting (GTB); Multilayer Perceptron (MLP)	Nenhum modelo hidrológico; comparação interna entre algoritmos	-	Hidrológico

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
46	Support Vector Machine (SVM); Artificial Flora (AF)	Wavelet-SVM; Bayesian-SVM	MATLAB (parâmetros otimizados por tentativa e erro)	Hidrológico
47	ANN (MLP); LSTM	MLP vs. LSTM	Matlab	Hidrológico; Meteorológico; Pluviométrico
48	Temporal Fusion Transformer (TFT)	HBV; persistência (benchmark)	Python 3.9.18; PyTorch Forecasting; PyTorch Lightning; Eclipse IDE 2024-03 (4.31.0)	Hidrológico; Meteorológico; Geomorfológico
49	MLP	LSTM; SVM; RF; ELM	Keras	Hidrológico; Meteorológico
50	Transfer Learning Transformer (TL-Transformer);	TOPMODEL; LSTM; TL-LSTM; MLP; TL-MLP; Transformer	Python 3.9; PyTorch; Pandas; NumPy; PySwarms	Hidrológico; Meteorológico
51	Convolutional Neural Network (CNN) com blocos ResNet; Long Short-Term Memory (LSTM); XAJ-LSTM (híbrido)	ECMWF bruto (EC); Quantile Mapping (QM); modelo XAJ autônomo	NeuralHydrology (pacote Python); código e dados disponibilizados (repositórios declarados)	Hidrológico; Meteorológico; Pluviométrico
52	Artificial Neural Networks; Multilayer Perceptrons (MLP)	Persistence model (referência)	MATLAB R2012A (Neural Network Toolbox)	Hidrológico; Meteorológico
53	LSTM (Long Short-Term Memory)	Medição in loco — não foram citados outros modelos comparativos	Python	Hidrológico; Meteorológico
54	Random Forest	-	-	Hidrológico; Pluviométrico
55	Extreme Gradient Boosting (XGBoost); Genetic Algorithm (GA); Differential Evolution (DE)	Random Forest (RF); Classification and Regression Tree (CART)	R (xgboost; GA; randomForest; rpart)	Hidrológico; Meteorológico
56	Genetic Expression Programming (GEP)	Muskingum model (linear e não linear)	GeneXproTools 4.0 (Ferreira, 2006)	Hidrológico
57	Online Sequential Extreme Learning Machine (OS-ELM)	Artificial Neural Network (ANN); Support Vector Machine (SVM); Genetic Programming (GP)	MATLAB R2014a; LIBSVM; Discipulus	Hidrológico; Meteorológico
58	Long Short-Term Memory (LSTM); LSTM + Attention Layers (ATT)	Long Short-Term Memory (LSTM); LSTM + Attention Layers (ATT)	TensorFlow v2.16; Delft3D; OpenDA; HydroEval (bibliotecas Python e software hidrodinâmico)	Hidrológico; Meteorológico; Pluviométrico
59	ANFIS-GOA; ANFIS-GWO; ANFIS;	ANFIS-GOA; ANFIS-GWO; ANFIS;	-	Hidrológico; Meteorológico
60	Artificial Neural Network (ANN); Linear Regression (LR)	Artificial Neural Network (ANN); Linear Regression (LR); Auto-Regressive Integrated Moving Average (ARIMA);	SPSS v20.0	Hidrológico; Meteorológico
61	MLP; LSTM; GRU; AMLP; ALSTM; AGRU	MLP; LSTM; GRU (baselines frente às versões com atenção AMLP; ALSTM; AGRU)	-	Hidrológico
62	Support Vector Machine (SVM); Artificial Neural Network (ANN); Nearest Neighbours Classification (NNC); Linear & Polynomial Regression (LPR)	Support Vector Machine (SVM); Artificial Neural Network (ANN); Nearest Neighbours Classification (NNC); Linear & Polynomial Regression (LPR)	Python (Scikit-learn; Jupyter Notebook); GIS; WMS	Hidrológico; Meteorológico; Sensoriamento remoto
63	Artificial Neural Network (ANN); Random Forest; Decision Tree; Diffusion model	Comparação entre ANN; Random Forest; Decision Tree; Diffusion model	Python 3.7.14; NumPy; Pandas; Scikit-Learn; TensorFlow; Keras; Matplotlib	Hidrológico; Meteorológico
64	CNN-LSTM-Attention (Hybrid Deep Learning Model)	SVM; Logistic Regression; Multinomial Naive Bayes; KNN; CNN; LSTM	Python (NumPy; Pandas; Scikit-learn; TensorFlow; Keras; Matplotlib; SHAPASH)	Hidrológico; Meteorológico

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
65	Attention-based LSTM; LSTM; Transformer	Naïve Method benchmark (comparativo)	-	Hidrológico; Meteorológico; Ambiental
66	LSTM (Long Short-Term Memory)	ESP (Ensemble Streamflow Prediction); ECMWF/CSSPv2 Meteo-Hydro	Python; ECMWF datasets; CSSPv2 land surface model	Hidrológico; Meteorológico
67	Random Forest	Xin'anjiang Model; SCE-UA Algorithm	-	Hidrológico; Meteorológico
68	Support Vector Regression (NuSVR; kernel RBF)	-	Python; scikit-learn (sklearn.svm NuSVR); LIBSVM	Hidrológico
69	Convolutional Neural Network (CNN); Long Short-Term Memory (LSTM); Wavelet-based Adaptive Neuro-Fuzzy Inference System (WANFIS)	Nenhum modelo convencional ou hidrológico comparativo declarado, apenas comparação entre CNN; LSTM; WANFIS	MATLAB (Neural Network Toolbox; ANFIS Toolbox)	Hidrológico; Meteorológico
70	Multivariate Linear Regression (MLR); Artificial Neural Network (ANN); Support Vector Regression (SVR); Wavelet SVR (WSVR); Black Widow Optimization-SVR (BWO-SVR); Algorithm of Innovative Gunner-SVR (AIG-SVR)	Modelos estatísticos e híbridos comparados entre si (MLR vs ANN vs SVR vs híbridos)	MATLAB	Hidrológico; Meteorológico
71	Multilayer Perceptron (MLP); General Regression Neural Network (GRNN); Group Method of Data Handling (GMDH)	ARMA; ARIMA	-	Hidrológico
72	ANN; SVM	WRF (esquemas MYJLD; MYJLG; MYJWD; MYJWG; YSULD; YSULG; YSUWD; YSUWG); HEC-HMS	WRF; HEC-HMS	Hidrológico; Meteorológico
73	Bayesian Causal Modelling (BCM)	-	Netica 6.09 Application Software	Meteorológico; Hidrológico
74	Adaptive Network-based Fuzzy Inference System (ANFIS)	Autoregressive model with exogenous inputs (ARX)	-	Meteorológico; Hidrológico
75	Recurrent Adaptive-Network-based Fuzzy Inference System (R-ANFIS(GL))	ANFIS(SL); R-ANFIS(SL)	-	Meteorológico; Hidrológico
76	Extreme Learning Machine (ELM); MLR-ELM híbrido; GWO-ELM; HHO-ELM; BOA-ELM; WOA-ELM	Multiple Linear Regression (MLR)	-	Hidrológico; Meteorológico
77	Adaptive Neuro-Fuzzy Inference System (ANFIS-PSOSMA)	ANN; ANFIS; ANFIS-PSO; ANFIS-SMA	MATLAB	Hidrológico; Meteorológico
78	Artificial Neural Network (ANN); Gene Expression Programming (GEP)	Quantile Regression Technique (QRT)	MATLAB	Hidrológico; Meteorológico; Geomorfológico
79	variational mode decomposition (VMD);forgetful online sequence learning mechanism (FOS);orthogonal triangular decomposition (QR);regularised broad learning (RBL);VMD-FOS-QR-RBL	QR-ELM;EEMD-FOS-QR-RBL;CEEMDAN-FOS-QR-RBL;	-	Hidrológico
80	Support Vector Regression (SVR)	Radial Basis Function Neural Network (RBFNN); Nonlinear Autoregressive Exogenous Neural Network (NARX)	MATLAB; LIBSVM	Hidrológico
81	Manifold Learning Algorithm; Locally Linear Embedding (LLE); K-Means; LSTM Neural Network	LSTM neural network (comparativo)	-	Hidrológico; Pluviométrico

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
82	Artificial Neural Network (ANN)	Markov model; robust linear regression; hydrologic models	NS-2; MATLAB (Neural Network Toolbox)	Hidrológico; Meteorológico
83	Linear Regression (LR); Gradient Boosting Regressor (GBR); MultiLayer Perceptron (MLP)	Empirical lag and route model (SPC Toulouse)	Scikit-learn; TensorFlow; Keras	Hidrológico
84	Radial Basis Function Neural Network (RBFNN); Artificial Neural Network	-	-	Hidrológico; Pluviométrico
85	Random Forest	Nonlinear partial least squares regression	-	Hidrológico; Meteorológico
86	ST-DTW; Multi-feature algorithm	ARIMA; SVM; LSTM	Python 3.6; TensorFlow	Hidrológico; Meteorológico
87	Wavelet Neural Network (WANN)	HEC-RAS 2D; SMADA	Matlab; ArcMap; SMADA; HEC-RAS 2D; UAV photogrammetry software	Hidrológico; Meteorológico
88	Radial Basis Function Neural Network (RBFNN); Self-Organizing Map (SOM) (para pesos/centros)	-	Antares (plataforma IoT); Android (aplicativo); Arduino; Excel (arquivo de entrada)	Hidrológico; Pluviométrico
89	Artificial Neural Networks (ANN); Adaptative Neuro-Fuzzy Interference System (ANFIS)	ANN; ANFIS	Matlab 2013; nntool; anfisedit	Hidrológico; Pluviométrico
90	LSTM; CFNN; GBDT; MARS	LSTM; CFNN; GBDT; MARS	TensorFlow; Keras; Scikit-learn; MATLAB	Hidrológico; Pluviométrico
91	LSTM; Multilayer Group Method of Data Handling (ML-GMDH)	LSTM; Multilayer Group Method of Data Handling (ML-GMDH)	Python 3.10; TensorFlow; Keras; Scikit-Learn; NumPy; Pandas; PyCharm IDE; Google Earth Engine (GEE)	Hidrológico; Meteorológico; Pluviométrico; Sensoriamento remoto
92	Support Vector Machine (SVM); Support Vector Regression (SVR) com kernels linear; quadrático; Gaussian (RBF)	Support Vector Machine (SVM); Support Vector Regression (SVR) com kernels linear; quadrático; Gaussian (RBF)	MATLAB	Hidrológico
93	LSTM; seq2seq LSTM	TUFLOW (Physics-Based Model)	Python; Keras; TensorFlow2	Hidrológico; Meteorológico; Geomorfológico
94	Support Vector Regression; Support Vector Machine; Radial Basis Function; Linear Regression; Gaussian Process Regression; Decision Tree; Artificial Neural Network	Support Vector Regression; Support Vector Machine; Radial Basis Function; Linear Regression; Gaussian Process Regression; Decision Tree; Artificial Neural Network	MATLAB	Hidrológico; Meteorológico
95	LASSO; Random Forests; Support Vector Regression (SVR)	LASSO; Random Forests; Support Vector Regression (SVR)	R (lars; randomForest; kernlab)	Hidrológico; Pluviométrico
96	Game-Theoretic Consensus Deep Learning (GTCDL)	CNN-LSTM; FloodTransformer; ConvLSTM-Unet; ST-DenseNet; Temporal Latent Diffusion; U-FLOOD	-	Sensoriamento remoto
97	LSTM (encoder-decoder)	GloFAS (Global Flood Awareness System)	NeuralHydrology (biblioteca Python)	Meteorológico; Geomorfológico
98	GRU-KAN; VMD; RPV; GWO	GRU; LSTM; BiLSTM; Transformer; GRU-KAN; FT-LSTM; EMD-GRU; CEEMDAN-GRU; VMD-GRU; VMD-LSTM; VMD-BiLSTM; RPV-GRU; RPV-GRU-KAN; VMD-RPV-GRU	Python 3.10; PyTorch 2.5	Hidrológico
99	LSTM; LSTM-CNN; LSTM-CNN-Attention	LSTM; GRU; ARIMA; Random Forest Regression (RFR)	TensorFlow v2.0	Hidrológico; Meteorológico; Geográfico; Ambiental

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
100	Emotional Neural Network (ENN)	MARS; MPMR; RVM	-	Hidrológico; Meteorológico
101	MLP (Multilayer Perceptron)	Variações de janela deslizante (A; B; C) para formação de atributos; comparação entre janelas de minutos e de horas	WEKA	Hidrológico; Meteorológico
102	DEEMD-KNN-PSO; DEEMD-SVM-PSO; KNN; SVM	SVM-PSO; KNN-PSO; EEMD-SVM-PSO; EEMD-KNN-PSO; DEEMD-SVM-PSO; DEEMD-KNN-PSO	R Software	Hidrológico
103	LSTM-RNN; Feedforward Neural Network (FNN)	LSTM-RNN; FNN	Python; Anaconda Jupyter Notebook; Pandas; NumPy; Keras; SHAP	Meteorológico; Hidrológico; Pluviométrico
104	Bayesian Causal Modelling (BCM)	Johnson SB Distribution; Huff method (chuva extrema)	HUGIN Expert 8.9; SPSS (IBM)	Hidrológico; Meteorológico
105	Back-Propagation Neural Network (BPNN); Ensemble Neural Network (ENN)	Single Neural Network (SNN); ENN1–ENN12; Arithmetic Average; Bayesian Model Average; Stacking Average	-	Hidrológico; Pluviométrico
106	Explainable Convolutional Neural Network (ECNN)	LSTM; CNN; LSTM-CNN	Python; TensorFlow; Keras; Adam	Hidrológico; Meteorológico
107	Autoencoder-CNN-LSTM (AE-CNN-LSTM)	LSTM; BiLSTM; GRU; SVM; CNN	Python; TensorFlow; Keras; Pandas; Scikit-learn; NumPy; Matplotlib	Hidrológico; Meteorológico
108	Multilayer Perceptron (MLP); Elman Recurrent Neural Network (E-RNN)	Multilayer Perceptron (MLP); Elman Recurrent Neural Network (E-RNN)	WEKA	Hidrológico; Pluviométrico
109	Genetic Algorithm–Support Vector Machine (GA-SVM)	Support Vector Machine (SVM); Multiple Linear Regression (MLR)	MATLAB 2021	Hidrológico; Meteorológico
110	Spatio-Temporal Attention Long Short-Term Memory (STA-LSTM)	Historical Average (HA); Fully Connected Network (FCN); Convolutional Neural Network (CNN); Graph Convolutional Network (GCN); LSTM; Spatial Attention LSTM (SA-LSTM); Temporal Attention LSTM (TA-LSTM)	Linux server com GPU NVIDIA TITAN Xp e Adam optimizer	Hidrológico; Pluviométrico
111	Long Short-Term Memory (LSTM)	Recurrent Neural Network (RNN); Gated Recurrent Unit (GRU); Linear Regression (LR); Support Vector Regressor (SVR); eXtreme Gradient Boosting (XGB)	PyTorch; Optuna; NeuralHydrology; Numpy; Pandas	Hidrológico; Meteorológico; Pluviométrico; Pedológico
112	Artificial Neural Networks (ANN); Random Forest (RF); K-Nearest Neighbour (KNN); Long-Short Term Memory (LSTM); Support Vector Machine (SVM); Ensembles (LSTM+RF; LSTM+SVM; ANN+RF)	ANN; RF; KNN; LSTM; SVM; LSTM+RF; LSTM+SVM; ANN+RF	-	Meteorológico; Hidrológico
113	Vanilla Recurrent Neural Network (VRNN); Long Short-Term Memory (LSTM); Gated Recurrent Unit (GRU)	National Water Model (NWM v3.0)	PyTorch; Torch; cudnn; Python; NVIDIA A100; Palmetto HPC	Meteorológico; Hidrológico
114	Long Short-Term Memory (LSTM)	Multiple Linear Regression (MLR)	PyTorch; Scikit-learn; NeuralNetRegressor; HEC-RAS 6.2	Hidrológico; Simulado
115	Logistic Regression; K-Nearest neighbors; Support Vector Classifier; Naive Bayes; Decision tree; Random Forest; Artificial Neural Network	Logistic Regression; K-Nearest neighbors; Support Vector Classifier; Naive Bayes; Decision tree; Random Forest; Artificial Neural Network	Google Colab	Meteorológico; Hidrológico

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
116	Lasso Regression; Ridge Regression; Elastic-Net Regression; K-Nearest Neighbor (KNN); Decision Tree (DT); Random Forest (RF); Support Vector Regression (SVR); Gradient Boost; Time Delay Neural Network (TDNN)	Lasso Regression; Ridge Regression; Elastic-Net Regression; K-Nearest Neighbor (KNN); Decision Tree (DT); Random Forest (RF); Support Vector Regression (SVR); Gradient Boost; Time Delay Neural Network (TDNN)	Python; Scikit-learn; CDO; CDS API; Xarray	Hidrológico; Meteorológico; Pluviométrico
117	KNN; KNN-Depth; KNN-Speed	modelo hidrodinâmico; modelo hidrológico-hidrodinâmico	HEC-HMS; InfoWorks ICM	Hidrológico; Pluviométrico
118	Histogram Gradient Boosting (HGB); Extreme Gradient Boosting (XGB); Deep Neural Network (DNN); Convolutional Neural Network (CNN)	HGB; XGB; DNN; CNN	Python; pandas; scikit-learn; matplotlib; TensorFlow; Keras	Meteorológico; Hidrológico
119	Prophet	GMDH	-	Meteorológico; Hidrológico
120	Recurrent Neural Network (RNN); Long Short-Term Memory (LSTM); Gated Recurrent Unit (GRU)	Auto Regressive (AR); Moving Average (MA); Auto Regressive Integrated Moving Average (ARIMA)	Python; TensorFlow v2.0	Hidrológico; Meteorológico; Geográfico; Antrópico
121	Multiscale Homogenized Deep Neural Network (MHDNN); Unified Parallel C (UPC)	1D-DNN; Support Vector Machine (SVM); Random Forest (RF); ARIMA	C; UPC; Python	Hidrológico; Meteorológico
122	Recurrent Neural Network (RNN); Ensemble Recurrent Neural Networks (ERNN)	Arithmetic Average (AA); Bayesian Model Averaging (BMA)	-	Hidrológico; Pluviométrico
123	LSTM; BiLSTM; CNN-BiLSTM; CNN-BiLSTM-Attention; Gaussian Process Regression (GPR)	LSTM; BiLSTM; CNN-BiLSTM; CNN-BiLSTM-Attention; BiLSTM single model	-	Hidrológico
124	Artificial Neural Networks (ANN); Multilayer Perceptron (MLP)	Persistence model; SGB (Brazilian Geological Survey) model	Matlab	Hidrológico; Pluviométrico
125	Artificial Neural Network (ANN); Support Vector Machine (SVM); Random Forest (RF); Boosted Tree Regression (BTR)	ANN; SVM; RF; BTR	STATISTICA software package	Hidrológico; Pluviométrico
126	Support Vector Regression (SVR)	Antlion Optimization (ALO); Ant Colony Optimization (ACO); Multiverse Optimization (MVO); Salp Swarm Algorithm (SSA)	-	Hidrológico; Meteorológico
127	Long Short-Term Memory (LSTM); Artificial Neural Network (ANN); Particle Swarm Optimization (PSO-LSTM; PSO-ANN)	ANN; LSTM; PSO-ANN	Python 3.9; TensorFlow	Hidrológico; Meteorológico
128	Long Short-Term Memory (LSTM)	HEC-RAS; CADDIES	Python; HEC-RAS; CADDIES (open access)	Hidrológico; Meteorológico
129	Artificial neural network (NNbr; NNlm; NNcg; NNscg; NNrbp); Fuzzy logic (Mamdani; Sugeno); ANFIS (hybrid; backpropagation)	Multiple Linear Regression (MLR)	MATLAB R2018a	Hidrológico; Meteorológico
130	Muskingum linear (estendido) + PSO; WSA; Cat Algorithm; Firefly Algorithm; Cuckoo Search; Gravitational Search Algorithm; Gray Wolf Optimization; Chicken Swarm Optimization; Kalman filter	PSO; WSA; CA; FA; CSO; GSA; GWO; CHSO (entre si; com e sem Kalman filter)	Google Earth; ArcGIS	Hidrológico
131	Physics-Informed Neural Networks (PINNs)	Conceptual models (Saint-Venant equations); Empirical models (regression; neural networks)	Python; TensorFlow; NumPy; pandas	Hidrológico; Meteorológico

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
132	Random Forest Regression (RFR); Support Vector Regression (SVR); Extreme Gradient Boosting (XGBoost); Neural Network – Multi-layer Perceptron Regression (NN-MLP); Principal Component Regression (PCR); Partial Least Square Regression (PLSR); Multivariate Linear Regression (MLR); MLR-3paras; LSTM; Bidirectional LSTM (Bi-LSTM); Bidirectional GRU (Bi-GRU)	RFR; SVR; XGBoost; NN-MLP; PCR; PLSR; MLR; MLR-3paras; LSTM; Bi-LSTM; Bi-GRU	Scikit-learn; RandomizedSearchCV; XGBoost	Hidrológico; Pluviométrico
133	ANFIS	Nonsequential ANFIS; Sequential ANFIS; Multi-input ANFIS	MATLAB	Hidrológico
134	Particle Swarm Optimization – Support Vector Machine (PSO-SVM)	Support Vector Machine (SVM); Back Propagation Neural Network (BPNN)	MATLAB; OriginPro 2020; GIS	Hidrológico; Meteorológico
135	SVM-Linear; SVM-RBF; Random Forest; Random Subspace; CEEMDAN-SVM (Linear); CEEMDAN-SVM (RBF); CEEMDAN-RF; CEEMDAN-RS	SVM-Linear; SVM-RBF; Random Forest; Random Subspace	Python; Pandas	Hidrológico
136	Diffusion-based runoff model (DRUM)	LSTM-d; LSTM-p	-	Hidrológico; Meteorológico
137	Long Short-Term Memory (LSTM)	-	MATLAB; NodeMCU; Arduino Mega2560	Hidrológico; Meteorológico
138	Cascaded-ANFIS; LSTM; GRU; RNN; Linear regression; Ridge regression; Lasso regression	Linear regression; Ridge regression; Lasso regression; LSTM; GRU; RNN	-	Hidrológico; Pluviométrico
139	Back-Propagation Network (BPN); Self-Organizing Map (SOM)	Back-Propagation Network (BPN); Self-Organizing Map (SOM)	Matlab	Hidrológico
140	Light Gradient Boosting Machine (LightGBM); Xin'anjiang Model;	LightGBM	AutoML	Hidrológico; Meteorológico
141	Long Short-Term Memory (LSTM); Particle Swarm Optimization (PSO)	M-EIES; ANN; PSO-ANN; LSTM	Python 3.7; NumPy; Pandas; PySwarms; TensorFlow	Meteorológico; Hidrológico
142	Recurrent Neural Network (RNN); Long Short-Term Memory (LSTM)	Recurrent Neural Network (RNN); Long Short-Term Memory (LSTM)	Python 3.7; TensorFlow 2.0; Jupyter Notebook	Hidrológico; Meteorológico
143	Transformer; RFM_Trans; LSTM	LSTM; Transformer (Trans_v0, Trans_v1, Trans_v2, Trans_v3)	PyTorch 1.8; TensorFlow 2.8; Python 3.9	Meteorológico; Hidrológico
144	Support Vector Machine (SVM); Wavelet-Support Vector Machine (WASVM)	Variable Parameter McCarthy–Muskingum (VPMM)	LIBSVM; MATLAB	Hidrológico; Pluviométrico
145	MLR; ANN; M5 Decision Tree (M5T); ANFIS; Mamdani-Fuzzy Logic (M-FL); Simple Membership Functions and Fuzzy Rules Generation Technique (SMRGT)	MLR; ANN; M5T; ANFIS; M-FL; SMRGT	-	Meteorológico; Hidrológico
146	Bidirectional Gated Recurrent Unit (BiGRU); Extreme Learning Machine (ELM); Random Forest (RF); Relief; Variance Inflation Factor (VIF); Shapley	LSTM; GRU; BP Neural Network; ELM; CEEMDAN-VMD-XGBOOST-SARIMA; CEEMDAN-RCMSE-VMD-LSTM; TVFEMD-BiGRU; RLMD-BiGRU	SPSS26; Python (RELU; ADAM optimizer); TVFEMD; RLMD; MPE	Hidrológico; Meteorológico; Pluviométrico
147	LSTM-Pangu; GRU-Pangu	LSTM; GRU; modelos baseados em dados	Keras; TensorFlow; Python	Meteorológico; Hidrológico
148	LSTM; LSTM-new; CouplingVIC; CouplingVIC-new	VIC; LSTM; LSTM-new; CouplingVIC; CouplingVIC-new	Python 3.9; TensorFlow (Keras)	Hidrológico; Meteorológico; Geomorfológico
149	Artificial neural networks; Wavelet neural networks	Artificial neural networks (sem wavelet); Wavelet neural networks	MATLAB (Neural Network Toolbox)	Hidrológico; Pluviométrico

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
150	Pre-training Enhanced Short-term Flood Prediction Model (PE-SFPM)	Support Vector Regression (SVR); Long Short-Term Memory (LSTM); Graph Convolutional Network (GCN); Attention-LSTM; ST-GCN; AGCLSTM; DAGAT	PyTorch	Hidrológico; Meteorológico
151	C4.5; CART; RepTree; Nnge; Jrip	-	-	Hidrológico; Meteorológico
152	Random Forest; Ridge Regression; Decision Tree; Composite AutoML ensemble	AR; ARIMA; Snowmelt-Runoff Model	FEDOT AutoML; GRASS GIS	Hidrológico; Meteorológico; Sensoriamento remoto
153	REPT; BA-REPT; RC-REPT; RS-REPT; AR-REPT; DA-REPT	REPT; BA-REPT; RC-REPT; RS-REPT; AR-REPT; DA-REPT	WEKA 3.9	Hidrológico; Pluviométrico
154	Artificial Neural Network (ANN); Support Vector Machine (SVM); Adaptive Neuro Fuzzy Inference System (ANFIS)	Artificial Neural Network (ANN); Support Vector Machine (SVM); Adaptive Neuro Fuzzy Inference System (ANFIS)	-	Hidrológico; Meteorológico
155	Multivariate Linear Regression (MLR); Artificial Neural Network (ANN); Support Vector Regression (SVR); Wavelet Support Vector Regression (WSVR)	MLR; ANN; SVR	MATLAB	Hidrológico; Meteorológico
156	Multi-Layer Perceptron (MLP); Convolutional Neural Network (CNN); Long Short-Term Memory (LSTM); Transformer	Modelos hidrológicos conceituais (SWAT; VIC; INCA)	Python; TensorFlow	Hidrológico; Meteorológico
157	CNN-LSTM; CNN; LSTM; DNN; MLP; ELM; DT; GBM; XGB; MARS; RFR	CNN; LSTM; DNN; MLP; ELM; DT; GBM; XGB; MARS; RFR	Python; Keras; TensorFlow; Scikit-learn; PyEarth; MATLAB; Minitab (conforme descrições de modelos e métricas)	Hidrológico
158	EMD-Encoder Decoder LSTM (EMD-En-De-LSTM)	Vanilla LSTM; Stacked LSTM; En-De-LSTM; EMD+Vanilla LSTM; EMD+Stacked LSTM	-	Hidrológico
159	Support Vector Regression (SVR)	ARIMA; ANN; RF (citados em revisão)	Python; Radial Kernel; K-fold Cross-Validation	Hidrológico; Meteorológico
160	Multilayer Perceptron (MLP); MLP-AOA (Archimedes Optimization Algorithm); MLP-BA (Bat Algorithm); MLP-PSO (Particle Swarm Optimization); MLP-FFA (Firefly Algorithm); Copula Bayesian Model Averaging (CBMA)	Bayesian Model Averaging (BMA); individual MLPs	-	Hidrológico; Meteorológico
161	XGBoost; CatBoost	XGBoost; CatBoost	-	Hidrológico; Meteorológico; Sensores IoT
162	SVR-HHO; SVR-ALO; SVR-MVO; SVR-SHO; SVR-PSO; SVR-BO	SVR-ALO; SVR-MVO; SVR-SHO; SVR-PSO; SVR-BO	MATLAB; LIBSVM 3.23	Hidrológico; Pluviométrico
163	Agent-Based Model; Data-Driven Model (ABM+DDM)	-	-	Hidrológico; Meteorológico
164	Deep Artificial Neural Network (DNN); Deep Recurrent Neural Network (RNN)	Global Multilayer Perceptron (MLP)	MATLAB	Hidrológico; Meteorológico; Pluviométrico
165	LSTM; GRU; Transfer Learning (TL); TL+LSTM; TL+GRU	TL; TL+LSTM; TL+GRU	Python 3.6.4; pandas; Keras; math; matplotlib; scikit-learn; TensorFlow	Hidrológico; Meteorológico
166	Decision Tree; Decision Jungle; Random Forest	Decision Tree; Decision Jungle; Random Forest	MATLAB; Simulink; MATLAB ML Toolbox	Hidrológico

ID	Modelos IA Adotados	Algoritmos Comparativos	Ferramenta	Tipo de Dado
167	Bayesian Linear; Bayesian Long Short-Term Memory (LSTM)	Bayesian Linear; Bayesian Long Short-Term Memory (LSTM)	TensorFlow 2.0; PyTorch	Hidrológico; Meteorológico; Geográfico; Antrópico
168	Long Short-Term Memory (LSTM); Explainable AI (Permutation Importance)	-	TensorFlow; Keras	Hidrológico; Meteorológico
169	Bayesian Linear Regression; Neural Network Regression; Boosted Decision Tree Regression; Decision Forest Regression; Linear Regression	Modelos comparativos entre técnicas de ML (NN; BDT; DF; LR)	Microsoft Azure Machine Learning	Hidrológico; Meteorológico
170	Artificial Neural Networks (ANN); Adaptive Neuro Fuzzy Inference System (ANFIS); Support Vector Machine (SVM)	ANN; ANFIS; SVM com kernels Linear; Gaussian; Polynomial	MATLAB	Hidrológico; Meteorológico
171	GRU encoder-decoder com atenção (Gated Recurrent Unit); GSA; GSA-R; GSA-RL; GSA-RU; GSA-ZFR; GSA-RP	Persistência temporal (benchmark)	TensorFlow; Keras; Python 3	Hidrológico; Pluviométrico; Simulado
172	Long Short-Term Memory (LSTM); Convolutional Long Short-Term Memory (ConvLSTM)	Modelos hidrológicos convencionais (GR4J; HEC-HMS)	Scikit-Optimize (skopt); Global Mapper	Hidrológico; Meteorológico; Sensoriamento remoto
173	Gated Recurrent Unit (GRU); Convolutional Neural Network (CNN)	Long Short-Term Memory (LSTM); ARIMA; Wavelet-based Artificial Neural Network (WANN)	TensorFlow-gpu 2.0.0; Python	Hidrológico
174	Artificial Neural Network (ANN); Multi-Layer Perceptron (MLP); Empirical Mode Decomposition (EMD)	Backpropagation (BP); DWT (Discrete Wavelet Transform)	-	Hidrológico; Meteorológico

APÊNDICE C - DADOS DO BLOCO DE AVALIAÇÃO

ID	Métricas	Validação	Comparação de Desempenho
1	RMSE; MAE; R ² ; NSE; PBIAS	k-fold (k=5)	CNN-RNN-Neural ODE > CNN-RNN e Neural ODE em todas as métricas
2	R ² ; RMSE	10-fold cross-validation; treino/teste (dados reais WSN)	MLP > GP > SVM em desempenho geral; GP tem melhor R ² ; MLP menor RMSE
3	R ² ; RMSE	Treino/validação/teste com eventos reais e projetados; previsão multi-step (3h–36h)	LSTM híbrido SOM-R-NARX apresenta melhor desempenho (R ² > 0.9 até 12 h)
4	Accuracy; Precision; Recall; F1 Score Macro	k-fold (k=4)	Random Forest > KNN; SVC; Logistic Regression em todas as métricas
5	NSE; KGE; α -NSE; β -NSE; NSE<0	k-fold cross-validation (k não especificado); treino/validação/teste = 70/15/15	DNN > LSTM-TL e GRU-TL em NSE e KGE
6	NSE; Accuracy	Treino/teste por períodos distintos (2010–2019); Validação temporal implícita	Ensemble (ANN+SVM+HBV) apresentou melhor NSE e acurácia de volume que modelos individuais
7	R ² ; RMSE; MRE	Treinamento/validação divididos em 70%/15%/15%; avaliações adicionais com 10%; 50; 176 épocas e cenários de treinamento restritos (anos secos; normais; úmidos)	SBEL > MLP em R ² ; RMSE; MRE; melhor em picos; com poucos dados; em dias chuvosos e não chuvosos
8	R ²	-	Suporte Vector Machine > Logistic Regression; Neural Network em Fars (R ² =0.86)
9	NSE; RMSE; MAE; r	k-fold (k=10); treino/teste (80%,20%) com divisão temporal (treino 1970–2002; teste 2003–2011)	ATE > WAE > SAE $\approx$ XGB > RF > AdaBoost; ATE supera XGB em NSE (+10.22%), RMSE (–18.52%), MAE (–28.17%) e r (+4.54%)
10	RMSE; NSE; R ²	Treino/teste (1991–1997 / 1998–1999); previsão multi-step (1–12h)	Attention-LSTM > LSTM; SVM; BPNN em todas as métricas; melhor estabilidade temporal
11	Erro médio; erro médio percentual; % comparativo	Treino/validação/teste (60 %; 20 %; 20 %); previsão 1–5 dias	ANN proposta > RNN; CNN; MLP; Perceptron em precisão e estabilidade
12	R ² ; MAE; RMSE; PBIAS; Accuracy	Treino/Teste 80/20; Validação por clientes em ambiente Federated Learning (5 nós)	FNN > LSTM-RNN > TFT-CNN em R ² , RMSE e MAE
13	NSE; R; RMSE; MAE	Validação por eventos (SOM em C1/C2); C1 validação: No.201609; No.201706; C2 validação: No.200509; No.201310; No.201908; No.202008	Cloud $\geq$ LSTM/GRU/XGBoost em NSE/RMSE; SE-Cloud > Cloud (hipervolume +13,14%–39,65%); MRO mais robusto que TSO
14	R ² ; MSE; RMSE; MAE	Treino/teste (80%/20%); validação temporal	RF-SARIMA > SARIMA; ANN; RF (melhor R ² e menor erro)
15	R; MAE; NRMSE; RMSRE	Treino/teste ($\approx$ 70%/30%); validação temporal; múltiplas janelas de previsão (1–18 h)	GSGMDH manteve R>0.9 para todas as previsões; desempenho estável até 18 horas à frente
16	NSE; R ² ; RMSE; MAE; MSE	Treino/teste (80%/20%)	GRU e Bi-GRU > demais modelos em RMSE e NSE; LSTM apresentou maiores erros
17	NSE; RMSE; MAE; RSD	Calibração $\approx$ 75%; Validação $\approx$ 25%; validação temporal separada por períodos 1954–1998 / 1999–2008; 1947–1993 / 1994–2008; 1982–2001 / 2001–2008	EEMD-VMD-RFR > EEMD-VMD-GEP > RFR > GEP em NSE, RMSE e Resiliência
18	R; NSE; RMSE	Treinamento 70%; Teste 30%; calibração/validação temporal; horizontes 1;2;3;7 passos à frente	M-DWT-ANN > DWT-ANN > ANN em R; NSE; RMSE
19	NRMSE; CC; F1-Score	Treino/teste (2016–2017 treino; 2021 teste); k-fold (k=10)	DNN > LSTM em previsão de nível d'água; XGBoost > RF; Tree em classificação de risco
20	RMSE; R ² ; MAPE; WI	k-fold (k=4); treino/teste (80%/20%)	MLP-NN > ANFIS em tempo de execução; desempenho geral semelhante (RMSE e MAPE próximos)

ID	Métricas	Validação	Comparação de Desempenho
21	RMSE; MAE; NSE	Treino/teste (70%/30%)	SVM-WOA4 > SVM4 em RMSE, MAE e NSE; previsão mais próxima dos valores observados
22	R; RMSE; MSE; MAE	Treino/teste (70%/30%)	ELM > GPR > ENN > SVM > ANFIS em todos os índices de desempenho; ELM obteve melhor classificação geral em 14 estações
23	MAE; MSE; RMSE; MAPE	Treino/teste (2021–2023)	iTransformer > LSTM > XGBoost > ARIMA em todas as métricas
24	R ² ; MSE; %δ; HE	Treino/teste com período 2014–2017; comparação entre modelos	PM > MLP; ELM; RBF; LR em HE e VE; PM produziu resultados mais realistas e confiáveis
25	MAE; rMAE; RMSE; rRMSE; NSE; PI; CSI; TDAb	Treino 75%; Validação 10%; Teste 25% (2007–2022 para Kogenheim; 2007–2019 para Waltenheim)	RF2 > GB2 > MLP2; ambos superam RNN e CNN; desempenho consistente em NSE e RMSE
26	Accuracy; MAE; MSE; RMSE; R ²	K-fold (k=10); treino/teste 80/20	RF > MLP > SVC em classificação; SVR > MLP em regressão
27	NSE; MAE; WI; RMSE; CVRMSE	Split temporal: ML 75% treino / 25% teste com TimeSeriesSplit (3 folds); LSTM 55% treino / 20% validação / 25% teste	1 h: RF > demais; 12 h e 24 h: LSTM_IPIP > ML (melhor RMSE/MAE e NSE)
28	NASH; MRAE; R ²	Treino/teste; 2000-2008/2008-2011 (aprox. 70/30)	LSTM > GRU > HEC-HMS
29	R; NSE; RMSE; MAE	Treinamento 70%; Teste 30%; validação temporal; normalização min-max	FFBP-M5 > ANFIS-M10 > RF ≈ XGBoost > LightGBM > CatBoost (melhor NSE e RMSE)
30	RMSE; E; R	Treino/teste 70/30	Wavelet-ANFIS > Wavelet-ANN > ANFIS > ANN em todas as métricas
31	NSE; R ² ; RMSE	Treino/validação/teste por eventos: 9/2/1 (2000–2007/2008–2009/2010); BOA com validação cruzada 5-fold para hiperparâmetros	SVR > demais modelos em NSE/RMSE na maioria dos horizontes; em T=1 h XGBoost tem maior R ²
32	RMSE; MAE	Treino/teste com GridSearchCV para otimização de hiperparâmetros; validação temporal 2001–2019	LSTM > ARIMA em RMSE e MAE; LSTM reduziu RMSE em 44.57% e MAE em 8.47% (Kemaman); reduziu RMSE em 7.29% e MAE em 21.05% (Dungun)
33	R; NSE; RMSE; MAE	Treino/teste 70%;30%	VMD-MLPNN > VMD-RFR > MLPNN > RFR > GR5J > HBV
34	Precision; Recall; F1 Score	Treino (2007–2009); validação (2010); teste (2011–2012)	Lasso > Decision Tree > SVM em F1 Score; Lasso obteve melhor precisão e recall em todos os horizontes (1–6 h)
35	RMSE; RRMSE; Rbias; REr	Treino/teste (126/55 bacias)	ANN > SVM em REr e Rbias; ambos > ARR RFFA em precisão
36	NSE; RMSE; MAE; PBIAS	Treino/teste (1990–2005; 2006–2020); calibração/validação temporal	Ensemble > LSTM > FFNN > SVR > SWAT+ em NSE, RMSE e PBIAS
37	NSE; MAE; RMSE	Treino/validação 80/20 (1995–2013); teste com dados independentes de 2014	LSTM ≈ GRU > Stacked LSTM ≈ BiLSTM > FFNN > CNN em NSE e estabilidade
38	R ² ; RMSE; Bias	Treino/teste (70/30)	LLR > DLLR > BFGS > CG > TLBP em R ² e RMSE
39	MAE; MAPE; MSE; RMSE; CC; pc; CE	Treino/teste (70/30); validação temporal (HydroTest)	ANN (sigmoid–sigmoid) > ANN (sigmoid–linear) > HEC-RAS em MAE, RMSE e CC
40	R ² ; MSE; RMSE; MAE	Treino/teste com ajuste por GridSearchCV; validação de desempenho por métricas de regressão	Bayesian Ridge Regression > Gradient Boosting > Random Forest; Lasso Regression apresentou pior desempenho
41	MAE; MSE; RMSE; Acurácia	Treino em Brooklyn Station e teste em Hoppers Crossing; validação cruzada temporal	LSTM > RNN em todas as métricas (menores erros e maior acurácia)
42	NSE; RMSE; MAE; PBIAS	Treino/Validação/Teste por períodos; SWAT+: aquecimento 1985–1989; calibração 1990–2005; validação 2006–2020	SWAT+-LSTM > SWAT+ e > LSTM; acoplado com SWAT+ calibrado > acoplado com SWAT+ default; usar 7 saídas do SWAT+ + meteorologia > usar apenas vazão do SWAT+

ID	Métricas	Validação	Comparação de Desempenho
43	R ² ; Erro relativo pico; Erro de tempo; Taxa qualificada pico; Taxa qualificada tempo	Treino/teste temporal com 10 eventos de inundação; validação com dados de 2018	CRML > modelos tradicionais em acurácia e tempo de chegada; desempenho superior para lead time curto e longo
44	RMSE; R ²	Treino 80%; teste 20% (validação temporal 2003–2012)	SVM-PSO2 > SVM-PSO1 > SVM2 > SVM1 em todas as métricas (menor RMSE e maior R ²)
45	SMAPE; RRMSE; NNSE; KGE; WI	Treino 2006–2012; teste 2013–2016 (validação temporal)	CNN > RF > GTB > MLP em precisão geral; CNN apresentou menor RMSE e maior KGE em todas as estações
46	R ² ; RMSE; MAE; NSE	Treino 80%; teste 20%; 2008–2018 (validação temporal)	SVM-AF > Wavelet-SVM > Bayesian-SVM em todos os critérios de desempenho
47	R; MAE; NSE; RMSE	Divisão de treino e validação por intervalos temporais; avaliação multietapas (30 min e 1 h à frente)	LSTM > MLP em todas as métricas; 45 % de melhoria no R; melhor desempenho com Qt+0.5 como alvo
48	NSE; CRPS; α (reliability); π_{rel} (relative resolution); resolução	treino/validação/teste = 60%/20%/20% (seleção aleatória considerando anos hidrológicos)	TFT > HBV em NSE em todas as estações; P2 > P1 em CRPS e resolução; TFT (GFS) supera persistência em previsão
49	RMSE; Bias	Treino/teste 80–20; validação temporal (2023–2024)	MLP > LSTM > SVM > RF > ELM (melhor em RMSE); MLP teve melhor desempenho geral
50	NSE; RMSE; bias	Validação temporal; treino/teste em múltiplas bacias (fonte/target)	TL-Transformer > TL-LSTM > Transformer > LSTM > MLP > TOPMODEL em todas as métricas
51	RMSE; NSE; RE; CRPS; REF	XAJ calibrado 1981–2015 e validado 2016–2019; LSTM treinado 1981–2015 com Randomized Search e validação 5-fold; testado 2016–2019; QM treinado 2002–2015 e testado 2016–2019; previsões com lead time 1–30 dias; ECMWF S2S inicializado 35 datas/ano (maio–agosto) 2002–2019	XAJ-LSTM + EC-CNN > EC e EC-QM (melhor em RMSE em todas as janelas); para vazão, XAJ-LSTM dirigido por EC-CNN tem 16%–33% menor RE e 20%–31% menor RMSE vs. EC; XAJ autônomo mostra melhora marginal com EC-CNN
52	RMSE; NSE; R; PSS	Treino 50%; validação 25%; teste 25%	Ensemble MLP > modelo de persistência em todos os indicadores
53	Erro	-	LSTM com múltiplos parâmetros > modelo inicial com poucos parâmetros (erro reduzido de 98% para 17%)
54	R; R ² ; Média R	Treino (Jul 2013–Jun 2014); Teste (Jul 2014 em diante; intervalos por eventos); validação temporal por períodos	Avaliação de desempenho em diferentes períodos/testes
55	RMSE; CC; NSE; MAE; MAPE; Bias; Time Lag; AIC	5-fold cross-validation (k=5)	GA-XGBoost e DE-XGBoost > RF > CART em RMSE, NSE e MAPE
56	R ² ; RMSE	Comparação direta com modelos Muskingum e métodos de Karahan (2012) e Al-Humoud e Esen (2006)	GEP > Muskingum; resultados superiores em R ² e RMSE para os três casos
57	RMSE; NSE; R ²	Treino/teste (70%/30%); previsão temporal com leads de 1–6h	OS-ELM > SVM > GP > ANN em RMSE, NSE e R ² (melhor desempenho geral até 5h de antecedência)
58	RMSE; NSE; KGE; MAPE; ρ ; α ; β	Treino 80%; Teste 20%; validação temporal (flood 2016; 2019; 2021); 100 épocas; early stopping após 3 épocas sem melhora	ATT > LSTM para janelas > 12 h; para previsões $\leq$ 12 h LSTM melhor; ATT estável até 36 h (KGE $\approx$ 0.89 vs 0.81 LSTM)
59	WI; RMSE; MSE	Treino/teste (1970–2004 / 2005–2019)	ANFIS-GOA > ANFIS-GWO > ANFIS > ANN em WI e RMSE
60	R ² ; RMSE; APE; R ² adj	Treino/teste (2001–2006 / 2007–2010)	ANN > LR > ARIMA em R ² e RMSE (melhor desempenho geral)
61	RMSE; MAE; MAPE	Treino/teste 80%;20%; normalização min–max; janela deslizante; 10 bacias MOPEX (33 anos)	ALSTM > LSTM e AGRU > GRU; ambos > MLP; melhorias exemplares relatadas: ALSTM vs. LSTM (test MAE) = 6.69% (Quinebaug); 12.64% (Royal); ALSTM vs. AGRU (test RMSE) = 21.60% (Nezinscot); 12.41% (Housatonic)

ID	Métricas	Validação	Comparação de Desempenho
62	R ² ; RMSE; MAE	Treino/teste (80/20)	NNC > SVM > NN em R ² ; NNC obteve menor erro (RMSE=0.59)
63	CC; NSE; RMSE; PI	Treino-teste (divisão do conjunto descrita genericamente; percentuais não especificados)	RF > DT; ANN com bom desempenho (sem valores); RF e DT >> Diffusion em CC; NSE; RMSE
64	Accuracy; Precision; Recall; F1-score	Treino/teste (80/20%); 10-fold Cross-Validation (Mean Accuracy $\pm$ CI)	CNN-LSTM-Attention > LSTM; CNN; SVM; LR; KNN; MNB em todas as métricas
65	RMSE; MAE; R ²	Treino/validação/teste 60%/20%/20%	Attention-based LSTM > LSTM > Transformer; melhor desempenho em RMSE e R ² , especialmente em previsões de 30 dias
66	NSE; RMSE; CRPSS	Treino/teste por eventos (4 principais enchentes 2010–2017); validação cruzada LSTM-CV; sem k-fold	ECMWF/CSSPv2 > ESP/CSSPv2 (ganho médio NSE=+0.49; RMSE–31.7%)
67	NSE	Treino/teste com séries históricas 1970–2014 (validação cruzada temporal)	Ensemble probability-weighted forecasts > single-type forecasts em NSE e erro de pico
68	KG; NSE; MARE	Amostras múltiplas de treino/validação (8 amostras) no período 1964–2004; janela móvel de 20 anos; teste temporal 2005–2015; previsão 1 dia à frente	Modelos por grupo (clusters) tiveram melhor desempenho para os respectivos grupos; desempenho semelhante ao modelo treinado na série completa para 1 dia de antecedência
69	R ² ; NSE; WI; RAE	Treinamento/teste 9:1; validação temporal por bacia (1900–2018 e 1981–2013)	CNN > LSTM; WANFIS para previsão de cheias; WANFIS > CNN para previsão de secas
70	R ² ; RMSE; MAE; NSE; PBIAS	Treino 80% (2010–2017); teste 20% (2018–2020)	AIG-SVR > WSVR > BWO-SVR > SVR > ANN > MLR em todas as métricas
71	RMSE; NRMSE; WI	D1: último ano para validação; D2: últimos 4 anos (~30% dos dados) para validação; calibração no restante	D1: GMDH > MLP > GRNN > ARIMA > ARMA em RMSE e WI; D2: MLP > GMDH > demais; modelos de IA superam os estocásticos
72	NSE; PTVE; RMSE; MAPE; NS	Treinamento/teste (ANN; SVM); Calibração/Verificação (HEC-HMS); previsão WRF em intervalos de 6 h	SVM > WRF; ANN para hidrograma (NS; RMSE; MAPE); WRF esquema MYJLG > demais esquemas em chuva/temperatura
73	Logarithmic loss; Quadratic loss; Spherical payoff; Variance Reduction; Mutual Information	Treino/teste 80/20; eventos EV1–EV8 divididos em submodelos e modelo geral	BCM superou expectativas com precisão elevada; quartis III e IV produziram maiores vazões
74	NSE; R ² ; RMSE; MAE; RPE	Treino/teste 50/20 eventos (70 no total) com divisão temporal	ANFIS > ARX em todas as métricas (maior CE; R ² e menor RMSE; MAE)
75	NSE; RMSE; Gbench; PPTS	Treino/validação/teste com divisão temporal (2003–2009; 2010–2012; 2013–2016)	R-ANFIS(GL) > ANFIS(SL) em NSE; RMSE; Gbench e PPTS
76	RMSE; NSE; R ² ; Pbias	Treino/teste (70/30%); validação temporal em duas estações (Meki e Abura)	MLR-GWO-ELM > HHO-ELM > WOA-ELM > BOA-ELM > ELM > MLR em todos os indicadores; híbrido linear-não linear teve melhor desempenho
77	NSE; R ² ; RMSE; MAE	Treino/teste 70/30 temporal	ANFIS-PSOSMA > ANFIS-SMA > ANFIS-PSO > ANFIS > ANN em NSE, R ² e RMSE
78	CE; r; RE	Treino/teste (80%/20%) com seleção aleatória de estações; avaliação em 90 bacias de teste	ANN > GEP > QRT na maioria dos quantis; GEP superior em Q5 e Q100
79	NS; MAE; RE; run time	Treino/teste 65/35	VMD-FOS-QR-RBL superou os outros modelos em todas as métricas
80	RMSE; R ²	Treino/teste 80/20; previsão multi-passo (1–12h)	NARX-NN obteve menor RMSE (0.1154), mas SVR apresentou maior R ² (0.9864), sendo mais consistente para longos horizontes
81	RMSE; R ² ; Δ Qm; Δ Tm; %Erro	Treino/teste (110 amostras treino; 5 teste; comparação temporal)	Manifold Learning > LSTM em RMSE, R ² e tempo de previsão (erro médio de pico 8.33% vs 23.53%)
82	R	Treino/teste 65/35; dados 2006–2011 para treino e 2012–2014 para validação	ANN (RN+HM+WF) obteve melhor correlação (R=0.9912) que combinações parciais

ID	Métricas	Validação	Comparação de Desempenho
83	R ² ; NSE; Persistência	Cross-validation GroupKFold (k=5); treino/teste 80/20; eventos de 2007–2018	GBR > SPC em R ² , NSE e Persistência; desempenho robusto mesmo com dados escassos
84	MAPE; RMSE; MSE	treino/teste (Jan–Jun 2015; Jul–Dez 2015)	-
85	R ²	Treino/teste 80/20	Nonlinear partial least squares regression > Random Forest com alta pluviosidade; Random Forest > Nonlinear partial least squares regression com baixa pluviosidade
86	RMSE; T; D	Treino/teste (Changhua: 1998–2008 treino, 2009–2010 teste; Heihe: 2003–2010 treino, 2011–2012 teste)	ST-DTW ≈ LSTM em RMSE; ST-DTW > LSTM em previsão de tempo de pico; Multi-feature ≈ LSTM
87	R ² ; RMSE	Treino (75%); Validação (25%)	WANN > estruturas comparadas (estrutura 2 apresentou melhor desempenho)
88	MSE	treino/teste (50%, 50%)	RBF com lr=0.00007 e 700 épocas obteve menor MSE do que outras configurações (taxas de aprendizado/épocas)
89	CCC; CC; MAE; MAPE; MSE; RMSE	treino/teste 90/10	ANN (sigmoidal–sigmoidal) > ANN (sigmoidal–lineal) > ANFIS
90	R; RMSE; MAPE; NSE; KGE; IA	Treino/teste 75%/25%; hold-one-out cross-validation	CART-TVF-EMD-CFNN > CART-TVF-EMD-MARS; CART-TVF-EMD-GBDT; CART-TVF-EMD-LSTM e todos os modelos individuais
91	R ² ; R; RMSE	Treino/teste 85%/15%; validação temporal (2010–2020 treino; 2021–2022 teste)	LSTM > ML-GMDH em R ² e RMSE
92	R ² ; RMSE; MAE; 0.415	Treino/teste (70%, 30%); defasagens Qt–1 a Qt–5	Diário: kernel linear > quadrático; Gaussian em R ² e RMSE; Mensal: kernel linear > demais; Sazonal: kernel quadrático > demais
93	MAE; RMSE; NSE; Correlação; Precisão; Recall; F1 Score	Treino/Teste 80%/20% (16 e 4 eventos); validação com dados de 2016–2018	seq2seq LSTM > LSTM em RMSE, NSE e correlação, especialmente em previsões de longo prazo
94	StD; RMSE; RMSD; ME; MAE; Corr; Bias	k-fold (k=10)	RBF > DT > ANN > GPR = LR > SVR > SVM
95	MAE; RMSE; CE	Treino/teste 1071 amostras (1994–2000) e 459 amostras (2001–2003); 10-fold cross-validation (2 repetições)	SVR > RF > LASSO em MAE e RMSE; todos dentro da faixa de erro aceita pela Mekong River Commission
96	AUC; LTA-24h; F1-SCORE; PRECISION; RECALL; TIMEACCURACY; TC	Treino/Validação/Teste; 2017-2020(42096)/2021(8732)/2022-2023(12418)	GTCDL > demais métodos
97	Precisão; Revocação; F1; NSE; KGE; Bias	k-fold espacial aleatório (k=10); validação temporal (janela ≥1 ano entre treino e teste); splits por continentes (k=6); por zonas climáticas (k=13); por bacias terminais hidrologicamente separadas (k=8)	IA (LSTM) ≥ GloFAS: melhora em 64% (1 ano); 70% (2 anos); 60% (5 anos); 49% (10 anos) dos postos; confiabilidade (F1) até 5 dias ≥ GloFAS em 0 dia para eventos de 1–5 anos; precisão e revocação maiores em todos os períodos de retorno
98	MAPE; RMSE; U1; MAE; NSE	treino/validação/teste (60%/20%/20%)	VMD-RPV-GRU-KAN > modelos base; vs M5: MAPE –92.81%; RMSE –96.90%; MAE –95.86%; vs M10: MAPE –90.46%; RMSE –95.75%; MAE –94.68%
99	RMSE; MAE; MSE; AR ² ; tempo de computação	Treino/validação/previsão com divisão temporal; 100 iterações de treino e validação	LSTM-CNN-Attention > LSTM-CNN > LSTM em MSE, MAE e AR ²
100	RMSE; MAE; R ² ; NSE; KGE; PBIAS	Treino/validação/teste 60%/20%/20%	ENN > MARS > MPMR > RVM em R ² e NSE; ENN obteve menor erro absoluto
101	R ² ; R; Accuracy	k-fold (k=10); matrizes de confusão; intervalo de confiança de 95% (teste t de Student)	Abordagem C (janelas dos últimos minutos) > abordagens de horas (B) nas predições de 1–5 min
102	RMSE; MSE; MAPE; R ²	treino/teste (80%, 20%); validação temporal (treino 2011-01-01–2020-08-01; teste 2020-08-02–2022-12-31)	DEEMD-KNN-PSO superior (menor RMSE; MSE; MAPE; maior R ²) em relação aos demais
103	MSE; R ² ; RMSE; MAE; k-fold	Treino/Teste (80%, 20%); k-fold (k=10)	FNN > LSTM-RNN em MSE; R-squared; RMSE; MAE; perda

ID	Métricas	Validação	Comparação de Desempenho
104	p-value; Runoff; Relação	Calibração contínua com dados históricos e validação por indicadores de IA e Teoria da Informação (p-value; Mutual Information; Entropia)	BCM > ajuste matemático Johnson SB em precisão probabilística; forte correlação entre chuva e escoamento
105	R ²	Treino/validação/teste 3:1:1 (60%;20%;20%); previsão 1–3 h à frente	ENN > SNN em RMSE e R ² ; melhor estratégia: Boosting (resampling) + Bayesian Model Average
106	NSE; RE; RMSE; ΔT	k-fold (k=8) por ano (2012–2019)	ECNN > LSTM; CNN; LSTM-CNN (em 12 h, redução de RMSE de 34.11%; 48.41%; 33.14%)
107	RMSE; MAE; MAPE; NSE; R ²	Treino/teste 80%/20%; validação temporal contínua	AE-CNN-LSTM > LSTM; BiLSTM; GRU; SVM; CNN em todas as métricas
108	MAE; RMSE; R ²	10-fold cross-validation; validação temporal	MLP > E-RNN em todos os testes; inclusão da variável de chuva aumentou a precisão
109	RMSE; MAE; r; MSE; Variance	Treino 70%; validação 15%; teste 15%	GA-SVM > SVM > MLR em todas as métricas; GA-SVM mais estável e preciso
110	RMSE; R ² ; MAE; MAPE; QR	Treino 80%; teste 20%; 60 épocas; Adam optimizer; 12 h de entrada e previsão de 6 h	STA-LSTM > TA-LSTM > SA-LSTM > LSTM > GCN > CNN > FCN > HA em RMSE, R ² e QR
111	NSE; KGE; RMSE; FHV	Treino 1980–2010; Validação 2011–2014; Teste 2015–2018; early stopping 5; 100 epochs	LSTM > GRU > RNN > XGB > SVR > LR em NSE e KGE; LSTM com melhor generalização e menor overfitting
112	Sensitivity; Specificity; Accuracy	Holdout 70% treino; 10% validação; 20% teste	LSTM+RF > modelos individuais (ANN; RF; KNN; LSTM; SVM) em sensibilidade; especificidade; acurácia
113	NSE; NWM; VRNN	treino/validação/teste 60:20:20 (183/60/60 eventos); divisão temporal (ordem cronológica); early stopping	GRU > LSTM > NWM > VRNN em NSE; GRU e LSTM com menores RPE e PTE
114	RMSE; NSE; MAE	Treino/teste 80/20; 5-fold cross-validation; grid search; early stopping (5 epochs)	LSTM > MLR em todas as métricas (RMSE - 21.42%; NSE +0.39%; MAE -23.14%)
115	Accuracy; Precision; Recall; F1-score	-	Random Forest > KNN em Accuracy; Logistic Regression teve o menor desempenho; ANN apresentou mean accuracy=90.85%
116	RMSE; NSE	Treino/validação/teste temporal (1981–2005; 2006–2011; 2012–2016)	TDNN > SVR > Gradient Boost > Random Forest > KNN > Decision Tree > Linear models em RMSE e NSE
117	R ² ; RMSE; MAE	treino/teste (9:1; 149/17); k-fold (k=10)	KNN-Depth ≈ modelo hidrodinâmico (alto R ² e baixos erros); KNN-Speed ≈ modelo hidrodinâmico; KNN muito mais rápido
118	R; NRMSE; NMAE; FB	Treino/teste; comparação ilustrada com 2016–2017 (últimos anos)	XGB > CNN ≈ HGB ≈ DNN em R; NRMSE; NMAE; FB (teste)
119	R ² ; MAE; MAPE; RMSE; Erro	Treino/teste; Treino até 16 junho de 2013	Prophet > GMDH
120	MSE; MAE; R ² ; R ² adj.	Treino/teste; Validação cruzada; comparação entre fases de treinamento, validação e previsão	LSTM > GRU > RNN em precisão e tempo de resposta
121	RMSE; MAPE; MSE	Treino/validação/teste com divisão 75/25 e validação cruzada; lead-time de 1 ano	MHDNN-UPC > DNN; SVM; RF; ARIMA em RMSE e MAPE
122	RMSE; MAE; CC; NS	treino/validação/teste 7/3/3 eventos (315/138/123 horas); 13 eventos de tufão; horizonte de previsão=5 h	ERNN > BMA e AA (teste): RMSE=276<481<541; NS=0.85>0.55>0.42; CC=0.93>0.79>0.72; CRPS(ERNN)=169 (~38% de AA; ~42% de BMA)
123	MAE; MAPE; RMSE; NSE; PICP; PINAW; CRPS; CWC; PIT	training/testing split 80%–20%; multi-step 1–12 months; single-step e multi-step	CNN-BiLSTM-Attention-GPR > BiLSTM e configurações LSTM>BiLSTM>CNN-BiLSTM em MAE; MAPE; RMSE e NSE; maior PICP e menores PINAW; CRPS; CWC
124	RMSE; MAE; NSE; KGE; Bias	Treino/validação 85/15; teste independente (2022); horizonte 6h, 12h, 24h; validação temporal	ANN (P48h;Hps;Hp;Hbv) > ANN (Hps;Hp;Hbv) > SGB model > Persistência em MAE e RMSE (redução média 68%)
125	WI; RMSE; R ² ; MAE; NSE	SVM: treino/teste 75%/25%; RF: treino/teste 70%/30%; BRT: treino/teste 69%/31%	RF > ANN; SVM; BRT em WI; RMSE; R ²
126	RMSE; NSE; MDA	Treino/Teste (80%, 20%)	ALO > ACO; MVO; SSA em RMSE e NSE

ID	Métricas	Validação	Comparação de Desempenho
127	NSE; RMSE; MAE; MAPE; R	Treino/teste 80/20; validação temporal	PSO-LSTM > LSTM; ANN; PSO-ANN em NSE e RMSE
128	NSE; NRMSE	Sem calibração; validação com série temporal observada; comparação entre modelos	LSTM $\approx$ HEC-RAS em NSE e tempo de execução; CADDIES inferior no caso da Narmada
129	NSE; R ² ; MSE; RMSE; MAE; CA	Calibração 80%; validação 20%; simulação do evento de cheia de 2014	ANFIS > NNlm e Fugeno nas métricas (menor MSE; RMSE; CA e maior R ² ; NSE); Fmamdani foi o pior
130	CC; PSR; NSE; d	-	1º caso: GWO > demais; 2º e 3º casos: GSA > demais; Kalman filter melhora todos os índices
131	MSE; NSE; R ²	Validação cruzada temporal; treino/teste em simulação sintética e real	PINN superou modelos tradicionais e híbridos em MSE e acurácia
132	R ² ; MAE; RMSE	treino/teste (70%,30%); RandomizedSearchCV para hiperparâmetros	RFR $\approx$ NN-MLP > XGBoost > SVR > PCR $\approx$ PLSR $\approx$ MLR $\approx$ MLR-3paras; no CTER, LSTM/Bi-LSTM/Bi-GRU > RFR
133	R ² ; NSE	calibração 1971–2000 e validação 2001–2014; validação temporal por anos ímpares (1971–2013) para calibração e anos pares (1972–2014) para validação	Sequential ANFIS com r ² =0.99 e Nash–Sutcliffe=0.98 e lead time de 6 dias > Nonsequential e Multi-input (2 dias)
134	RMSE; NSE; R ²	Treino/teste (1969–2003 / 2004–2018)	PSO-SVM > SVM > BPNN em todas as métricas
135	R ² ; RMSE; MSE	Treino/teste (80%,20%); treino 01–06-2014 a 20–07-2020; teste 01–08-2020 a 31–12-2022	CEEMDAN-RF > demais; RF (standalone) > demais standalone; RS pior desempenho
136	CRPS; F1; precisão; recall; KGE	-	DRUM > LSTM-p; LSTM-d em CRPS; F1; capacidade de alerta antecipado
137	MAE; RMSE	Treino/validação/teste (80%/10%/10%)	Avaliação em diferentes intervalos de tempo (1, 15, 30min); 30min com melhores resultados
138	R; RMSE; NSE; KGE; Bias	treino/teste (70%,30%)	Cascaded-ANFIS > GRU; LSTM; RNN; Linear; Ridge; Lasso em R; RMSE; NSE; KGE
139	CE; MAE; MAPE; EQp; R ²	Treino/validação com divisão de eventos (5 calibração; 5 validação)	Ensemble BPN+SOM > modelos BPN individuais em todas as métricas; melhora de CE e redução de MAE e MAPE
140	NSE; MAE	Treino/teste (Feb 2023–Sep 2023; 70%/30%)	Modelo Integrado (Xin'anjiang+LightGBM) > LightGBM isolado em NSE e MAE; melhor desempenho até 6 h de antecedência
141	NSE; RMSE; Bias	Treino/validação; calibração e validação com conjuntos separados; 78 eventos calibração e 20 validação	PSO-LSTM > LSTM; PSO-ANN; ANN; M-EIES em NSE, RMSE e Bias
142	MSE; RMSE; MAE	Divisão treino/teste (5400h treinamento; 1896h teste)	LSTM > RNN em MSE, RMSE e MAE
143	MSE; MAE; NSE	Treino/validação/teste 70%; 20%; 10%	RFM_Trans_v3 > LSTM; RFM_Trans_v3 > Transformer em MSE, MAE e NSE; ganho de até 51,68% em MSE e 4,94% em NSE
144	RMSE; NMSE; R ² ; NSE	Treino 1999–2001; Teste 2002 (9 eventos de cheia)	VPMM > SVM; VPMM > WASVM na maioria das métricas; WASVM > SVM em precisão geral
145	MSE; MAE; R	treino/teste (75%,25%)	SMRGT > M-FL > ANN > ANFIS $\approx$ MLR > M5T em R; SMRGT com menores MSE e MAE
146	RMSE; MAE; MAPE; R ²	Treino/validação/teste (6:2:2) — 2010–2017 treino; 2017–2019 validação; 2019–2021 teste	TMRBER (TVFEMD-MPE-RLMD-BiGRU&ELM-RF) > todos os modelos comparativos; reduziu RMSE em até 55.99%
147	NSE; RMSE; R	Treino/teste (90%;10%); Validação temporal; testes com múltiplos passos de tempo e lead times	LSTM-Pangu > LSTM; GRU-Pangu > GRU; melhora média de 8.1% (LSTM) e 11.7% (GRU) em NSE

ID	Métricas	Validação	Comparação de Desempenho
148	NSE; R ² ; KGE; RMSE	five-fold cross-validation; treino/teste temporal LSTM (1980–2004 treino com 5 folds; 2005–2013 validação); calibração/validação VIC (1980–1995; 1996–2013)	CouplingVIC-new > LSTM-new > LSTM > VIC em NSE/KGE/RMSE; VIC melhor para pico extremo e tempo do pico
149	R; NSE; PBIAS	treino/validação/teste (70%, 15%, 15%); early stopping (LM backpropagation)	WNN > NN (adicionar chuva > apenas vazão; WNN superior em curto e longo prazo)
150	MAE; RMSE; MAPE	Treino/teste (80%;20%)	PE-SFPM > DAGAT; AGCLSTM; ST-GCN; LSTM; SVR em todas as métricas
151	F-Score; Misclassification rate	Treino/teste	-
152	NSE; MAE; SMAPE	Divisão temporal: treino 1985–2006; ajuste 2006–2010; validação 2010–2012; 10 estações; horizonte 7 dias; validação abril–julho	Ensemble > SRM; AR; ARIMA em NSE; MAE; SMAPE (ex.: NSE 0.84 vs 0.74; 0.67; 0.69)
153	R ² ; RMSE; MAE; NSE; PBIAS; RSR	treino/teste (70%,30%); validação temporal (23/09/1997–22/09/2008 treino; 23/09/2008–22/09/2012 validação)	AR-REPT > DA-REPT > BA-REPT > RS-REPT > RC-REPT > REPT em R ² ; RMSE; NSE; RSR
154	RMSE; R ² ; NC	K-fold Cross Validation (para SVM); treino/teste (2007–2012 treino; 2013–2014 teste)	ANN treinado com dados de chuva intensa > ANN com todos os dados; ANFIS mais robusto a ruído; SVM mais estável em picos
155	R ² ; RMSE; MAE; NSE; PBIAS	Treino/Teste (80%, 20%)	WSVR > SVR > ANN > MLR em RMSE e NSE
156	RMSE; NSE; RPE	-	LSTM > CNN > MLP > Transformer em NSE e RMSE
157	RMSE; MAE; WI; LM; ENS; r	Validação temporal; treino/teste com janelas 1-Week; 2-Weeks; 4-Weeks; 9-Months (20% dos dados); early stopping (patience=20)	CNN-LSTM > CNN; LSTM; DNN; MLP; ELM; DT; GBM; XGB; MARS em RMSE; MAE; WI; LM; ENS; menor tempo razoável vs maior acurácia nas várias janelas
158	RMSE; R ² ; WI; LMI	Validação temporal; previsão contínua de 10 anos (2009–2018); anos 1998 e 2016 usados como validação anual (12 meses); experimentos com Min-Pd=6m; 12m; 18m; 24m	EMD+En-De-LSTM > LSTM e Stacked LSTM (6m-Min-Pd) com RMSE -30% e LMI +20%; En-De-LSTM teve melhor R ² e WI
159	NSE; R ²	K-fold Cross-Validation (k=4); treino/validação (2006–2016; 2017–2020)	SVR com 4 variáveis (Discharge, Rainfall, Temperature, Snow Cover) > SVR com 3 variáveis em NSE e R ²
160	RMSE; MAE; NSE	Treino/Teste (70%, 30%)	CBMA > BMA > MLP-AOA > MLP-BA > MLP-FFA > MLP-PSO > MLP em RMSE, MAE e NSE
161	Accuracy; Precision; Recall; F1-Score	Treino/teste (80%, 20%) com Random Search cross-validation	XGBoost > CatBoost em todas as métricas (Accuracy, Precision, Recall, F1-Score)
162	RMSE; SI; COC; WI	treino/teste temporal 70% (427 amostras, 1st June 2000–31st July 2003); 30% (183 amostras, 1st August 2003–30th September 2004)	SVR-HHO > SVR-ALO; SVR-MVO; SVR-SHO; SVR-PSO; SVR-BO em RMSE; SI; COC; WI
163	RMSE; R ² ; r; %ERRO	Divisão de dados em 5 anos de séries horárias com cenários de calibração/teste	Cenário 3 (chuva + vazão) apresentou melhor desempenho (R ² >0.8; menor RMSE)
164	NSE; PPD; SPPD; RMSE	Treino/Teste (53/4 eventos); Early stopping; Cross-validation parcial; Ensemble de 10 modelos	DNN > MLP em NSE, PPD e SPPD; melhora no tempo de previsão de 2h para 3h
165	MSE; MAE; MAPE	k-fold (k=5); treino/teste (80%,20%)	TL+GRU > TL+LSTM > TL (na maioria dos bacias; exceção em Ammonoosuc)
166	Accuracy; Average accuracy; Precision; Recall	three-fold cross-validation; treino/teste 40:60; 50:50; 60:40	DT > RF > DJ em accuracy; DT com maiores precision e recall
167	CIL; CIAW; RMSE	Treino/teste/predição (80%/10%/10%)	Bayesian LSTM > Bayesian Linear em CIL, CIAW e consumo computacional
168	RMSE; MSE	Treino/teste (80%/20%)	LSTM com Explainable AI mostrou forte correlação entre precipitação e nível d'água; Rathnapura principal contribuinte para cheias

ID	Métricas	Validação	Comparação de Desempenho
169	RMSE; MAE; EI	Treino/teste (80%/20%)	Bayesian Linear Regression obteve melhor desempenho até 12h de antecedência; Neural Network e Decision Tree tiveram bom desempenho em curto prazo
170	MSE; R ²	treino/teste (70%,30%); k-fold (k=5) para seleção de kernel SVM	ANN > SVM > ANFIS em MSE
171	KGE	Treino/teste (80%,20% dos 5000 eventos; 4000 treino com validação interna 20%); avaliação por evento (mediana KGE); modos Hindcast e Forecast	GSA > Persistência no futuro intermediário e distante; Persistência > modelos DL no futuro próximo; modelos em Forecast apenas ligeiramente melhores que persistência
172	R ² ; NSE; RMSE	Treino/validação (Bayesian optimization; 100 iterações)	ConvLSTM > LSTM e modelos hidrológicos tradicionais em NSE e R131
173	NSE; RMSE; MRE	Treino/teste (80%/20%) dividido por períodos sazonais (seca; média; cheia)	CNN-GRU > GRU > LSTM > WANN > ARIMA
174	NSE; RMSE; MAE; MAPE; R	Treino/teste (60%/40%) com dados de 1972–2012	MLPQTP-EMD > MLPQ-EMD > MLPQTP > MLPQ; decomposição EMD melhora a previsão

APÊNDICE D - DADOS DO BLOCO DE CONTEXTO

ID	Local / Bacia Hidrográfica	País	Tipo de Ambiente
1	Al Ain	Emirados Árabes Unidos	Árido
2	Rios urbanos de São Carlos (SP)	Brasil	Urbano
3	Kemaman River Basin	Malásia	Costeiro; Urbano
4	Bangladesh (distritos não especificados)	Bangladesh	-
5	CAMELS-US; CAMELS-CL	Estados Unidos; Chile	-
6	Seyhan Basin	Turquia	Montanhoso
7	Dez Dam watershed; Dez River; Taleh-Zang hydrometric station (upstream of Dez Dam)	Irã	-
8	Tehran; Fars; Charmahal e Bakhtiari; North Khorasan; Sistan e Baluchistan	Irã	urbano; semiárido; montanhoso
9	Fuchun River Reservoir; Qiantang River basin; Xin'an River Reservoir (influência a montante)	China	-
10	Tunxi Watershed; Anhui Province	China	Montanhoso; Subtropical
11	República do Bashkortostan; cidade de Ufa (Rio Belaya)	Rússia	-
12	Sylhet; Surma-Kushiyara River System; Meghalaya; Assam	Bangladesh; Índia	Urbano
13	Lishimen (LSM) Reservoir; Shifeng River subbasin; Jiaojiang River basin; Tiantai; Linhai; Taizhou	China	Costeiro
14	Sindh River (bacia do rio Jhelum, vale de Kashmir)	Índia	Montanhoso
15	Saint-Charles River; Hurons Station; Quebec City	Canadá	-
16	Rio Bârsa, afluente do Rio Olt	Romênia	Montanhoso
17	Karaj Basin; Siira; Bilghan; Gachsar (sub-bacias)	Irã	Montanhoso
18	Gamasiab River basin (estação Polechehr/Chehr Bridge), províncias Kermanshah e Hamedan	Irã	Semiárido; montanhoso;
19	CarayCaray Basin; Biliran Island; Eastern Visayas	Filipinas	Montanhoso; Costeiro; Insular
20	Muda River; Jambatan Syed Omar Station; Kedah	Malásia	Montanhoso
21	Barak River Basin; Badarpur Ghat Gauging Station; Assam	Índia	Montanhoso
22	Bacia dos rios Eufrates e Tigre (Euphrates-Tigris Basin)	Turquia	Montanhoso
23	Saigon River; Phu An Station; Ho Chi Minh City	Vietnã	Urbano
24	Connecticut River Basin	Estados Unidos	-
25	Bacia do rio Ill; estações Kogenheim, Colmar, Sélestat, Ostheim; estação Zorn em Waltenheim	França	-
26	Hunza River; Danyor Station; Upper Indus Basin	Paquistão	Montanhoso; Gélido
27	Mar Menor basin; Albujón watercourse (pontos "La Puebla (06A01)" e "Desembocadura (06A18)")	Espanha	Costeiro; semiárido; curso d'água intermitente/efêmero
28	Ellagawa sub-basin (Kalu river basin); Thanamalwila sub-basin (Kirindi Oya basin)	Sri Lanka	úmido; árido
29	Indravathi sub-bacia, Godavari River Basin, Nowrangpur	Índia	Montanhoso
30	Bacia do Rio Sebaou; Tizi Ouzou; Algiers Coastal Basin	Argélia	Montanhoso
31	bacia do rio Bahe	China	-
32	Kemaman River; Dungun River; Terengganu	Malásia	Costeiro
33	Côtiers Algérois Watershed	Argélia	-
34	North Texas	Estados Unidos	-
35	South-East Australia	Austrália	-
36	Tagus Headwaters River Basin (THRB)	Espanha	Montanhoso; Semiárido
37	Red River Basin (Son Tay Station; Hanoi; Da; Lo; Thao Rivers)	Vietnã	-
38	Jhelum River; Punjab; Rasul Barrage; Victoria Bridge; Kohan River at Rohtas; Railway Bridge	Paquistão	-
39	Upper Bogotá River Basin (entre Puente Florencia e Tocancipá)	Colômbia	-
40	-	-	-

41	Brooklyn Station; Hoppers Crossing; Kororoit Creek	Austrália	-
42	Tagus Headwaters River Basin (THRB)	Espanha	Semiárido
43	Xixian River Basin, Henan Province	China	-
44	Upper Bertam Catchment; Cameron Highlands; Pahang	Malásia	-
45	Cauvery River Basin (estações Kodumudi, Biligundulu, Kudige)	Índia	-
46	Dez River Basin; Karun sub-basin; Lorestan Province	Irã	Montanhoso; Semiárido
47	Klang River e Ampang River confluence (SMART Tunnel)	Malásia	Urbano
48	Mainland Portugal; 74 bacias não reguladas; estações 05K/01H; 16G/01H; 24H/03H; 28L/02H	Portugal	-
49	Tejo River; Mondego River	Portugal	-
50	Yellow River Basin (bacias Jingle, Lushi, Kuye, Tuwei, Chabagou, Gushanchuan, Jialu, Zuli)	China	-
51	Source region (SR) of the Yangtze River Basin; Shigu station (sub-bacias norte e sul)	China	Montanhoso; planalto; Subtropical
52	Englishman River, Vancouver Island	Canadá	Montanhoso; temperado; úmido
53	Krasnoyarsk hydroelectric power station	Rússia	-
54	Cagayan River Basin; Lucban Bridge (Abulug, Cagayan); Santiago City Bridge (Isabela)	Filipinas	-
55	Jungrang Basin (Han River Basin)	Coreia do Sul	Urbano
56	-	-	-
57	Neckar River (entre Rottweil e Oberndorf)	Alemanha	Urbano; florestal
58	Douro River Estuary (Crestuma-Lever Dam, Porto-Vila Nova de Gaia)	Portugal	Urbano; Estuarino; Montanhoso
59	Bacia do rio Mahanadi; estações Jondhra e Kesinga	Índia	-
60	Muda River; tributários Ketil, Sedim e Chepir	Malásia	Urbano; florestal
61	Quinebaug; Nezinscot; Housatonic; Pequest; Saco; Sacandaga; Ammonoosuc; Pemigewasset; Tenmile; Royal	Estados Unidos	-
62	Khosf Region; South Khorasan	Irã	Árido; Semiárido; Montanhoso
63	Chiba Prefecture	Japão	Urbano
64	Rios Punarbhaba e Dhepa (Dinajpur District)	Bangladesh	Rural
65	Lago Velence	Hungria	Urbano
66	Luo River Basin (sub-bacias Lushi; Yiyang; Baimasi)	China	Montanhoso
67	Bacia do Rio Jingle (sub-bacia do Rio Amarelo)	China	Montanhoso; semiárido; semiúmido
68	União da Vitória (bacia do rio Iguaçu, Paraná); Rio Negro; São Bento; Fluvópolis; União da Vitória	Brasil	-
69	Lower Darling River Basin; Sekong River Basin	Austrália; Camboja; Laos; Vietnã	Árido; Tropical
70	Karkheh Catchment; estações Cham Anjir; Kashkan; Pol-e-Zal; Jologir	Irã	-
71	Zilakirud River; Sefidrud basin; Guilan province; Dorfak Mountains	Iran	Montanhoso
72	Karun-4 basin; Armand hydrometric station; Shahrekord; Boroojen; Lordegan; Koohrang; Saman	Iran	-
73	Bacia do Alto Andarax (Upper Andarax); afluente do Rio Andarax	Espanha	Semiárido; montanhoso
74	Bacia do Rio Semenyih; Selangor	Malásia	Tropical
75	Bacia do Rio Yangtzé; Três Gargantas (Three Gorges Reservoir)	China	Subtropical; urbano
76	Lake Ziway Watershed; Meki River; Abura River (Katar sub-basin)	Etiópia	Semiárido; semiúmido; montanhoso
77	Bacia do Rio Brahmani; Estações Tilga; Jaraikela; Gomlai; Jenapur	Índia	-
78	Eastern Australia (bacias não monitoradas)	Australia	-

79	Yellow river basin (Xiaolangdi and Tongguan stations)	China	-
80	Bacia do Rio Kelantan (estações Lebir, Galas, Kuala Krai)	Malásia	-
81	Zhongping River Basin (Guangxi Zhuang Autonomous Region)	China	Montanhoso
82	Bacia do Rio Ganges; sistema Ganga-Brahmaputra-Meghna	Índia	-
83	Bacia do Rio Garonne; Toulouse	França	Montanhoso; rural
84	Dayeuhkolot	-	-
85	Three Gorges Reservoir; Yangtze River	China	montanhoso
86	Changhua Watershed; Heihe Watershed	China	-
87	Behesht-Abad Watershed; Chaharmahal e Bakhtiari Province	Irã	Rural; Montanhoso
88	Citarum River Basin (Central Citarum River Basin)	Indonésia	-
89	rio Bogotá	Colômbia	-
90	Clarence River (estações Lilydale e Baryulgil)	Austrália	Rural; Montanhoso
91	Chenab River Basin; Marala Station	Paquistão; Índia (98% da bacia)	Montanhoso
92	Euphrates River a montante do Haditha Dam reservoir; Husaybah hydrological station (Al-Qaim)	Iraque	-
93	Norfolk (Virginia)	Estados Unidos	Urbano; Costeiro
94	Cork City; River Lee	Irlanda	Costeiro; Urbano
95	Thakhek Station; Nong Khai (sub-bacia do Mekong)	Laos; Tailândia	-
96	-	-	-
97	Global; 5,680 estações fluviométricas (GRDC)	Global; previsões operacionais em 80+ países	-
98	Pengshan Hydrological Station; Min River; Minjiang River Basin; Yangtze River Basin	China; Sichuan Province	-
99	Tiaoxi Watershed (Qiaodongcun, Changle); Qiantang River Watershed (Qixi Reservoir)	China	Montanhoso
100	Albert River, Queensland	Austrália	Montanhoso; urbano
101	São Carlos (SP)	Brasil	Urbano
102	Klang River; Taman Sri Muda; Selangor; Kuala Lumpur (Station 3015432)	Malaysia	Urbano
103	Sylhet; Surma (Shurma) River; Kushiara	Bangladesh; Índia	-
104	Bacia do Alto Duero; estação Molinos de Duero; PL47 Covalada	Espanha	Montanhoso
105	Longquan Creek; Jinhua River; tributária do Qiantang (Zhejiang)	China	Montanhoso
106	Bacia do rio Lushui; Reservatório Lushui	China	-
107	Ala River; Akure; Ondo State	Nigéria	Misto
108	São Carlos; Estado de São Paulo	Brasil	Urbano
109	Tikarapara Station; Mahanadi River Basin	Índia	Misto
110	Tunxi Basin; Changhua Basin; Heihe Basin	China	Misto
111	Han River Basin; Yangxian Station; Shaanxi Province	China	Misto; Subtropical
112	-	-	-
113	Stevens Creek; Twelve Mile Creek; Chattooga River; bacia urbanizada em Greenville, SC; USGS 02164000; 02177000; 02186000; 02196000	Estados Unidos	montanhoso; urbano
114	Neretva River Estuary; Metković; Opuzen; Norin; Ušće	Croácia	Costeiro; Estuarino
115	Dungun River; Terengganu	Malaysia	-
116	Danube River Basin	Europa (regiões da Alemanha, Áustria, Sérvia, Eslováquia, Moldávia, Bulgária, Romênia, Croácia, Hungria)	Costeiro; Montanhoso
117	Yangshuo County; Yulong River; Jinbao River; Tianjia River; Lijiang River; Limu River	China	montanhoso; urbano
118	Lower South Piney Creek; North Fork Dry Piney Creek; Dry Piney Creek; Wyoming Range	United States	Semiárido; montanhoso

119	Bow River	Canadá	montanhoso
120	Tiaoxi Catchment; Zhejiang Province	China	Montanhoso
121	48 estados dos EUA	Estados Unidos	Urbano
122	Shihmen reservoir watershed	Taiwan	montanhoso
123	Yalong River Basin; Lianghekou; Jinping; Guandi; Ertan	China	-
124	Rio Branco Basin; Boa Vista (Roraima)	Brasil	Urbano; Tropical
125	Aswan High Dam; Nile River	Egito	-
126	Bacia do Reservatório de Bukan; afluentes KS (Khorkhoreh Senteh), PA (Pol-Adnian) e SDP (Saqez Dareh-Panbehdan)	Irã	Montanhoso
127	Ganges; Brahmaputra; Meghna River Network; Buriganga River (SW42)	Bangladesh	Misto
128	Aricanduva catchment (São Paulo–SP); Narmada River Basin (Índia)	Brasil; Índia	Misto
129	River Jhelum; Padshahi Bagh (Srinagar); Kashmir Valley	India	-
130	Karun (Ahvaz–Farsiat); Dez (Harmaleh–Bamadej); Jarahi/Marun (Moshraheh–Ramshir)	Irã	Montanhoso
131	Bacia do Rio Itajaí Mirim; Santa Catarina	Brasil	Rural
132	Lake Carl Blackwell; Verdigris River at Lenapah, OK; Oklahoma Cross Timber Experimental Range (CTER) micro-catchment; Lake Hefner	USA	Urbano
133	Athabasca River; Jasper; Hinton; Athabasca; Fort McMurray	Canada (Alberta)	Montanhoso; urbano
134	Barak River Basin; BP Ghat; Fulertal	Índia	rural; montanhoso
135	Sg Muar at Buloh Kasap, Johor station; Muar River; Segamat, Johor	Malásia	-
136	531 bacias representativas na CONUS (CAMELS)	Estados Unidos	-
137	Bicol River Basin; Nabua Municipality (Balayan Creek)	Filipinas	Misto
138	Mahaweli River; Manampitiya; Peradeniya; Thaldena	Sri Lanka	-
139	Wu River Basin; Ta-Tu Bridge; Chi-Nan Bridge; Nan-Kang Bridge; Wu-Chi Bridge	Taiwan	Misto; montanhoso
140	Yongxing Bridge Basin; Xiaoshan District; Hangzhou	China	Misto
141	Jingle Watershed (Fenhe River); Lushi Watershed (Luohe River)	China	semiárido; semiúmido
142	Tiaoxi Watershed; Qiaodong Village	China	Montanhoso
143	CAMELS-GB; Chao Lake Basin	Reino Unido; China	Misto
144	Neckar River (entre Rottweil e Oberndorf)	Alemanha	Montanhoso
145	Stillwater River; Sterling region; Massachusetts; USGS station 01095220	EUA	-
146	Shigu e Benzilan Hydrological Stations	China	Montanhoso
147	Beipan River Basin (Dongqing Hydropower Station)	China	Montanhoso
148	Yalong River Basin (YRB); Ertan hydrological station; upper reaches of the Yangtze River	China	montanhoso
149	Mahanadi River basin (estações: Andhiyakore; Bamnidih; Basantapur; Jondhra; Kantamal; Kurubhata; Rajim; Salebhata; Simga; Sundargarh)	Índia	-
150	ChangHua Basin; HeiHe Basin; TunXi Basin	China	rural; montanhoso
151	Spring creek watershed	Canadá	urbano
152	Lena River basin; Lena River	Russia	-
153	Kurkursar basin; Kurkursar River; Noshahr	Irã	-
154	Yaojiang Watershed; Zhangting Station (Ningbo)	China	Misto
155	Karkheh catchment (Cham Anjir; Kashkan; Polezal; Jologir)	Irã	montanhoso; rural
156	Mainstream stations of Mekong River Basin (Chieng Saen; Luang Prabang; Nong Khai; Nakhon Phanom; Mukdahan; Pakse; Kratie)	China; Mianmar; Laos; Tailândia; Camboja; Vietnã	montanhoso
157	Brisbane River; Teewah Creek	Australia	-

158	Hankou Hydrological Station; Yangtze River; Wuhan; limite do médio e baixo curso do Yangtze	China	-
159	Tehri Dam (Bhagirathi e Bhilangana Rivers, Uttarakhand)	Índia	Montanhoso
160	Golok River; Kelantan River; Lanas River; Nenggiri River (Kelantan Basin)	Malásia	montanhoso; úmido
161	-	Reino Unido	-
162	Naula watershed, upper Ramganga river catchment, Ranikhet forest sub-division, Uttarakhand	India	montanhoso
163	Rio Medio	Panamá	-
164	Gardon de Mialet Basin (Cévennes Range, Southern France)	França	Montanhoso
165	Quinebaug river; Nezinscot river; Housatonic river; Sandy river; Saco river; Sacandaga river; Ammonoosuc river; Pemigewasset river; Tenmile river; Royal river	United States of America	-
166	Anglian river basin district (RBD); Northampton; Lincoln; Chelmsford; Milton Keynes	Reino Unido	-
167	Tiaoxi River Basin, Hangzhou, Zhejiang Province	China	Montanhoso
168	Kalu Ganga River Basin; Demuwawatha gauge; Rathnapura District	Sri Lanka	Montanhoso; Urbano
169	Pattani River Basin; TX339 e TX343 stations	Tailândia	Urbano; Montanhoso
170	Magdalena River; Aguadas; Barbosa; El Banco; Palenquito; Puerto Berrío	Colômbia	-
171	Turkey River Basin (sub-bacias Spillville; Eldorado; Elkader; Littleport; Garber)	Estados Unidos (Iowa)	-
172	Bacia do rio Ouémé (Bétérou outlet)	Benin	Rural; Tropical
173	Yangtze River; estações Jiujiang; Anqing; Wuhu; Nanjing	China	Urbano; Estuarino
174	Upper Indus Basin (UIB); Massan Region; Bunji; Besham Qila	Paquistão	Montanhoso; Rural

APÊNDICE E - DADOS DO BLOCO DE DADOS

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
1	precipitação; vazão	ERA5; ALOS PALSAR	Horária; 2016–2022	nível de runoff
2	Nível da água; precipitação; leituras de sensores s1, s2, s3	REDE – Wireless Sensor Network da USP São Carlos	Horária; maio 2014	Nível do rio (altura da lâmina d'água)
3	Precipitação; Vazão; Profundidade de inundação; Uso do solo; População; Infraestrutura	DID (Department of Irrigation and Drainage, Malaysia); JUPEM; MOA; JPDB Terengganu	15 min	Profundidade média e máxima de inundação (m)
4	precipitação; umidade relativa; velocidade do vento; cobertura de nuvens; brilho solar	Bangladesh Meteorological Department (BMD)	Diária; 65 anos	ocorrência de inundação
5	Precipitação; Temperatura; Umidade relativa; Vazão defasada; Uso do solo; Área da bacia; Propriedades do solo	CAMELS-US; CAMELS-CL	Diária; 1988–2000	Vazão (streamflow)
6	Precipitação; Temperatura; Umidade do solo; Evaporação; Nível e vazão do rio; Neve	DSI; TEIAS; MGM; ECMWF	Horária e diária; 2010–2019	Vazão do rio
7	Descargas de 1 e 2 dias anteriores; chuva diária de 12 postos pluviométricos; WAPI (weighted antecedent precipitation index)	Taleh-Zang hydrometric station; 12 rain-gauge stations (Dez Dam watershed)	Diária; setembro 1982–setembro 2014 (7304 eventos)	Vazão média diária (inflow no reservatório do Dez Dam)
8	Precipitação; Vazão; Condições geográficas e topográficas	Estações hidrológicas locais; Iranian Energy Ministry; 17 especialistas	Mensal; 1990–2020	Ocorrência de inundação (binária 0/1)
9	inflow prévio (lags de 1; 2; 3 dias); precipitação superficial do dia; vazão/inflow do reservatório a montante	-	Diária; 1970–2011	inflow diário ao Fuchun River Reservoir (daily runoff)
10	Precipitação; Vazão; Evaporação; Umidade do solo (implícita)	Tunxi Hydrological Station; Wucheng; Shimen; Zuolong; Dalian; Shangxikou; Rucun; Yixian; Yanqian; Xiuning; Chengcun (10 estações de chuva)	Horária; 1991–1999	Vazão (streamflow)
11	Nível da água; Precipitação; Pressão atmosférica; Velocidade do vento; Espessura da neve; Precipitação; Temperatura do ar; Hora	Bashhydromet (Departamento de Hidrometeorologia e Monitoramento Ambiental da Bashkíria)	Diária; 2000–2021 (1 025 815 registros)	Nível da água (water level)
12	Chuva; Vazão; Nível do rio; Temperatura; Velocidade do vento; Cobertura de nuvens; Ocorrência histórica de enchentes	Bangladesh Water Development Board (BWDB); India Meteorological Department (IMD); Indian Hydrology Department; UNDRR; IFRC; Oxfam	Mensal; 1945–2022 (78 anos)	Nível do rio; Vazão; Severidade de inundação (0–2)
13	Precipitação antecedente e prevista (6 estações); chuva máx. 3 h; centros de chuva; intensidade	Taizhou Municipal Bureau of Water Resources (estações Xiatian; Tuoxi; Sixie; Fangqian; Sijakeng; Lishimen); vazões afluentes do LSM	Horária; 1987–2020	Vazão afluente (inflow)
14	Vazão média mensal; precipitação; temperatura; variáveis hidrológicas derivadas	Flood Irrigation Department Kashmir	Diária; 1980–2021	Vazão (descarga do rio)

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
15	Vazão; Precipitação; Temperatura	Ministère de l'Environnement et de la Lutte contre les changements climatiques, de la Faune et des Parcs du Québec	Horária; 2008–2020	Vazão (flow rate)
16	Vazão; Nível d'água; Hidrogramas sintéticos; Volume de onda	INHGA (Instituto Nacional de Hidrologia e Gestão de Água da Romênia); S.C. AQUAPROIECT S.A.	Anual	Vazão máxima; Nível d'água; Volume da onda de cheia
17	Vazão antecedente; chuva; lag 1–7 dias; dados de PACF e ACF	Estações hidrométricas locais no rio Karaj	Diária; 1954–2008; 1947–2008; 1982–2008	Vazão (streamflow diário)
18	Vazão; precipitação; temperatura; defasagens de 1–20 dias/meses	Arquivo da Regional Water Company of Kermanshah; estação hidrométrica de Polechehr	Diária; 1986–2017; Mensal; 1986–2017	Vazão (streamflow)
19	Precipitação; Nível d'água (water level)	Estações locais de chuva (Brgy. Calumpang; Capinahan Elementary School; Brgy. Villavi Centa)	Horária; 2016–2017 (treino); 2021 (avaliação)	Nível d'água (flood water level)
20	Nível do rio (L(t-1); L(t-2); L(t-3)); Precipitação (implícita)	Department of Irrigation and Drainage Malaysia (JPS)	Horária; 2008–2018	Nível do rio (river level)
21	Vazão (Qt); Precipitação (Pt); Temperatura média (Tavg); Umidade relativa (Rh)	Central Water Commission (CWC), Shillong; India Meteorological Department (IMD), Pune	Mensal; 2001–2020	Vazão (streamflow)
22	Vazão diária Q(t); Q(t-1); Q(t-2); Q(t-3)	Turkish State Hydraulic Works (DSI)	Diária; 1981–2010	Vazão (river flow)
23	Nível do rio; Precipitação (dados históricos)	Estação Phu An (Ho Chi Minh City)	30min; 2021–2023	Nível do rio (water level)
24	Sinais de satélite (brilho Tb); Vazão (Q); Largura (b); Profundidade (d); Velocidade (v)	AMSR-E; AMSR2; USGS; GDACS	Diária; 2014–2017	Vazão e nível d'água (river discharge; water level)
25	Altura d'água (nível); vazão média; históricos horários de estações em montante e na estação-alvo	HydroPortail (https://hydro.eaufrance.fr)	Horária; 2007–2022 (Kogenheim); 2007–2019 (Waltenheim)	Altura d'água (water level)
26	Precipitação; Vazão; Umidade; Temperatura; Velocidade do vento; Fator de orvalho; Evaporação	WAPDA (Water and Power Development Authority)	Diária; 1991–2022	Situação de cheia (Flood/No-Flood); Vazão (discharge)
27	Vazão; precipitação (pluviômetros); nível piezométrico; lags e agregações horárias	SAIH/Confederación Hidrográfica del Segura (CHS)	5 min; 2021–2023	Vazão (streamflow) em La Puebla e Desembocadura
28	Precipitação; Vazão; Temperatura máxima e mínima	Meteorological Department and Irrigation Department	Diária; 2000–2011	Vazão (streamflow)
29	Precipitação; temperatura; vazão antecedente (Qt-1, Qt-2); defasagens de 3 dias	Indian Meteorological Department (IMD Pune); India WRIS (Nowrangpur station)	Diária; 1966–2013	Vazão (streamflow)
30	Precipitação; Vazão	National Agency of Hydraulic Resources (ANRH)	Diária; 1990–2000	Vazão (daily flow rate)
31	Chuva antecedente e prevista; vazão antecedente (Qobs t-n...t-1)	Medições da estação hidrológica Maduwang (bacia do Bahe)	Horária; 2000–2010; (12 eventos: 9 treino/2 validação/1 teste)	Vazão (runoff no exutório)
32	Vazão mensal; Precipitação média	Drainage and Irrigation Department of Malaysia	Mensal; 2001–2019	Vazão (river flow)
33	Precipitação; Evapotranspiração; Temperatura; Vazão	National Hydraulic Resources Agency (ANRH)	Diária; 1992–2002	Vazão

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
34	Nível da água; precipitação; vazão; escoamento superficial	USGS; NWS (Weather Surveillance Radar-1988 Doppler); Hydrology Laboratory Distributed Hydrologic Model (HLRDHM)	Horária; 1996–2012	Previsão de ocorrência de inundação (binária) em horizonte de 1–6 horas
35	Área de bacia (AREA); Intensidade de chuva (I62); Chuva anual média (MAR); Evapotranspiração (MAE); Densidade de drenagem (SDEN); Slope S1085; Área florestada (FOREST); Fator de forma (SF)	Australian Bureau of Meteorology; WaterNSW; Department of Environment, Land, Water and Planning of Victoria	Anual	Vazão (quantis Q2–Q100)
36	Precipitação; Vazão; Temperatura máxima e mínima; DEM; Uso e tipo de solo	Spanish National Meteorological Agency (AEMET); Spanish National River Flow Network (ROEA); IGN; Corine Land Cover; DSOLMAP	Diária; 1985–2020	Vazão (runoff)
37	Vazão observada em 7 estações; dados de descarga (m³/s)	Estações hidrológicas nacionais (Vietnã)	Diária; 1995–2014	Vazão (streamflow)
38	Vazão (discharge) em múltiplas estações fluviais	Punjab Irrigation Department	Semanal; 1991–2017	Vazão (streamflow)
39	Vazão; Nível da água; Precipitação	Corporación Autónoma Regional de Cundinamarca (CAR)	Horária; 2009–2013	Nível do rio (flood level)
40	Monsoon Intensity; River Management; Drainage Systems; Climate Change; Deforestation; Urbanization; Dam Quality; Siltation; Agricultural Practices; Coastal Vulnerability; Wetland Loss; Population Score; Political Factors	Kaggle (public dataset)	-	Probabilidade de inundação (Flood Probability)
41	Chuva; Vazão; Nível do rio	Melbourne Water (www.melbournewater.com.au)	Horária; 2017–2020	Nível do rio (river level)
42	Precipitação; Temperatura máxima; Temperatura mínima; Potencial evapotranspiração (pet); Evapotranspiração real (et); Conteúdo de água no solo (sw_final); Percolação (perc); Escoamento superficial (surq_gen); Fluxo lateral (latq); Vazão estimada do SWAT+ (flow_out)	Spanish National River Flow Network (ROEA); Hydrographical Studies Center; Spain weather datasets (conforme indicado no artigo); SWAT+ Spain datasets	Diária; treino 1985–1989; validação 1990–2005; teste 2006–2020	Vazão (streamflow)
43	Chuva; Vazão; Nível de fluxo	50 estações pluviométricas e 1 estação hidrológica de Xixian; dados horários; interpolação IDW e método Thiessen	Horária; 2011–2018	Vazão (Flow)
44	Precipitação; Vazão; Temperatura mínima; Temperatura máxima; Umidade relativa; Evaporação; Velocidade do vento	Estações meteorológicas e hidrológicas locais	Diária; 2003–2012	Vazão (River flow)
45	Vazão diária defasada (Q(t–n)); variáveis derivadas de séries de vazão	India-WRIS WebGIS; Indian Meteorological Department	Diária; 2006–2016	Vazão (Qflow)

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
46	Q(t-1); Q(t-2); Q(t-3); Q(t-4)	Estações hidrométricas Ab Garmeh; Tireh Marvak; Gelehr-rood; Silakhor; Tireh; Cham Chit; Ab Sardeh; Sezar; Taleh Zang; Tang Pangeh	Diária; 2008–2018	Vazão (streamflow)
47	Precipitação; Vazão Qt; Temperatura; Evaporação	Departamento de Irrigação e Drenagem da Malásia; 11 estações telemétricas do SMART catchment	30min; 2008–2021	Vazão (streamflow)
48	precipitação; temperatura; vazão passada (P3); área de drenagem; coordenadas do centróide; índice de compacidade de Gravelius; altitude média; uso do solo	SNIRH/Agência Portuguesa do Ambiente (dados de vazão); ERA5–Land (meteorologia); GFS (previsões); Copernicus GLO-30 DEM; Copernicus CORINE Land Cover	Diária; 1980–2022	vazão específica q (m³/s/km² × 10³)
49	Vazão; precipitação; nível de reservatório; descarga de barragem	SNIRH (Sistema Nacional de Informação de Recursos Hídricos)	Diária; 1984–2024	Vazão (discharge)
50	Precipitação; temperatura; umidade; vazão anterior; topografia	Estações de chuva e hidrológicas locais	Diária; 1960–2016	Vazão (runoff; discharge)
51	Precipitação total e convectiva; temperatura; vento U/V; umidade específica; altura geopotencial (200; 500; 850 hPa); elevação; precipitação/temperatura CN05.1 (forçamento); vazão observada (Shigu)	ECMWF Sub-seasonal to Seasonal (S2S) reforecasts; CN05.1 (precipitação e temperatura); vazão diária da estação Shigu	Diária; 1981–2019;	Vazão (streamflow); pico de cheia (maximum daily flow)
52	Precipitação; temperatura mínima; temperatura máxima; vazão; equivalente de água na neve (SWE)	Meteorological Service of Canada; Water Survey of Canada; BC Ministry of Environment	Diária; 1995–2011	Vazão
53	Inflow; nível d'água; ciclo de regulação do reservatório	Yenisei Basin Water Administration; Federal Agency for Water Resources; Central Siberian UGMS	Diária; 2009–2022	Vazão (inflow)
54	Nível da água (m) com defasagens n–1...n–10; Chuva (mm) com defasagens n–1...n–10	DOST–Advanced Science and Technology Institute (ASTI); estações ARG (Automated Rain Gauge) e WLMS (Water Level Monitoring Stations)	Treino 2013–2014; Testes Jul–Oct 2014	Nível do rio (water level)
55	Chuva (MAP); nível da água em três estações	KMA; WAMIS; HRFCO	Horária; 2003–2020	Nível da água (water level)
56	Inflow; outflow; tempo (T)	Dados experimentais de Viessman e Lewis (2003); Wilson (1974); Wu et al. (1985)	Diária	Vazão (outflow)
57	Vazão em Rottweil (upstream); chuva; vazão em Oberndorf (downstream)	Institut für Wasser- und Umweltsystemmodellierung, Stuttgart	Horária; 1999–2000	Vazão (discharge)
58	Precipitação; Vazão; Nível d'água; Tempo (dia/mês/hora); distância entre bacias; maré	ERA5-Land (ECMWF); SNIRH/APA; SRTM; IH (Instituto Hidrográfico)	Horária; 2001–2021	Vazão fluvial na barragem; Nível da água no estuário
59	Precipitação; temperatura; radiação solar; umidade; evapotranspiração; absorção; percolação	CWC Bhubaneswar; IMD Pune	Mensal; 1970–2019	Vazão fluvial; descarga de cheia
60	Precipitação; nível d'água	Department of Irrigation and Drainage (DID) Malaysia	Mensal; 2001–2010	Nível do rio (water level)
61	Vazão (séries temporais de descarga)	USGS National Water Information System; MOPEX	Diária; 1970–2003	Vazão (streamflow)

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
62	Precipitação; Vazão; Temperatura; Cobertura vegetal; Custo de danos (MUSD)	Estações hidrológicas locais; Water Management Organisation of South Khorasan	Horária; Diária; 1990–2020	Ocorrência de inundação (0/1); Danos de inundação (MUSD)
63	Precipitação; Direção do vento; Velocidade do vento; Temperatura; Umidade; Nível d'água	AMeDAS; Japan Meteorological Agency (JMA); Japan Meteorological Business Support Center	período setembro 2019	Probabilidade de inundação
64	Nível da água; Vazão; Chuva; Latitude; Longitude; Data	Bangladesh Water Development Board (BWDB); Bangladesh Meteorological Department; Kaggle (dados da Índia)	Diária; 1987–2023	Nível da água; Ocorrência de inundação; Nível de perigo
65	Precipitação; temperatura do ar; vazão de entrada e saída; evapotranspiração; umidade relativa; temperatura da água; vento; temperatura máxima e mínima; noites de hóspedes	Hungarian State Meteorological Service; Ministry of Tourism; autoridades locais de água	Diária; 2002–2022	Nível da água do lago (Lake Water Level)
66	Precipitação; Temperatura; Umidade; Pressão; Velocidade e direção do vento; Radiação de onda curta e longa; Vazão observada	ECMWF TIGGE; China Meteorological Forcing Dataset (CMFD); 51 estações locais	Horária; 2010–2017	Vazão (streamflow)
67	Precipitação; vazão; duração do evento; profundidade do escoamento; descarga de pico; intensidade média e máxima da chuva	Estação hidrológica de Jingle; dados de chuva e vazão locais	Diária; 1970–2014	Vazão e volume de cheia
68	Qtp-2 Rio Negro; Qtp-1 São Bento; Qtp-1 Fluvópolis; Qtp-1 União da Vitória (vazões defasadas como entradas)	-	Diária; 1964–2015	Vazão média diária (previsão 1 dia à frente)
69	Precipitação; Vazão; SPI; API; Q05; Q95; vazão média; pico anual	Bureau of Meteorology (Austrália); WaterNSW; Thai Meteorology Department	Diária; 1900–2018 (chuva/vazão); SPI mensal 1981–2013	Vazão; índice SPI (severidade e duração de seca)
70	Precipitação; vazão diária (Q e P com defasagens de até 4 dias)	Lorestan Regional Water Company	Diária; 2010–2020	Vazão do rio
71	Defasagens da vazão diária (Qt/C01; Qt/C02; Qt/C03; Qt/C04; Qt/C05)	-	Diária; 2001–2015	Vazão diária do rio
72	temperatura do ar média; pressão do ar; umidade relativa; velocidade do vento na superfície; direção do vento; precipitação	estações sinóticas na bacia; estação hidrométrica Armand; saídas do WRF	6 h; março de 2016	vazão; hidrograma de cheia no posto Armand
73	Precipitação; vazão; umidade antecedente; PR24; intensidade e duração da chuva	SAIH-HIDROSUR (Sistema Automático de Informação Hidrológica); CNIG (satélites e DEM)	Horária; 1997–2021	Hidrograma de cheia (vazão de pico; forma completa do evento)
74	Precipitação; vazão; defasagens temporais; chuva antecedente	Department of Irrigation and Drainage (DID), Malaysia	Horária; 2002–2013	Vazão (runoff)
75	Precipitação; vazão; defasagem temporal (6h–48h)	67 estações pluviométricas e fluviométricas; Three Gorges Reservoir Authority	6 horas; 2003–2016	Vazão (reservoir inflow)
76	Vazão (Qt-1...Qt-5); chuva atual	Estações hidrométricas (Abura, Meki); estações meteorológicas locais (Thiessen polygons)	Diária; 2006–2017	Vazão diária do rio

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
77	Precipitação; temperatura; umidade; intensidade de chuva; evapotranspiração	Estações fluviométricas locais (Brahmani gauging stations)	Diária; (360 amostras)	Vazão (QFD — flood discharge)
78	A (área de drenagem); Itc_ARI (intensidade de chuva de projeto); S (declividade, m/km); E (evapotranspiração média anual); R (chuva média anual)	Banco de dados de cheias da revisão do Australian Rainfall and Runoff (ARR); Bureau of Meteorology (chuva)	-	Vazão de cheia (quantis Q2–Q100, m³/s)
79	vazão (runoff)	-	Diária; (390.000 registros mas sem período indicado)	Vazão (runoff)
80	Níveis de água de quatro estações a montante	Department of Irrigation and Drainage (DID) Malaysia	15 min; novembro de 2011	Nível da água (water level)
81	Precipitação; vazão; volume de cheia; tempo de pico	Estações Wangtian; Dachang; Liuxiang; Zhongping (hidrológica)	5min; 2002–2023 (séries de chuva e vazão)	Vazão; volume de cheia; tempo de pico
82	Precipitação; vazão; umidade; pressão; nível da água	NASA GPM e TRMM (2006–2014)	Diária; 2006–2014	Nível da água; severidade de inundação
83	Nível da água; vazão; chuva (limitada)	Serviço Central d'Hydrométéorologie et d'Appui à la Prévision des Inondations (SPC Toulouse)	Horária; 2007–2018 (30 eventos; ~30.000 pontos)	Vazão; nível da água
84	nível d'água; chuva (precipitação)	-	2015	nível do rio (nível d'água); chuva (predição)
85	precipitação; vazão	Observação local	Horária; 2014–2021	flood peak size
86	Precipitação; Vazão; Umidade do solo; Tendência de chuva acumulada	China Shaanxi e Zhejiang Hydrology Administration	Horária; 1998–2012	Vazão (stream-flow)
87	Precipitação; Temperatura; Vazão; Nível d'água	Estações hidrométricas DV, KS, BA; Estações meteorológicas AR, FA, SH	10min; 2018–2019	Vazão (streamflow)
88	chuva; nível do rio (nível d'água/debito)	Citarum River Hall; Central Citarum River Basin/Office (informado pela equipe)	Diária	nível do rio previsto; chuva prevista; status final de inundação (Flood/No Flood) por limiares
89	Vazão	estaciones hidrológicas de la Corporación Autónoma Regional de Cundinamarca (CAR); cartografía IGAC	Horária; 2009–2013	Vazão
90	Nível d'água (WL) diário; precipitação média; vazão média; lag de 1 a 12 dias	Bureau of Meteorology (Australia); NSW Office of Water; NSW Department of Service Technology and Administration (Manly Hydraulics Laboratory)	Diária; 2005–2021	Nível do rio (Water Level)
91	Precipitação; Vazão; Temperatura; Umidade; Pressão atmosférica; Solo; Uso do solo	Google Earth Engine (CHIRPS; ERA5-Land; ESA WorldCover; OpenLandMap; SRTM); Flood Forecasting Division (PMD)	Diária; 2010–2022	Vazão (river flow)
92	Qt–1; Qt–2; Qt–3; Qt–4; Qt–5 (vazão defasada)	Haditha Dam Project Administration — General Authority for Dams and Reservoirs, Iraqi Ministry of Water Resources (dados não publicados); estação Husaybah	Diária; Mensal; Sazonal; 1985–2024; (Treino 1985–2012/Teste 2012–2024)	Vazão (inflow) a montante do reservatório

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
93	Chuva; Maré; Profundidade da água; Elevação; Topographic Wetness Index (TWI); Depth-To-Water (DTW)	NOAA; HRSD; USGS; City of Norfolk GIS Bureau; STORM	Horária; 2016–2018	Profundidade da água na rua (nível de inundação)
94	Vazão do rio; nível do mar	Office of Public Works (OPW), Irlanda	15 min; 2009	Altura d'água; profundidade da inundação
95	Níveis d'água diários em Thakhek e Nong Khai	Dados hidrométricos da Mekong River Commission (MRC)	Diária; 1994–2003	Nível do rio (altura d'água)
96	séries temporais SAR; observações de sensoriamento remoto spatio-temporal	Sentinel-1	2017-2023	damage forecasting (previsão de dano por inundação)
97	Total precipitation (TP); 2-m temperature (T2M); surface net solar radiation (SSR); surface net thermal radiation (STR); snowfall (SF); surface pressure (SP); atributos HydroATLAS; previsões IFS (0–7 dias)	ECMWF IFS HRES; ECMWF ERA5-Land; NOAA CPC Global Unified Gauge-Based Analysis of Daily Precipitation; NASA IMERG; HydroATLAS; GRDC (alvos de vazão)	Diária; 1984–2021	Vazão (river discharge) diária; eventos por períodos de retorno (1; 2; 5; 10 anos)
98	runoff (discharge)	Hydrological Yearbook of the People's Republic of China; Pengshan Hydrological Station	Diária; 2010-2024	runoff (m3/s)
99	Precipitação; nível d'água; temperatura; umidade; velocidade e direção do vento; radiação solar; atividades humanas	Departamento de Recursos Hídricos de Zhejiang; China Meteorological Data Service Centre	Horária	Nível do rio
100	Vazão; precipitação; temperatura; umidade; vento; radiação solar	Departamento de Recursos Hídricos de Queensland; dados de monitoramento local	Horária; 2009–2014	Vazão (river flow)
101	Nível do rio (cm); médias móveis (Mavg) dos últimos 5–60 min e 1–12 h	WSN REDE (ICMC/USP) em São Carlos; nó meteorológico com pluviômetro e sensores de temperatura/umidade/pressão	1min; outubro de 2016–abril de 2017	Nível do rio (previsão de curto prazo 1–5 min); estados de alerta (verde; amarelo; vermelho) derivados por limiar
102	Weekly water level (extremos semanais via block máxima–mínima); IMFs; residual	Department of Irrigation and Drainage Malaysia (DID)	Diária; 2011–2022; (treino 2011–2020/teste 2020–2022)	Water level
103	Chuva (Sylhet; Jaintia Hills; Karimganj; Hailakandi; North Cachar Hills; Cachar; Cherrapunji); Nível do rio Surma/Shurma; Histórico de severidade de inundação (flood(y))	Bangladesh Meteorological Department; India Meteorological Department; Bangladesh Water Development Board (BWDB); World Health Organization (WHO); ReliefWeb; Dataset inicial online (Kaggle)	Mensal; 1955–2016	Severidade/nível de inundação (flood(y)=0;1;2)
104	Precipitação; vazão; baseflow; tempo de resposta; entropia	Duero River Basin Authority (IDE-Duero); AEMET (2021)	Horária; 20–30 janeiro 2021	Vazão (runoff; escoamento superficial)
105	Longquan: Q(t); Q(t–1); Q(t–2); P(t–3); Jinhua: Q(t); Q(t–1); Q(t–2); P(t–10)	-	Horária; 1994–2013	vazão (streamflow)
106	precipitação areal média; evaporação areal média; vazão afluente observada (Qo)	estações locais (17 postos de chuva/evaporação); Reservatório Lushui (inflow)	3h; 2012–2019	vazão afluente (inflow) / previsão de cheias

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
107	Precipitação; vazão; temperatura; umidade; nível do lençol freático	-	Diária; 30 anos de dados	Vazão (streamflow)
108	Nível do rio; precipitação (volume de chuva)	Rede de sensores sem fio REDE (desenvolvida pelo grupo da USP)	5 min; mar/2013; 1 min; abr/2014	Nível do rio
109	Temperatura; chuva; nível da água; sedimento	-	Diária; 1971–2004	Vazão (water discharge)
110	Chuva horária; vazão horária	Estações hidrológicas locais	Horária; 1981–2007 (Tunxi); 1998–2010 (Changhua); 2003–2010 (Heihe)	Vazão (flow discharge)
111	Precipitação; vazão; temperatura; umidade específica; runoff superficial; runoff subsuperficial; umidade do solo (4 camadas)	Shaanxi Hydrological Bureau; ERA5-Land; China Regional Ground Meteorological Element Driven Dataset (MET)	Diária; 1980–2020	Vazão (runoff)
112	monsoonal rain; duration in day; number of dead; number of displaced; snowmelt and ice jams; magnitude; centroid; heavy rain; torrential rain; total of affected area; tropical storm	Environment Agency; centros de monitoramento de cheias	-	Severidade do nível d'água (normal; abnormal; high-risk)
113	precipitação; PET; umidade específica; temperatura do ar; vento U; vento V; radiação de onda longa (RLDS); radiação de onda curta (RSDS); baseflow	NLDAS-2; USGS; NWM v3.0 (reanalysis)	Horária	vazão (discharge)
114	Nível d'água; descarga simulada; maré; vazão de entrada	HEC-RAS 6.2 (simulação hidráulica 1D)	Horária; 2016–2019	Vazão (discharge)
115	rainfall; water level; annual snowfall; floods (0/1)	IGISMAPs; Department of Drainage and Irrigation Malaysia (DID)	Anual; 1986–2000	floodings events (0/1); flood frequency
116	Meteorológicas (temperatura; precipitação; umidade específica; pressão; vento; água no solo; runoff; tipo de solo; declividade; máscara terra-mar)	ERA5 (ECMWF); GloFAS (Copernicus Climate Data Store)	Horária; 1981–2016	Vazão do rio (river discharge)
117	QYu; QJin; ZLong; ZYang; PYu; P3Yu (picos de vazão; níveis máximos; chuva máxima 1 h; chuva máxima 3 h)	estações pluviométricas de Yangshuo; Longtan water level station; Yangshuo Hydrological Station; saídas de modelos HEC-HMS	48 h; 2016–2023; 166 cenários (38 históricos; 128 de projeto)	profundidade máxima de inundação; velocidade máxima de escoamento

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
118	precipitation (moving averages); temperature; evapotranspiration; snow water equivalent; drainage area; elevation; slope; slope–area ratio; soil bulk density; surficial geology contacts; faults; hydraulic conductivity; depth to soil restrictive layer; permeability index; water content; depth to water table; base-flow index; number of springs; cropland cover; forest cover; wetland cover; number of water diversions; number of roads; number of water wells; Year; Month	USGS; Wyoming Cooperative Fish and Wildlife Research Unit; University of Wyoming; PRISM; Soil Survey; Geological Survey; MRLC; Wyoming state (segundo a descrição do conjunto)	Mensal; 2012–2017; 971 eventos	streamflow (m3/s)
119	precipitação; vazão; temperatura	Environment Canada Banff station; Alberta Environment	Diária; 1909–2013	vazão
120	Precipitação; nível da água; vazão; temperatura; topografia; atividades humanas	Water Conservancy Department of Zhejiang Province; China Meteorological Data Service Centre	Horária; abril–julho 2021	Nível da água (flood level)
121	Deslocamento da superfície da água; altura de nível; vazão; profundidade; velocidade; parâmetros hidrodinâmicos	USGS (waterdata.usgs.gov)	Anual; 1900–2019	Deslocamento da superfície da água (nível)
122	chuva de pluviômetros (mm); chuva de radar QPESUMS (mm); chuva de satélite PERSIANN-CCS (mm)	15 pluviômetros; QPESUMS (CWB Taiwan; NSSL USA); PERSIANN-CCS (CHRS, University of California, Irvine)	2006–2009; 13 eventos	vazão afluente ao reservatório (m3/s)
123	monthly average discharge (runoff series); 130 climate circulation indices; ENSO indices; lags de runoff (12 months)	China Hydrological Yearbook; National Climate Center of the China Meteorological Administration	Mensal; 1953– 2011	runoff (monthly average discharge)
124	Nível do rio; precipitação acumulada 48h; altura d'água; vazão	ANA; SGB; CHRS-UCIrvine (PDIRnow)	Horária; 2015–2022	Nível do rio (altura d'água)
125	Qt-1; Qt-11; Qt-12; índice temporal (T); chuva mensal do AHD com defasagens 1–6; 12 meses	Nile Water Authority, Ministry of Water Resources (Egypt)	Mensal; 1871–2001	Inflow/streamflow mensal no Aswan High Dam (Qt)
126	Vazão diária dos três rios	West Azerbaijan Regional Water Company	Diária; 1990–2020	Vazão do rio (m³/s)
127	Nível da água; vazão; tempo de defasagem (lead time); dados de maré	Bangladesh Water Development Board (BWDB); Flood Forecasting & Warning Center (FFWC)	Diária; 1979–2014	Nível da água (water level)
128	Precipitação; vazão; temperatura; radiação solar; umidade relativa; velocidade do vento; elevação média; declividade; uso e cobertura do solo; características do solo	SAISP; IMD; India-WRIS; USGS	Diária; horária; 2019 (Aricanduva); 1994 (Narmada)	Nível da água; vazão (streamflow)

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
129	Bringi (q1); Aripah (q2); Sandran (q3); Lidder (q4); Aripal (q5); Watlala (q6); Romshu (q7); Vishow (q8); Rambira (q9); Rainfall; PET; NDVI	Irrigation and Flood Control Department, Srinagar; Indian Meteorological Department (IMD); India Water Portal; Bhuvan-ISRO	Diária; 1990–2018	vazão no Jhelum em Padshahi Bagh
130	Hidrograma de entrada (vazão a montante); $\Delta t=1$ h	Iran Water Resources Management Company	Horária; 2015-11-27 (Karun); 2013-01-21 (Dez); 2014-04-29 (Marun)	Vazão (hidrograma de cheia; descarga de saída)
131	Nível da água; vazão; declividade do leito; coeficiente de Manning	Agência Nacional de Águas (Hidroweb)	15 min; 5 dias (jan 2020)	Vazão; nível da água
132	Rainfall acumulado Rain_00hr–Rain_600hr (amostragem a cada 12 h; últimas 24 h hora-a-hora para microbacia); target_001dayEarlier; target_002dayEarlier; mês	Stage IV hourly rainfall (NCEP); USGS National Water Information System; medições de níveis/lâmina do Lago Carl Blackwell (vários medidores históricos); CTER H flume	Horária; 2002; 2007; 201-2016	Nível do lago (flood stage); estágio de vazão; escoamento superficial
133	vazões antecedentes em Jasper; Hinton; Athabasca (defasagens de 1–10 dias)	Water Survey of Canada (WSC)	Diária; 1971–2014; treino 1971–2000/teste 2001–2014	vazão no posto Fort McMurray
134	Precipitação; temperatura; radiação solar; umidade; evapotranspiração	Indian Meteorological Department (IMD)	Mensal; 1969–2018	Vazão (flood discharge)
135	Lags 1–3; stream water flow; IMF-1; IMF-2; IMF-3; IMF-4; IMF-5	Sg Muar at Buloh Kasap, Johor station	Mensal; 2014–2023; treino 2014–2020/teste 2020–2022	River water level (nível do rio)
136	precipitação; temperatura máxima; temperatura mínima; radiação de onda curta; pressão de vapor; atributos estáticos de bacias; previsões de precipitação (ECMWF-IFS)	CAMELS; Daymet; Maurer; NLDAS; ECMWF-IFS; ERA5-Land	Diária; 1980–2010 (CAMELS)	vazão; detecção de picos por períodos de retorno (2; 5; 10; 20; 50 anos)
137	Temperatura; umidade; índice de calor; chuva horária; chuva diária; nível da água; velocidade do vento	Sistema de monitoramento local (Indoor e Outdoor Control Units)	1min; Janeiro–Março 2023	Nível do rio; vazão
138	chuva diária (0;1;2 dias de defasagem)	Department of Meteorology, Sri Lanka; Department of Irrigation, Sri Lanka	Diária; 2000–2017	nível do rio (water level)
139	Vazão horária em estações; precipitação; lag temporal entre estações	Discharge stations (Taiwan Water Resources Agency)	Horária; 1996–2017; durante 10 tufões	Vazão (discharge)
140	Precipitação; nível d'água; vazão; hora; mês; dados lunares	Xiaoshan District Hydrological Station; Baiyan Bridge Flow Station	Horária; 2021–2023	Nível do rio
141	Chuva; Vazão; Nível; Dados horários	Estações locais pluviométricas e fluviométricas	Horária; 1971–2016	Vazão (runoff)
142	Nível d'água; chuva; umidade do ar; temperatura	Estações locais; Central Meteorological Observatory; Zhejiang Rainfall Real-time Website	Horária; 2020–2021	Nível da água (flood level)
143	Precipitação; Vazão; Temperatura; Evapotranspiração; Umidade; Radiação solar; Hidro_rainfall; Hidro_runoff	CAMELS-GB Dataset; Climate Change Research Centre (CAS); estações hidrometeorológicas locais	Diária; 1970–2015	Vazão (runoff)

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
144	Precipitação; Vazão; Parâmetros hidráulicos; Lateral flow; Altura do leito; Rugosidade de Manning	University of Stuttgart; Estações locais de precipitação	Horária; 1999–2002	Vazão (discharge)
145	precipitação (P); temperatura da água (T); vazão defasada de 1 dia (Q_{t-1})	United States Geological Survey (USGS); Massachusetts–Rhode Island Water Science Center	Diária; 2014–2017	vazão do rio (Q_t)
146	Precipitação; Vazão; Evaporação; Umidade; Cobertura de nuvens; Temperatura; Radiação solar; Vento; CAPE	Estações hidrológicas locais	Diária; 2010–2021	Vazão dos rios (runoff)
147	Vazão; Temperatura; Umidade; Precipitação; Radiação solar	Climate Data Store; Guizhou Qianyuan Power Company Limited	Diária; 2015–2023	Vazão (runoff)
148	precipitação; temperatura; evapotranspiração; uso do solo; tipo de solo; fatores de terreno (elevação; declividade; aspecto; flutuação relativa etc.); índice de características climáticas; saída do modelo VIC (acoplamento unidirecional)	China Surface Climate Data Daily Dataset (V3.0) – China Meteorological Data Service Centre; USGS HydroSHEDS (DEM); University of Maryland (land cover); NOAA Hydrology Office (global 5' soil texture)	Diária; 1980–2013	vazão (runoff diário)
149	Vazão diária antecedente; Chuva diária antecedente; Aproximações wavelet (Meyer DWT) de vazão e chuva	Central Water Commission (Índia)	Diária; 1990–2010	Vazão
150	Precipitação; Vazão	STA-LSTM datasets	Diária; 1981–2010	Vazão (flow)
151	precipitação; nível d'água	-	Horária; 2008, 2011–2013	Nível da água (water level)
152	maximum daily water level; water temperature; river events; ice thickness; discharge; air temperature; relative humidity; atmospheric pressure; precipitation; snow coverage; snow height; dados agregados (médias; amplitudes; somas; rankings de eventos)	Russian Federal Service for Hydrometeorology and Environmental Monitoring; Federal Agency of Water Resources; MODIS MOD10A1; SRTM DEM; estações meteorológicas; hidrométricas	Diária; 1985–2012	maximum daily water level
153	Rt; Rt-1; Rt-2; Rt-3; Qt-1; Qt-2; Qt-3	Mazandaran Meteorological Organization; Autoridade Regional de Recursos Hídricos; quatro estações pluviométricas; estação hidrométrica de saída do Kurkursar	Diária; 1997–2012	vazão (Q_t)
154	Precipitação; Vazão; Nível; Temperatura; Umidade; Evapotranspiração; Velocidade do vento	Ningbo Hydrologic Station; Central Water Commission; Dados meteorológicos locais	Horária; 2007–2014	Nível d'água
155	Precipitação; Vazão ($Q(t)$); Vazão defasada ($Q(t-1)$ a $Q(t-4)$)	Lorestan Regional Water Company	Diária; 2010–2020	Vazão do rio
156	Precipitação; Temperatura; Vazão; Nível da água	Mekong River Commission (MRC); Climate Prediction Center (NOAA)	Diária; 1979–2019	Vazão (streamflow)

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
157	Vazão horária defasada (Qflow t-6...t)	Water Monitoring Data Portal (Department of Environment & Resource Management, Queensland) (conforme seção de dados)	Horária; 2014–2018	Vazão (Qflow) horária
158	Vazão mensal; componentes IMF e resíduo de EMD	Yangtze River Water Resources Commission	Mensal; 1952–2018	Vazão (streamflow)
159	Chuva; Vazão; Temperatura; Área de cobertura de neve	THDC India Limited; IMD (India Meteorological Department); MODIS/Terra	Diária; 2006–2020	Vazão (streamflow)
160	Índices climáticos Nino 3.4; PDO; NAO; SOI (com defasagens de 1 a 9 meses)	Japanese Agency for Marine-Earth Science and Technology (JAMSTEC)	Mensal; 2005–2015	Vazão (streamflow)
161	Dados de sensores; nível da água; medições de fluxo; variáveis meteorológicas	Department for Environment, Food, and Rural Affairs (DEFRA, UK)	Mais de 1 milhão de registros	Status da água (Good, Moderate, Bad)
162	Rt; Rt-1; Qt-1; Qt-2	Soil Conservation Divisional Forest Office (SCDFO), Ranikhet, Uttarakhand State, India	Diária; 2000-2004	daily streamflow (Qt)
163	Chuva; nível d'água; vazão	Estações hidrométricas locais	Horária; 2016–2021	Vazão
164	Precipitação em 3 pluviômetros (Barre-des-Cévennes; Saint-Roman-de-Tousque; Mialet); Cumulativa de chuva; Vazão	Serviço Central de Hidrometeorologia e Previsão de Cheias (SCHAPI)	30min; 1992–2008	Vazão (discharge)
165	precipitation; streamflow	MOPEX basins; USGS National Water Information System	Diária; 1980–2005	streamflow discharge
166	RBD; operational and catchment management; waterbody; water level; water quality assessment; flood measurement; classification; environmental effect; protection	Environment Agency — Anglian RBD dataset	149.676 eventos	13 river states (Active; Bad; Does not require assessment; Does not support good; Fail; Good; High; Moderate; Moderate or less; No trend; Poor; Supports good; Upward trend)
167	Precipitação; Temperatura; Umidade; Velocidade e direção do vento; Nível da água; Dados geográficos	China Meteorological Data Service Centre; Departamento de Recursos Hídricos de Zhejiang	Horária; 2022	Nível da água (water level)
168	Precipitação; Nível d'água; Dados de chuva de cinco estações (Allupola; Hapugastenna; Landsdown; Rathnapura; Wellandura Estate)	Department of Meteorology; Department of Irrigation (Sri Lanka)	Horária; 1993–2023	Nível da água (water level)
169	Nível da água; Precipitação; Correlação entre estações; Dados telemétricos	Telemeter Project Pattani Basin; Institute of Irrigation Development (Thailand)	Horária; 2015–2017	Nível da água (water level)
170	nível máximo; nível médio; nível mínimo diários; atrasos (delays); estação (posição no rio); estação do ano (trimestres); fenômeno El Niño/La Niña	IDEAM (Instituto de Hidrología, Meteorología y Estudios Ambientales)	Diária; 1997–2015	nível da água do rio (previsão de nível)
171	Precipitação média de bacia (passada e futura); histórico de vazão local; histórico e previsões de vazões a montante	Stage IV (chuva calibrada por pluviômetros) 2002–2018 (abril–novembro) via RainyDay; séries sintéticas de vazão pelo HLM	Horária; 20 dias; 5000 eventos	Vazão (runoff) horária

ID	Parâmetros de Entrada	Fonte de Dados	Resolução / Período	Indicador de Inund.
172	Precipitação; Temperatura; Vento; Vazão; Nível d'água	ERA (ECMWF); AMMA-CATCH; USGS; Direção Geral da Água do Benin	Horária	Vazão; Nível d'água
173	Nível d'água diário (8h); histórico de 30 anos	Sistema de telemetria IoT; Changjiang Nanjing Waterway Bureau	Diária; 30 anos	Nível d'água
174	Precipitação; Temperatura; Vazão	WAPDA; SWHP (Surface-Water Hydrology Project); PMD (Pakistan Meteorological Department)	Mensal; 1960–2012	Vazão (streamflow)

APÊNDICE F - DADOS DO BLOCO DE RESULTADOS

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
1	CNN-RNN-Neural ODE obteve $R^2=0.98$, RMSE mais baixo, e menor viés; superou CNN-RNN e Neural ODE isolados	Generalização limitada por validação em único evento recente; necessidade de validação multi-anual	Aplicar em diferentes climas; integrar sensores em tempo real; testar com séries históricas maiores
2	Abordagem distribuída melhora previsões t+1 e t+2; MLP obtém melhor precisão geral; modelos distribuídos superam locais em R^2 e RMSE	não implementação real em nós REDE; desempenho varia por kernel; GP subestima picos de vazão; dependência de conectividade	Implementar abordagem distribuída real; explorar previsões entre sensores; integrar ao sistema REDE; avaliar sensibilidade de atraso temporal
3	SOM-R-NARX obteve $R^2 > 0.9$ até 12 h; Fuzzy IBF forneceu mapas de risco integrando perigo, exposição e vulnerabilidade; plataforma web exibiu previsão até 36 h	Subjetividade nas funções fuzzy; qualidade e disponibilidade de dados; incapacidade de capturar dinâmica temporal completa	Incorporar dados de vulnerabilidade e exposição em tempo real; aprimorar previsões de longo prazo; melhorar comunicação com usuários
4	Random Forest atingiu $F1=98\%$, superando trabalhos anteriores; modelo equilibrado e independente da localização	Desequilíbrio de classes; ausência de dados espaciais detalhados	Utilizar mais dados geográficos; aplicar em outras regiões; ampliar variáveis de entrada
5	DNN superou modelos LSTM-TL e GRU-TL em NSE (ganho de 0.05–0.16) e KGE (ganho de 0.09–0.33); 4% menos bacias com $NSE < 0$ que LSTM-TL; 31% menos que GRU-TL	-	Explorar ensembles; incorporar dados de sensoriamento remoto e imagens de satélite; testar em outras regiões
6	Sistema atingiu NSE até 0.91 e acurácia de volume de 99.97%; melhora na previsão de fluxo e operação otimizada para evitar cheias e maximizar energia	Escalabilidade limitada por disponibilidade de dados e capacidade computacional; necessidade de calibração complexa	Emprego de deep learning e paralelização (GPU); ampliação para outras bacias
7	SBEL melhora MRE do MLP em até 59.9% (dados totais); reduz RMSE de picos em 15.6% e MRE em 21%; com 10% de dados de treino melhora MRE em até 74.5%; em dias chuvosos reduz MRE em 14.4%	-	-
8	SVM obteve melhor desempenho geral ($R^2=0.86$ em Fars); modelo prevê risco de inundação com base em precipitação; integração de ML com DSS e MCDM	Limitação de dados hidrológicos válidos; falta de validação externa; ausência de intensidade de inundação	Usar metaheurísticas e integração com sensoriamento remoto e imagens de satélite; aplicar em outras regiões e climas
9	ATE produziu maiores acurácia e estabilidade ($NSE=0.845$; $RMSE=331.9$ m ³ /s; $MAE=147.6$ m ³ /s; $r=0.920$) e melhorias percentuais frente a XGB; testes de Friedman e Nemenyi indicam superioridade do ATE	Tendência geral de subestimar escoamentos elevados; desempenho do ensemble pode ser afetado por modelos base com desempenho inferior	Explorar métodos de ensemble mais avançados; aprimorar pré-processamento e avaliação; ampliar conjunto/dobras para testes de significância
10	Attention-LSTM obteve $NSE=0.961$; $R^2=0.966$; $RMSE=50.885$; melhora de 12.8% (NSE) e 26.2% (R^2) sobre BPNN; desempenho estável até 12h	-	Considerar grandes bacias; explorar outros tipos de fluxo (urbano; com sedimentos); aprimorar correlação espaço-temporal
11	Erro médio ≤ 55.68 cm; erro ≤ 2.10 %; modelo supera métodos existentes (8.36 %); previsão eficiente para 5 dias à frente	aumento abrupto de nível em 1 dia; dados de relevo ainda ausentes	Incluir dados de relevo; aplicar método a outras regiões e ANNs de terceira geração; melhorar eficiência de treinamento

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
12	FNN obteve $R^2=0.96$, $MAE=0.108$ e $RMSE=0.179$ no ambiente FL; upstream rainfall em Cherrapunji e Surma-Kushiyara são variáveis mais influentes; melhora na precisão e privacidade de dados	Ausência de parâmetros meteorológicos diários como cobertura de nuvens e umidade do solo; necessidade de maior interpretabilidade dos modelos; limitação na previsão de longo prazo	Expandir datasets; integrar dados em tempo real; combinar deep learning com modelos físicos; aprimorar interpretabilidade e previsões de longo prazo
13	SE-Cloud capturou picos e caracterizou incertezas; hipervolume +13,14%–39,65% vs Cloud; MRO reduziu o nível máximo esperado em 0,05 m e elevou descarga pico esperada em 4,29%	Subestimação sistemática dos picos pelos modelos; difícil garantir retorno ao nível-alvo final devido a limitações estruturais do reservatório; melhor desempenho em grandes cheias que em pequenas	Aprimorar adaptabilidade/robustez dos modelos individuais; investigar seleção de objetivos para diferentes magnitudes de cheias; melhorar captação de picos; ampliar variáveis de entrada
14	Modelo híbrido RF-SARIMA atingiu $R^2=0.88$ e coeficiente de correlação >0.9 ; reduziu RMSE e MAE em relação aos modelos isolados; desempenho 73% superior em precisão	Não aborda variáveis climáticas e mudanças de uso do solo; alta complexidade computacional	Incluir variáveis de temperatura; precipitação; neve e ampliar para previsões diárias ou horárias
15	Modelo GSGMDH atingiu $R>0.9$; $MAE\approx 4$; previsão até 18h à frente; supera modelos convencionais em estabilidade e simplicidade	Dados ausentes (~40 mil amostras); limitação de apenas um posto fluviométrico a montante; dependência de qualidade dos dados	Explorar algoritmos evolutivos (GA; PSO); incorporar múltiplas estações a montante; ampliar série temporal
16	GRU e Bi-GRU apresentaram melhor desempenho com $RMSE<1.45$ e erro de volume $<3\%$; LSTM teve instabilidade e erros $>9\%$	Dependência de dados sintéticos; aplicabilidade local; ausência de dados reais limita generalização	Integração de dados reais; expansão para outras bacias; aplicação operacional em sistemas de alerta precoce
17	O modelo híbrido EEMD-VMD-RFR atingiu $NSE=0.97$ e reduziu RMSE em até 50% frente ao RFR puro; maior confiabilidade ($>95\%$) e resiliência ($>85\%$) nas três bacias	Necessidade de generalizar o método para outras bacias; desempenho inferior em eventos de pequena vazão; ausência de previsão probabilística	Explorar modelos híbridos adicionais; investigar seleção de objetivos para cheias de diferentes magnitudes; incluir variáveis climáticas e integração com previsão meteorológica
18	M-DWT-ANN elevou $NSE\approx 0.99$ e reduziu RMSE de 14.10 (ANN t+7 diário) para 0.2615; para t+1 diário $RMSE=0.00038$ e para t+1 mensal $RMSE=0.15207$	Aumento do tempo de computação; sensível à escolha de arquitetura/entradas; desempenho decresce com maior horizonte; resultados diários superiores aos mensais	Aplicar M-DWT-AI em outros fenômenos/bacias e diferentes regiões climáticas
19	DNN obteve $CC=0.92$; $NRMSE=9.48\%$; XGBoost atingiu $F1\text{-Score}=0.92$ e maior precisão geral em todas as classes de risco	Dependência de dados locais e curto período de validação; limitação de generalização geográfica	Futuras pesquisas incluirão variáveis adicionais (precipitação, vazão, umidade do solo) para melhorar a precisão
20	MLP-NN apresentou $RMSE=0.01299$; $ANFIS=0.0130$; ambos com $R^2\approx 0.999$; d-factor=0.00036; previsões eficazes até 12h de antecedência	Aplicabilidade restrita a uma única estação; ausência de validação em outras bacias	Validar em outros rios da Malásia e regiões com diferentes condições climáticas
21	SVM-WOA atingiu $NSE=0.9863$; reduziu RMSE em ~45% comparado ao SVM; maior precisão e generalização	Aplicabilidade restrita à bacia de Barak; ausência de testes com dados de outras regiões	Explorar outros sistemas inteligentes integrados para previsão de Qflow no futuro
22	ELM apresentou NSE e R mais altos ($R\approx 0.995$; $RMSE$ mínimo ≈ 0.031); uso de dados $Q(t-1)$; $Q(t-2)$; $Q(t-3)$ melhora desempenho; GPR e ENN também eficazes	Alta complexidade dos modelos tradicionais; número elevado de funções de pertinência no ANFIS; dificuldades de interpretação de parâmetros	Aplicar ELM, ENN e GPR em outros contextos; explorar otimização de hiperparâmetros e modelos híbridos
23	iTransformer reduziu RMSE para 0.0661 e MAE para 0.0527; superou LSTM, XGBoost e ARIMA em 4 métricas	Alta demanda computacional devido ao mecanismo de atenção e arquitetura multi-head	Explorar otimizações para reduzir custo computacional e expandir a aplicação a outras bacias

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
24	PM apresentou menor erro horizontal (HE) e vertical (VE) comparado aos outros modelos; $R^2 > 0.9$; resultados mais realistas	Risco de imitação de variáveis de entrada; necessidade de modelos não-lineares mais robustos	Aplicar o índice HE em paralelo com VE; testar métodos não lineares e upstream pixels adicionais
25	RF e GB alcançaram $NSE \approx 0.8$; $PI = 0.73$; $CSI \approx 0.9$; previsão 24h antecipada apenas com dados de nível; sem chuva; erro médio $\sim 5\%$	Ausência de precipitação causa atraso na subida dos níveis; dependência de dados locais; risco de generalização limitada	Incluir chuva, umidade e parâmetros de solo; aplicar em outras bacias; ajustar hiperparâmetros
26	RF alcançou 0.99 de acurácia; SVR teve $MAE = 0.06$ e $R^2 = 0.85$, superando MLP; resultados robustos para previsão de cheias e descarga	Dados escaneados de registros manuais; valores faltantes; variação climática e ruído de sensores	Incluir mais atributos ambientais; testar modelos híbridos e ensembles; aplicar em outras bacias
27	RF supera levemente para 1 h; LSTM com IPIP supera para 12 h e 24 h; resultados coerentes com série efêmera; melhora com dado categórico de picos	Desequilíbrio de classes (picos raros); série curta (~ 3 anos) e sensível a extremos; queda de desempenho em horizontes longos; generalização limitada a outros locais	Incluir variáveis ambientais (chuva satelital; umidade do solo; índices de vegetação); testar horizontes intermediários (3 h; 6 h); integrar dados em tempo real; expandir para outras lagoas
28	LSTM mostrou os melhores resultados para previsão da vazão em áreas úmidas; Acurácia baixa em região seca/árida; Modelos de IA mais eficientes no quesito tempo em comparação com modelos físicos	Necessário melhora na qualidade dos dados de entrada	-
29	FFBP-M5 alcançou $R = 0.887$; $NSE = 0.786$; $RMSE = 92.6 \text{ m}^3/\text{s}$; $MAE = 27.6 \text{ m}^3/\text{s}$ no teste; modelos baseados em árvores (RF/XGBoost) também apresentaram alta correlação ($R \approx 0.88$)	Série longa mas restrita a uma estação; dificuldades em captar picos de vazão; sensibilidade à inclusão de temperatura; ausência de validação externa	Aplicar híbridos (DWT-AI; LSTM; ensembles); ampliar variáveis climáticas e escala espacial
30	Wavelet-ANFIS com mãe db7 apresentou $RMSE = 3.61$; $NSE = 0.82$; $R = 0.91$; superou os modelos Wavelet-ANN, ANFIS e ANN	Dificuldade na escolha da wavelet ideal; dependência de decomposição adequada; dados limitados a uma década	Combinar Wavelet-ANFIS com técnicas metaheurísticas; testar outras famílias de wavelets e ampliação espacial
31	Precisão alta para $T = 1-3$ h; SVR atinge $NSE = 0.9965$ e $RMSE = 6.72 \text{ m}^3/\text{s}$ ($T = 1$ h); desempenho decai com o aumento do lead time; picos levemente subestimados em horizontes longos	dependência alta na qualidade dos dados; generalização limitada; performance baixa em eventos extremos ou mudanças climáticas rápidas	Aplicar o modelo em outras regiões; compreender as características hidrológicas da bacia; ajustar e otimizar o modelo para as características da bacia
32	LSTM superou ARIMA em ambas as bacias; desempenho 44.57% melhor em RMSE no Kemaman e 21.05% em MAE no Dungun; melhor captura de não linearidades	ARIMA limitado para relações lineares; dificuldade em capturar comportamentos não lineares	Expandir para outras bacias; integrar com sistemas de alerta de cheias e gestão de recursos hídricos
33	VMD-MLPNN apresentou melhor desempenho ($R = 0.990$; $NSE = 0.967$); híbridos superaram modelos conceituais e ML isolados	Subestimação de fluxos altos por modelos conceituais; ocorrência de valores negativos nas predições devido à extrapolação de dados limitados	Explorar novos híbridos; aplicar modelos em outras bacias; melhorar simulações em múltiplas escalas
34	Lasso obteve F1 Score médio de 0.78 a 0.92 nas predições de 1-6 h; Decision Tree teve recall comparável em curtos prazos; SVM foi o pior modelo	Dados altamente correlacionados e ruidosos; ausência de características hidrológicas completas em alguns postos; dependência de dados de radar e simulações	Explorar ensembles; ampliar o número de estações; incluir dados físicos e modelos híbridos; investigar regularização adaptativa
35	ANN teve menor erro relativo (33-54%) comparado a SVM (37-64%) e ARR (57-64%); melhor desempenho para Q5 e Q10	Erros maiores para períodos de retorno altos; viés de superestimação em Q100; necessidade de mais variáveis e registros longos	Uso de validação Monte Carlo; combinação híbrida de modelos IA; correção de viés climático

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
36	Ensemble aumentou precisão de 18–26% na calibração e 4.1–9.2% na validação; SWAT+ melhorou 44–74% e 40–55%; FFNN teve maior influência no ensemble segundo SHAP	Dependência de grandes volumes de dados; subestimação de vazões baixas pelo SWAT+; ausência de validação externa	Usar dados de diferentes bacias; empregar técnicas híbridas com menos dados; aumentar interpretabilidade das IAs
37	LSTM e GRU alcançaram NSE=0.988 (1 dia) e 0.93 (2 dias); GRU foi ligeiramente superior no teste; modelos simples com 1 camada foram tão eficazes quanto arquiteturas mais complexas	Aumento da complexidade (StackedLSTM, BiLSTM) não melhora o desempenho; necessidade de mais dados em múltiplas escalas e validação em outros rios	Combinação de DL com modelos hidrológicos para previsão de longo prazo; uso de híbridos DL-hidrológicos
38	LLR apresentou melhor desempenho ($R^2=0.908$ treino; 0.831 teste) e baixo RMSE, superando as redes neurais; adequada para previsão local de cheias	Conjunto de dados limitado a uma única bacia; ausência de validação em outras regiões; dependência de dados históricos	Incluir dados com resolução temporal mais fina; testar outros modelos de IA e aplicações em tempo real
39	ANN apresentou melhor precisão ($CC=0.92$; $MAPE \approx 12\%$; $CE > 0.8$), superando HEC-RAS; previsão mais próxima dos dados reais	Subestimação de picos de vazão pelo modelo físico; ausência de aplicação em múltiplas bacias; dispersão maior no modelo ANN	Aplicação de ANN em outras bacias; integração com sensores; uso de modelos híbridos
40	BRR obteve $R^2=1.00$ e menor erro ($MSE=2.46e-25$); variáveis Monsoon Intensity e Drainage Systems foram mais influentes segundo SHAP/LIME	Ausência de múltiplas bacias ou validação externa; uso de base genérica sem dados reais de sensores	Aplicar modelos híbridos; incluir dados espaciais e climáticos reais; ampliar escopo geográfico
41	LSTM alcançou 98% de acurácia para 1h e 93.55% para 12h; modelo generalizou bem para outra estação; útil para detectar falhas em sensores	Perda de precisão em predições de 8h e 12h; ausência de múltiplas bacias; dependência de calibração local	Adicionar mais parâmetros hidrológicos e meteorológicos; ampliar escopo e integração de dados
42	Modelos acoplados melhoraram a acurácia diária frente a SWAT+ e LSTM isolados; SHAP indicou maior influência de fluxo lateral ($\approx 34\text{--}40\%$) e percolação ($\approx 23\text{--}36\%$) nas predições	Não considerar mudanças de uso do solo e atividades humanas por dados limitados; subestimação de picos por modelos físicos em eventos intensos (limitação reconhecida)	Aprimorar a acurácia do modelo físico e integrá-lo a um AI otimizado; ampliar variáveis/monitoramento para captar mudanças antrópicas
43	Precisão de 90% para pico e 100% para tempo de chegada; redução de erro em relação a modelos anteriores; capacidade de prever inundações curtas e longas	Influência de fatores humanos (reservatórios); erros de previsão de chuva; lacunas e ruídos nos dados	Melhorar extração e processamento de dados; combinar IA e comunicação para monitoramento em tempo real e seleção adaptativa de modelos
44	Modelos híbridos SVM-PSO melhoraram desempenho (R^2 até 0.9837 e RMSE reduzido); inclusão de variáveis meteorológicas aumentou precisão em previsões de 1–7 dias	Dependência de calibração local; ausência de validação externa; sensibilidade à qualidade dos dados de chuva	Expandir para outras bacias e incluir integração de dados em tempo real
45	CNN obteve desempenho superior em todas as estações ($NNSE \geq 0.85$; $KGE \geq 0.84$); uso de AIC/BIC melhorou ligeiramente a seleção de entradas	Sem validação externa; variação entre fases de treino/teste; sensibilidade ao número de defasagens e características do terreno	Desenvolver sistemas de previsão online em tempo real; investigar modelos híbridos deep learning
46	SVM-AF alcançou R^2 até 0.985 e NSE até 0.995; erro RMSE mínimo 0.008 m ³ /s; superou modelos Wavelet-SVM e Bayesian-SVM em precisão e estabilidade	Necessidade de validação externa; dependência de qualidade dos dados e calibração; limitação de generalização a outras bacias	Explorar outras regiões e aprimorar integração de dados em tempo real
47	LSTM obteve $R=0.947$ e NSE=0.8963 para previsão 30 min à frente; inclusão da taxa de variação (RoC) reduziu erros e permitiu detecção precoce de mudanças de fluxo	Dados limitados e possíveis distorções de telemetria; sem inclusão de uso do solo; queda de desempenho para previsão de 1 h	Explorar modelos híbridos e métodos evolutivos; adicionar variáveis físicas e de evaporação; expandir uso de RoC em ML

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
48	NSE melhorou em todas as estações e superou o HBV; P2 aumentou a resolução (ex.: 2.19→3.43); TFT com GFS superou persistência	Alta dependência da disponibilidade/qualidade dos dados; complexidade na definição de hiperparâmetros; requisitos computacionais; fatores ambientais/temporais não contemplados (p.ex., mudanças de uso do solo); risco de overfitting em conjuntos menores; imprecisões de precipitação do GFS em eventos intensos	Mitigar overfitting (novas regularizações; explorar hiperparâmetros); ponderar maior peso a bacias sub-representadas; especificar distribuição espacial de variáveis dentro da bacia; estender para outras variáveis (transporte de sedimentos; nível; agendamento hidrelétrico)
49	MLP alcançou menor RMSE (104.53–227.02 m³/s) e maior precisão para 1–3 dias; boa capacidade preditiva de curto prazo	Dificuldade em prever picos de vazão e eventos extremos; sensibilidade a hiperparâmetros e dados ausentes	Uso de técnicas de reamostragem e inclusão de precipitação em tempo real; considerar GRU, Transformer e otimização bayesiana
50	TL-Transformer alcançou NSE>0.75; reduziu RMSE e bias em >25%; superou LSTM e modelos físicos em todas as bacias	Necessidade de validação externa; incerteza dos hiperparâmetros; dados confidenciais; transferência sensível à similaridade topográfica	Quantificar incertezas; expandir validação para outras regiões; integrar previsão probabilística e atributos topográficos
51	CNN-ResNet para downscaling melhora RMSE médio em ~34% vs. EC e ~26% vs. QM; para eventos pesados, melhora ~6%–10% no RMSE; XAJ-LSTM impulsionado por EC-CNN reduz RE de 16%–33% e RMSE de 20%–31% nos picos em relação a EC	QM não melhora RMSE em vários prazos; necessidade de tratar adequadamente eventos extremos; desempenho do XAJ autônomo melhora pouco com precipitação aprimorada; dependência dos reforecasts ECMWF	Integrar variantes mais recentes de CNN (p.ex., arquiteturas U-shaped) com novas funções de perda; combinar técnicas de IA meteorológica avançada com o encadeamento hidrológico
52	Ensemble MLP alcançou RMSE médio de 18.4 m³/s e NSE até 0.8; desempenho superior ao modelo de persistência; previsões úteis até 3 dias	Subestimação de picos de vazão; poucos eventos extremos na validação operacional; amostra limitada	Expandir testes operacionais; aplicar modelo a outras bacias; avaliar previsões probabilísticas
53	A inclusão de mais parâmetros reduziu o erro de previsão de 98% para 17%; o modelo torna-se adequado com dados expandidos	Considera apenas dados hidrológicos passados; falta de variáveis meteorológicas e morfométricas	Ampliar conjunto de dados com variáveis meteorológicas e morfométricas; melhorar arquitetura da rede
54	Desempenho alto com R e R² entre ~0.90–1.0 nas estações; o modelo segue a tendência de subida/descida do nível e é adequado como suporte à decisão de alerta	Lacunas de dados por falhas de data logger em áreas remotas; sub/superestimação pontual em picos; série de teste curta e por eventos	Melhorar o processo de treinamento e validar o modelo em conjuntos de dados diferentes; ampliar testes em mais estações/eventos
55	GA-XGBoost e DE-XGBoost superaram RF e CART; erros relativos 2.18%–9.21%; DE-XGBoost ligeiramente melhor em previsão contínua; GA-XGBoost melhor em passos isolados	Predição subestimada em horizontes longos (5–6h); NSE baixo (~0.65); dependência da variabilidade da chuva	Incluir novas variáveis de bacia; combinar previsões mensais/diárias; comparar com outros métodos de ML
56	R² até 0.991; RMSE mínimo de 0.26; GEP superou métodos Muskingum e soluções aproximadas anteriores	Aplicação limitada a três estudos de caso e dados não georreferenciados; ausência de validação em bacias reais	Aplicar GEP a outras bacias e condições hidrológicas; ampliar número de variáveis e estudos comparativos
57	OS-ELM atingiu NSE=0.97 e R²=0.97 no treino e NSE=0.94, R²=0.96 no teste até 5h; erros de pico <5% em 8/23 eventos	Dificuldade de prever longas variações devido a atualização contínua; ausência de memória de longo prazo	Incluir flexibilidade no número de neurônios e testar previsão de longo prazo
58	FEWS com LSTM + ATT prevê níveis d'água 36 h antes com RMSE < 0.25 m; desempenho melhor para descargas ≤ 5000 m³/s; atenção aumenta previsão de pico e estabilidade do modelo	Limitação de dados extremos > 8000 m³/s; erro sistemático por calibração em condições médias; depende da atualização ERA5 (18 h)	Ampliar dados de eventos extremos; calibrar cenários de cheia; testar dados GFS/WRF; mapear zonas vulneráveis para resposta rápida

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
59	ANFIS-GOA reduziu RMSE em até 62% em relação ao ANFIS; WI=0.991–0.993; previsão de picos próximos aos observados (5,442 vs 5,568 m³/s)	Tempo de treinamento elevado; dependência da qualidade e quantidade dos dados; área de estudo restrita a duas estações	Aplicação de novos algoritmos de busca e modelos probabilísticos; expansão para outras regiões; redução de complexidade de regras
60	ANN (2,7,1) alcançou $R^2=0.868$ e RMSE=0.18; ARIMA apresentou $R^2=0.615$ e erro de 43.1%; ANN reconheceu padrões não lineares com maior precisão	ARIMA teve limitação para prever sazonalidade; dependência de dados históricos e sensibilidade a pequenas variações	Integração híbrida ANN-ARIMA; ampliação espacial e temporal; uso em outras regiões
61	Modelos com atenção (ALSTM; AGRU) melhoraram sistematicamente RMSE/MAE/MAPE em múltiplas bacias; atenção reduziu erros p.ex. Quinebaug: train RMSE -2.33%; test RMSE -0.97%; train/test MAE e MAPE -10.36%/-6.96%	Devido a limitações de espaço apenas melhores redes reportadas; estudo utilizou apenas streamflow como entrada	Explorar integração de dados multiorigem (satélite; umidade do solo; previsões meteorológicas) e uso em tempo real com atualização contínua
62	NNC apresentou melhor acurácia para previsão de inundação; modelo híbrido GIS-WMS-AI com R^2 até 0.89; framework integrado reduz incertezas e melhora resposta em regiões áridas	Incertezas nos modelos WMS e IA; dados limitados à região de Khosf; simplificações metodológicas; falta de generalização	Ampliar aplicação para outras regiões áridas; testar modelos híbridos e metaheurísticos; integrar sensoriamento remoto
63	RF apresentou métricas perfeitas (CC=1.0; NSE=1.0; RMSE=0.0); DT obteve CC=0.981; NSE=0.950; RMSE=0.109; Diffusion teve NSE=-16.959 e RMSE=24.3853 (pior)	Período curto (setembro 2019); percentuais de validação não informados; ausência de métricas numéricas para ANN; possíveis indícios de sobreajuste (RF com métricas perfeitas)	Integrar variáveis adicionais; refinar o cálculo de danos; ajustar parâmetros da curva de crescimento; integrar analytics em tempo real
64	CNN-LSTM-Attention alcançou 98.63% de acurácia e 99% de precisão, recall e F1-score para nível de perigo; 97.26% de acurácia para previsão de inundação; SHAPASH mostrou que o nível da água é o fator mais influente, seguido de vazão e precipitação	Ausência de variáveis geográficas (DEM, uso do solo); necessidade de reentrenamento frente a mudanças climáticas; limitações computacionais para uso em tempo real; não inclui mapas GIS	Expandir para rios de maré; incluir dados geoespaciais e de sensores em tempo real; uso em sistemas operacionais de alerta
65	Attention-based LSTM superou LSTM e Transformer, com melhoria de até 30.19% sobre método Naïve; correlação forte entre noites de hóspedes e temperatura ($r=0.54$)	Dados restritos por autorização governamental; ausência de código aberto; limitação de generalização para outras regiões	Uso futuro de IA explicável e dados de redes sociais; ampliação para previsão de turismo e aplicação em outros lagos
66	Meteo-hydro-AI aumentou NSE em até 0.09 e reduziu RMSE até 11%; ECMWF/CSSPv2 reduziu RMSE em 22–49% e aumentou NSE até 0.82 vs ESP; LSTM corrigiu atrasos de pico	Poucas amostras de cheias extremas; ausência de operação de reservatórios; resolução espacial limitada; leve sobreajuste em LSTM-ALL	Incluir mais dados de cheias; expandir para sub-bacias; empregar downscaling dinâmico e dados de assimilação; aplicar AI em módulos hidrodinâmicos
67	Modelo de ensemble reduziu o erro de volume em até 17.88% e o erro de pico em 2.93%; NSE melhorou até 0.33 sobre o melhor modelo individual	Necessidade de avaliar generalização em outras bacias; limitação de dados históricos e sensibilidade a parâmetros	Aplicação do método em outras bacias; integração com modelos físicos; análise de diferentes processos de chuva
68	Modelos por cluster melhoraram as métricas (KG; NS; MARE) dentro de cada grupo; modelo por clusters e modelo da série completa mostraram eficácia semelhante para 1 dia	Limitações de tamanho na fase de ajuste restringiram comparações; sobrestimação de baixos fluxos em alguns modelos (razão de volume > 1,0); análise restrita a horizonte de 1 dia	Desenvolver e avaliar modelos de previsão baseados na metodologia proposta (trabalho futuro mencionado)

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
69	CNN teve melhor desempenho para cheias; WANFIS melhor para secas; clima pouco afeta desempenho dos modelos	Limitações: dados limitados no Sekong; previsão restrita a 1 dia (cheias) e 1 mês (secas); ausência de dados horários; modelos não adequados a chuva e vazão simultâneas	Uso de índices SPEI e PDI; inclusão de dados horários e de neve; combinar funções wavelet para eventos de variável única e redes profundas para múltiplas variáveis
70	AIG-SVR atingiu NSE até 0.991 e RMSE = 0.004 m³/s, com melhor desempenho em todas as estações; superou modelos convencionais e híbridos anteriores	Limitação de dados a uma única bacia; dependência de dados históricos; necessidade de validação externa	Aplicar AIG-SVR a outras bacias; incorporar variáveis secundárias e novos otimizadores
71	D1: GMDH obteve RMSE=1.50 CMS e WI=0.96; D2: MLP obteve RMSE=5.29 CMS; ambos superaram ARMA/ARIMA (RMSE D1 ~1.77–1.62 CMS)	-	Sugerem acoplar algoritmos de otimização (Genetic Algorithm; Particle Swarm Optimization; Firefly Algorithm; Gray Wolf Optimization) aos modelos de IA
72	Esquema WRF MYJLG apresentou as previsões de chuva/temperatura mais precisas; SVM obteve melhor desempenho para o hidrograma de cheia (NSE=0.548; RMSE=21.9 cms; PTVE=15.59%; MAPE=14.33)	Desempenho do WRF e do ANN no hidrograma apresentou NS negativo e maiores erros; diferenças no pico de vazão	-
73	BCM apresentou LogLoss=0.84; NSE não informado; erro de 22.7%; mostrou dependência maior da intensidade da chuva do que da umidade antecedente	Dados limitados e curtos períodos contínuos; ausência de medições diretas de umidade do solo; necessidade de séries mais longas	Uso de dados de satélite para umidade do solo; extrapolação para bacias não monitoradas; previsão sob cenários climáticos futuros
74	ANFIS apresentou NSE=0.95 e R²=0.96; erro de pico relativo (RPE)=0.03; desempenho superior ao ARX em todas as estatísticas; tempo de treinamento menor	Limitação quanto à disponibilidade de dados e necessidade de calibração para diferentes eventos	Investigar ANFIS em diferentes condições e cenários de bacias para aprimorar generalização
75	R-ANFIS(GL) melhorou NSE em 24.9% e reduziu RMSE em 25.3% em relação ao ANFIS(SL); mitigou defasagem temporal e aumentou precisão de previsões até 2 dias à frente	Necessidade de fusão de previsões externas (chuva) para eliminar totalmente efeitos de defasagem	Integração de variáveis meteorológicas previstas e uso de ensembles híbridos
76	MLR-GWO-ELM atingiu NSE = 0.937 (Meki) e 0.971 (Abura); reduziu RMSE em até 57% vs MLR; melhor generalização (GA≈1.09)	Necessidade de mais variáveis hidroclimáticas; falhas em captar picos de cheia; dependência de dados limitados (duas estações)	Explorar deep learning (CNN; LSTM); acoplar algoritmos de otimização; ampliar escala espacial e temporal
77	ANFIS-PSOSMA obteve NSE=0.9818 e RMSE=2.2532 no melhor cenário; desempenho mais próximo do observado em todas as estações	Dependência de um conjunto de dados limitado a uma única bacia e ausência de comparação com modelos físicos	Explorar generalização para múltiplas bacias e integração com previsões meteorológicas futuras
78	Modelo ANN com A e Itc_ARI obteve melhor desempenho geral (CE=0.65; r=1.03; RE=43.27%); nas medianas de 90 bacias de teste, ANN superou GEP e QRT para Q2; Q10; Q20; Q50, enquanto GEP foi melhor em Q5 e Q100	-	Incluir variáveis preditoras adicionais e registros de vazão mais longos; investigar relações hidrológicas e características físicas
79	VMD-FOS-QR-RBL prevê melhor inundações devido à melhoria que o VMD faz na acurácia e robustez dos modelos de previsão	-	Melhorar a eficiência computacional do uso do VMD e otimização
80	SVR foi mais consistente em R² e melhor em previsões de 4h e 12h; adequado para previsão de longo prazo	Curto período de dados (1 mês) e limitação espacial a uma bacia	Explorar integração em sistemas híbridos CMIS e ampliar correlação temporal

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
81	Erro médio 8.33% em vazão de pico; 14.27% em volume; erro de tempo 1 h; previsão eficaz com 1/3 da duração do evento	Limitado por dados de uma única bacia e pequeno conjunto histórico; não considera influência humana ou outros tipos de terreno	Ampliar banco de dados; incluir mais bacias e variáveis (topografia, vegetação, morfologia, engenharia)
82	Melhor correlação observada com múltiplas variáveis de entrada; ANN previu níveis de inundação com $R \approx 0.99$	Implementação prática do WSN ainda não realizada; necessidade de validação em campo	Integrar dados em tempo real do WSN e expandir teste de arquitetura de rede e thresholds de severidade
83	GBR+ obteve NSE=0.989 e $R^2=0.354$, superando modelo SPC; dados escassos exigem calibração cuidadosa	Dados escassos e heterogêneos; ausência de chuva direta nos modelos; sensibilidade a outliers	Incluir chuva e janelas temporais; melhorar robustez e estabilidade de aprendizado
84	RBFNN obteve MAPE de 0.047% (nível d'água, treino) e 1.05% (teste); para chuva: 4.97% (treino) e 29.1% (teste)	-	-
85	Nonlinear partial least squares regression teve melhor desempenho com alta pluviosidade; Random Forest foi superior em eventos complexos com baixa pluviosidade	Deve ser considerado as variações características dos locais onde o modelo for aplicado	Aplicar outros modelos de machine learning com melhores performances preditivas
86	ST-DTW e Multi-feature alcançaram melhor precisão de tempo de pico que LSTM; desempenho comparável em RMSE; vantagem em bacias com poucos dados	Escassez de dados hidrológicos; degradação de desempenho com pequeno conjunto de amostras; complexidade em bacias áridas	Integração de dados de radar e estações terrestres; expansão para grandes bacias; previsão de drenagem urbana e rios arenosos
87	WANN alcançou R^2 de até 0.9992 e RMSE de 0.289; sistema integrado WANN+HEC-RAS+IoT gerou alertas em tempo real com precisão temporal de minutos e espacial de 0.2 m	Escassez de dados hidrológicos detalhados e limitação da modelagem física; restrição geográfica à bacia estudada	Aplicar sistema em outras regiões; comparar com métodos convencionais; incorporar novos sensores e dados em tempo real
88	Com 700 épocas e $lr=0.00007$, MSE=0.027 (nível d'água) e 0.002 (chuva); sistema prevê nível d'água e chuva diários para o próximo mês e envia ao app Android	-	-
89	ANN sigmoidal-sigmoidal apresentou melhor desempenho (CCC=0.877; CC=0.921; MAPE=11.95%) e superou ANN sigmoidal-lineal e ANFIS	modelo ANFIS apresenta limitações com muitas entradas; informação horária limitada em 2009; ferramentas do matlab são limitantes	integração com GIS; validar em outras regiões; incorporar mais variáveis hidrometeorológicas/socias/econômicas; implementar algoritmos genéticos e fuzzy logic; comparação com modelos tradicionais
90	CART-TVF-EMD-CFNN alcançou $R=0.9958$ e RMSE=0.1155 (t+1); $R=0.9837$ e RMSE=0.2290 (t+7); superou LSTM, MARS, GBDT	-	-
91	LSTM atingiu $R^2=0.91$ e RMSE=9870; ML-GMDH obteve $R^2=0.88$; integração NRCS-CN + IA elevou a precisão e aplicabilidade em bacias sem dados	Uso de apenas 13 anos de dados; ausência de validação externa; dependência de dados satelitais	Ampliar série temporal; testar GRU; usar dados horários; replicar em outras bacias
92	Diário com kernel linear e atraso de 1 dia obteve melhor desempenho ($R^2=0.95$; RMSE=53.29 m3/sec; MAE=33.26 m3/sec); Mensal melhor com kernel linear e 3 dias ($R^2=0.731$; RMSE=109.4 m3/sec); Sazonal melhor com kernel quadrático e 1 dia ($R^2=0.415$; RMSE=152.3 m3/sec)	Necessidade de ajuste de parâmetros; custo computacional de treinamento; desempenho inferior em escalas mensal/sazonal	Recomenda modelo híbrido; incluir variáveis adicionais (chuva; temperatura; evaporação); expandir uso de IA em recursos hídricos

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
93	seq2seq LSTM apresentou RMSE médio 0.0226–0.0319 m (8 h) contra 0.0268–0.0373 m (LSTM); NSE e correlação mais altos; tempo de inferência 0.09–0.35 s por evento	Assume conhecimento perfeito de chuva e maré futuras; não considera incerteza de previsão externa; ausência de medições em tempo real	Explorar incerteza de previsão de chuva e maré; incorporar sensores de nível; expandir para múltiplas cidades
94	RBF obteve Corr=1.00 e RMSE muito baixo; previsão precisa da profundidade da água; desempenho superior aos demais modelos	Dependência da qualidade dos dados e do número de neurônios RBF; risco de sobreajuste; necessidade de mais variáveis ambientais	Incluir variáveis geográficas (uso do solo, declividade) e ambientais (chuva, umidade do solo); estudar previsões de curto, médio e longo prazo
95	SVR com RBF kernel alcançou MAE=0.486 m e RMSE=0.646 m, superando os requisitos da MRC (0.5–0.75 m); RF obteve CE=0.936	Dependência de dados limitados a duas estações; ausência de variáveis meteorológicas; não há validação externa	Aplicar o modelo para previsão de 1–4 dias; ampliar número de estações e variáveis
96	AUC=92%; +6% absoluto sobre baselines estáticos	Dados faltantes ou comprometidos por cobertura de nuvens ou ruído nos sensores	Incorporar no modelo proposto outros algoritmos de IA; integrar outras múltiplas fontes de dados
97	IA estende a confiabilidade de nowcasts (0 dia) para 5 dias; IA tem precisão/recall superiores e F1 melhor/igual em maioria dos continentes; precisão/recall de 5 anos da IA $\approx$ métricas de 1 ano do GloFAS	Comparação favorece GloFAS (calibrado e avaliado em parte em períodos de calibração); difícil prever sistematicamente onde cada modelo é melhor a partir de atributos; disponibilidade limitada/heterogênea de dados; alguns postos sem eventos para certas métricas	Ampliar acesso a dados hidrológicos; focar treino/ajuste para bacias maiores; implementar roteamento/modelos de grafo explícitos; incorporar assimilação de dados em tempo quase real
98	Modelo proposto atingiu RMSE=1.8436 m ³ /s e MAE=1.2244 m ³ /s no conjunto de teste; reduziu RMSE para 1.84 m ³ /s (–97.31% vs M6; –97.22% vs M8)	Arquitetura complexa e custosa computacionalmente; necessidade de avaliar adaptabilidade sob regimes hidrológicos/climáticos altamente heterogêneos	Avaliar em cenários mais heterogêneos; considerar trade-off entre complexidade e eficiência computacional
99	LSTM-CNN-Attention obteve menor erro (MSE=2.59% do LSTM; MAE=11.18% do LSTM; AR ² ≈99.75%); alto desempenho em tempo real com previsão <0.4s	Dados escassos e irregulares em bacias pequenas; interpretabilidade limitada dos modelos DL; dependência de dados multimodais de alta qualidade	Incluir interpretabilidade (SHAP); explorar janelas maiores; testar modelos híbridos e predição em períodos mais longos
100	ENN apresentou NSE≈1 e R ² ≈0.99 com menor RMSE e MAE; desempenho superior ao MARS e RVM	Dependência de parâmetros de entrada locais; ausência de otimização de hiperparâmetros; sem validação externa	Explorar múltiplos horizontes de previsão; testar otimização por algoritmos bioinspirados; avaliar divisão alternativa de dados
101	Janelas de minutos (abordagem C) alcançaram R ² =0.92807 e R=0.963384 para 1–5 min; sistema de alertas obteve 80% (vermelho) e 66% (amarelo)	Dependência de muitos nós/sensores; conjunto de dados restrito a uma cidade e ~7 meses; ausência de validação externa	Avaliar número ótimo de nós; testar outros algoritmos de ML; aprimorar ajuste de hiperparâmetros; abordagem distribuída; combinar leituras de diferentes sensores
102	DEEMD-KNN-PSO alcançou RMSE=0.52235; MSE=0.2725; MAPE=0.08596; R ² =0.84596; outperforming single e EEMD-based models	-	Aplicar a outros conjuntos/locais; testar outros métodos de decomposição; integrar deep learning (LSTM; GRU); substituir PSO por GA
103	FNN apresentou melhor desempenho (ex.: R-squared teste=0.94; RMSE teste=0.161; MSE=0.022) que LSTM-RNN; SHAP indicou maior influência de chuva em Sylhet (0.243) e Cherrapunji (0.231) e Karimganj (0.170)	Discordância entre categorias discretas (0;1;2) e saídas contínuas do modelo; necessidade de pós-processamento; possíveis vieses de dados	Investigar pós-processamento avançado; explorar arquiteturas neurais mais profundas; incorporar fontes de dados adicionais para melhorar generalização
104	Probabilidade média de escoamento 26.15 m ³ /s; pico máximo 92.11 m ³ /s; BCM obteve forte correlação causal chuva–escoamento e valores alinhados à distribuição Johnson SB	Dependência de calibração contínua; estudo restrito a um evento e uma bacia; não testado em diferentes condições hidrológicas	Expandir para eventos não simétricos; incluir baseflow no BCM; incorporar modelagem probabilística de condições climáticas e meteorológicas futuras

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
105	ENN melhorou ~19–37% (Longquan) e ~20–30% (Jinhua) em 1–3 h; combinação Boosting + BMA apresentou os melhores resultados	-	recomendação metodológica de usar Bayesian Model Average para integrar saídas
106	ECNN manteve desempenho mais estável em horizontes longos; em 12 h obteve NSE=0.81 e RMSE=64.37 m3/s, superando LSTM (RMSE=97.69; NSE=0.79) e CNN (RMSE=124.77; NSE=0.63); menor viés (RE) em 12 h	entradas limitadas (apenas precipitação; evaporação; inflow); não-estacionariedade; poucos eventos de alta vazão; ajuste manual de hiperparâmetros; heterogeneidade espacial ignorada; atrasos (lag) em alguns eventos	incluir precipitação de sensoriamento remoto com informação espacial; otimização Bayesiana de hiperparâmetros; ampliar variáveis; ajustar a arquitetura; decomposição empírica de modos
107	AE-CNN-LSTM obteve RMSE=2.63; NSE=0.97; R ² =0.96; reduziu erros em 5–20% frente aos modelos de comparação	-	Aplicar em diferentes regiões e incluir seleção de lag temporal e arquiteturas híbridas adicionais
108	Melhor configuração MLP (m=4; s=1) obteve R ² =0.994; inclusão de chuva reduziu RMSE para 1.17; previsão de curto prazo em tempo real viável	Dependência de um único sensor de chuva; ausência de validação externa	Incluir sensores adicionais; expandir análise estatística das séries e incorporar modelo nos sensores
109	GA-SVM obteve RMSE=0.04199; r=0.9675; MAE=0.02626; superou SVM e MLR; predições positivas e robustas em todos os regimes de vazão	Uso de dados de uma única estação; necessidade de mais conjuntos e estações para generalização	Aplicar em múltiplos pontos e combinar com outros algoritmos híbridos
110	STA-LSTM apresentou melhor desempenho (R ² até 0.96; RMSE 97.03; QR 96.19%); atenção espacial e temporal melhoraram previsões em todas as bacias	Dependência do tamanho do conjunto de dados; aumento de erro com o tempo de previsão; ausência de validação externa	Explorar grafos de bacias (GCN) e aumento de dados hidrológicos; incluir mais variáveis físicas
111	LSTM apresentou NSE e KGE > 0.9; dominância de chuva recente na formação do escoamento; fluxo e precipitação foram os fatores mais influentes; IG mostrou relação conjunta entre chuva e runoff histórico	Incerteza nas interpretações sob diferentes métodos; dependência do input histórico; ausência de validação cruzada externa	Desenvolver métodos explicáveis robustos (TimeShap; TFT); ampliar variáveis e bacias; combinar com mecanismos físicos
112	Ensemble LSTM+RF obteve sensibilidade=71.4%; especificidade=85.9%; acurácia=81.13% (teste); acurácia=0.997 (validação) e 0.811 (teste); superou individuais	Dados desbalanceados; não linearidades; possíveis rótulos incorretos; dados com ruído e valores ausentes discutidos pelos autores	Uso de PSO e algoritmo genético para otimização/seleção dos modelos; explorar outros algoritmos de deep learning e regressão de dados de cheia
113	GRU obteve melhor desempenho geral (NSE médio=0.70) e baixa variabilidade; LSTM apresentou desempenho próximo; ambos superaram o NWM; erros de pico (RPE) ~0.15 e PTE ~1 h para LSTM/GRU	RNNs caros computacionalmente; desempenho inferior em eventos multi-pico por insuficiência de entradas/temporal; VRNN com alta variabilidade; NWM não calibrado localmente	integrar mais parâmetros de entrada; explorar outros modelos de ML
114	LSTM superou MLR com 21.42% menor RMSE e NSE=0.9937; capturou padrões temporais complexos e altos valores de descarga com menor erro	Limitações de generalização por uso de dados simulados; ausência de variáveis ambientais adicionais	Aplicar em dados reais; testar modelos híbridos e variáveis como temperatura e salinidade
115	Entre 1970–2020 o número de cheias variou ~18–55; ~35 cheias por ano após 2000; frequência máxima ~110 ocorrências com rainfall=250 mm; Random Forest accuracy=75.61%; ANN mean accuracy=90.85%	Precisão/accuracy menores para alguns modelos em relação ao ANN; coleta em tempo real por longos períodos demanda tempo/orçamento e aumenta a complexidade computacional	Ampliar dados espaço-temporais; empregar modelos de Deep Learning; testar outros softwares; aplicar em outros locais; técnicas de redução de dimensionalidade

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
116	TDNN obteve RMSE=125.77 e NSE=0.92, superando todos os outros modelos; SVR foi o melhor entre ML tradicionais	Complexidade de dados espaciais; possível sobreajuste em modelos de boosting; limitação de recursos computacionais	Aplicar modelos híbridos e testar em outras bacias; desenvolvimento de aplicação prática com dados abertos
117	Precisão elevada (p.ex., R^2 médio=0.988 para profundidade; 0.968 para velocidade) e aceleração de 17 629× (KNN-Depth) e 3 462× (KNN-Speed) vs. modelo hidrodinâmico	Dados medidos limitados; amostra medida relativamente pequena	Aumentar dados medidos/amostras para melhorar desempenho; investigar desempenho com mais amostras
118	XGB obteve melhor desempenho global (teste: $R=0.911$; NRMSE=0.056; NMAE=0.038; FB=0.064) e capturou variações em 2016–2017 nos três mananciais	Dados esparsos; disponibilidade limitada de meses; subestimação de picos após 2017 em uma bacia	Explorar diferentes métodos de explicação além de SHAP; testar outros métodos de ML com múltiplas técnicas de XAI; ampliar o conjunto de dados (tempo e espaço)
119	Prophet conseguiu prever inundação a longo prazo; funciona com dados faltantes; boa performance para eventos extremos	Dependência de disponibilidade de dados com qualidade	Aplicar em outras bacias; aplicar em outros contexto hidrológicos
120	LSTM reduziu o erro MSE em 64.13% e MAE em 43.43% em relação ao RNN; maior precisão e tempo real	Dificuldade de generalização para outras bacias; coleta limitada de dados em pequena escala	Aplicar modelos híbridos e validar com bacias diferentes
121	MHDNN-UPC obteve ganho médio de 10% na acurácia preditiva em relação aos modelos tradicionais; melhor desempenho computacional com arquitetura paralela UPC	Necessidade de dados de longa duração e alta qualidade; complexidade de implementação	Explorar integração com dados de alta resolução e novos contextos espaciais; extensão a outras bacias
122	Correção de viés melhorou RMSE em ~2.5% (gauge); 21.8% (radar); 60.7% (satélite); ERNN atingiu CC=0.93 e NS=0.85 e reduziu CRPS em ~50% vs BMA; pesos de mesclagem (ERNN, IC95%): gauge 0.52–0.56; radar 0.35–0.39; satélite 0.08–0.09	Parâmetros de correção não variam no tempo; estudo focado em eventos de tufão; contribuição das fontes pode variar com o tipo de tempo	Calibração dinâmica dos parâmetros; investigar influência de umidade do solo e intensidade da chuva; avaliar variação por tipos de sistemas meteorológicos
123	MAPE ~ 20%; NSE 0.7–0.8; redução de MAE; MAPE; RMSE e aumento de NSE com o ensemble; PICP >70% e PINAW ~20%, indicando intervalos confiáveis e estreitos	A incerteza usa GPR como exemplo; necessidade de comparar mais métodos probabilísticos; avaliar desempenho sob eventos extremos; otimizar a estrutura do ensemble; investigar portabilidade para outras bacias/regiões	Comparar mais métodos probabilísticos (p.ex., Bayesian deep learning); explorar limiares de seleção de indicadores; melhorar desempenho em fluxos extremos; otimizar arquitetura; testar em outras bacias
124	ANN alcançou NSE=0.999 e RMSE=1.27 cm (validação); melhora de 70% no MAE sobre persistência; PDIRnow essencial para previsões 24h	Baixa densidade de pluviômetros; limitação de generalização; necessidade de calibração adicional	Incluir umidade do solo e previsões ETA/GEFS; expandir para outras bacias da Amazônia
125	RF com entradas Qt-1; Qt-11; Qt-12 obteve melhor desempenho (RMSE=2.2395; WI=0.998462; $R^2=0.9012$) e previsões mensais precisas de vazão	Limitação de localização: treinado para o Aswan High Dam; necessidade de retreinamento para outros locais	Modelos que considerem diferentes áreas geográficas
126	ALO reduziu o erro médio em 11% nas estações estudadas; NSE > 93%; boa correlação entre valores simulados e observados	Dependência de dados locais; necessidade de maior diversidade climática	Explorar novos algoritmos híbridos; expandir para diferentes regiões e condições climáticas
127	PSO-LSTM obteve NSE=0.9892 (1 dia); 0.9475 (15 dias); melhora $R=0.01-0.02$ sobre LSTM puro; previsão até 15 dias	Dados incompletos após 2009; ausência de variáveis climáticas complementares; dependência de dados locais	Adicionar chuva e variáveis meteorológicas; testar novos modelos híbridos; ampliar cobertura espacial

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
128	HEC-RAS e LSTM obtiveram NSE > 0.7; CADDIES adequado apenas para áreas urbanas; LSTM teve menor tempo de execução e alta flexibilidade	Ausência de calibração espacial; dados limitados; incertezas associadas a entradas e simplificações de modelo	Incluir análise de incerteza; ampliar métricas e cenários; explorar novos arranjos híbridos
129	ANFISh previu o pico da cheia de 2014 em 2220.997034 m³/s vs 2299.05723 m³/s (variação -3.395%); desempenho superior do ANFISh com NSE=0.968; R²=97.066%	Dependência de dados históricos; necessidade de regras de especialista para fuzzy; tentativa-e-erro na configuração; dependência de hardware; dados com valores faltantes e inconsistências tratados por curvas cota-vazão	Checar escalabilidade; aumentar o escopo (mais e melhores entradas); aplicar os modelos a outros estudos de caso
130	GWO obteve melhor desempenho no 1º caso; GSA no 2º e 3º; Kalman filter (KF) aumentou CC e NSE e reduziu PSR em todos os casos, com maior ganho no 3º caso	Principal limitação do modelo é calibração dos parâmetros	-
131	PINN alcançou MSE=4.126×10⁻³ e identificou parâmetros S₀=8.79×10⁻⁵ e n=0.02952 próximos aos reais; apresentou robustez e boa generalização	Escassez de medições; sensibilidade à posição das estações de monitoramento; dependência de boas estimativas iniciais	Aplicar PINNs em tempo real em bacias reais; ampliar conjunto de dados; explorar integração com controle ótimo
132	RFR e NN-MLP atingiram R²=0.95; MAE=0.11 ft; RMSE=0.21 ft (teste) no Lake Carl Blackwell; em Verdigris (grande bacia) R²=0.973 (teste); importância das features: chuva nas últimas 24–204 h ≈80% e nível do dia anterior ≈20%; Rain_060hr foi a mais importante	Dados de nível do Lake Carl Blackwell não contínuos; deep learning requer séries contínuas e apresentou variação estocástica; possível suavização ao promediar chuva em bacias grandes; ausência de observações no meio da subida de pico em um evento	Aprimorar deep learning com nova engenharia de features; modelagem específica para baixos níveis incluindo retiradas, evaporação e clima
133	Sequencial ANFIS prevê com 6 dias de antecedência usando um único input e mantém alta acurácia (r²=0.99; Nash–Sutcliffe=0.98); método fornece previsões acuradas em longas distâncias	Diferença entre os conjuntos de calibração e validação "poderia representar uma limitação" para o forecast em Fort McMurray	-
134	PSO-SVM obteve NSE=0.99334 e R²=0.98918, superando SVM e BPNN; inclusão de evapotranspiração melhorou a precisão	Limitações de dados remotos e resolução temporal; ausência de monitoramento fluvial denso; erros de digitalização geoespacial	Expandir aplicação para previsão de sedimentos; águas subterrâneas; uso de sensores e redes hidrometeorológicas densas
135	CEEMDAN-RF foi o melhor (teste R²=0.94; RMSE=0.13; MSE=0.02); a decomposição CEEMDAN melhorou a acurácia em relação aos modelos standalone	-	testar em outros locais; testar outros modelos de previsão
136	DRUM melhora nowcasting para o top 1% de vazões em 72.3% das bacias; sob condições operacionais estende o lead time médio em ~1 dia para cheias de 20 e 50 anos; com precipitação medida, recall +0.3–0.4 e janela de aviso +2.3 dias; maiores ganhos de 3–7 dias no leste e noroeste dos EUA	Metodologia focada em bacias pequenas-médias; desempenho dependente da qualidade das previsões de precipitação; questão de transferibilidade ao treinar com medição e aplicar com reforecast	Integrar medições e previsões no treino; incorporar restrições físicas (physics-informed) no modelo de difusão; ampliar para bacias maiores com extração espacial (p.ex., CNN); acelerar amostragem (DDIM; paralelização multi-GPU); integrar múltiplos sinais hidrológicos adicionais
137	LSTM apresentou alta precisão em intervalos de 30 min (RMSE=0.0101; MAE=0.0097); quanto maior o intervalo temporal, melhor o desempenho	Coleta curta de dados; limitações de disponibilidade e qualidade dos dados; alta dependência computacional	Ampliar período de coleta; incluir variáveis socioeconômicas e climáticas; expandir modelo spatiotemporal

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
138	Cascaded-ANFIS obteve $R=0.933$; $RMSE=0.66$; $NSE=0.87$; $KGE=0.90$ e superou os demais; Projeções SSP2-4.5 e SSP5-8.5 indicam diminuição de eventos e magnitudes de cheias; SSP5-8.5 mostra secas de maio a agosto	Dados futuros e correção de vies podem afetar resultados; amostra curta; indisponibilidade de dados completos em alguns postos; omissão de estações com lacunas	Implementar o modelo também com RCPs e comparar; análises extensas de cheias projetadas baseadas em fluxos medidos; mais pesquisa para níveis futuros
139	Ensemble mean apresentou $CE>0.93$; redução de MAE e MAPE; desempenho superior ao melhor modelo individual tanto na calibração quanto validação	Limitação de dados (falhas instrumentais 1999–2009); dependência de pesos iniciais aleatórios; diferenças no padrão de chuva	Aprimorar integração com séries climáticas; estender para múltiplas bacias; explorar dados adicionais
140	$NSE>0.95$ até 6 h; $MAE<0.12$ m; melhora de 0.185 em NSE e 0.1 m em MAE sobre LightGBM; alta precisão em curtos prazos	Dependência de precisão das previsões de chuva; redução de desempenho em longos prazos; não inclusão de modelos físicos	Integrar modelos de mecanismo hidrológico com ML; ampliar bacias e incluir dados climáticos
141	PSO-LSTM atingiu $NSE=0.9962$ (1h) e manteve $NSE>0.74$ em 12h; superou modelos comparativos em todas as métricas	Dependência de configuração adequada dos hiperparâmetros; ausência de variáveis adicionais como temperatura e umidade do solo	Incluir novas variáveis (solo; temperatura); ajustar peso de inércia do PSO; aplicar a previsão de outros parâmetros (qualidade da água; umidade)
142	LSTM obteve $MSE=0.000071$; $RMSE=0.008442$; $MAE=0.005551$; melhor ajuste e previsão de 48h	Dados limitados a uma estação; modelo testado em uma única bacia	Ampliar dados; testar em outras regiões; integrar múltiplas fontes de previsão meteorológica
143	RFM_Trans_v3 obteve $NSE=0.9578$ e reduziu MSE em 51,68% em relação ao LSTM; identificou 3 variáveis-chave (hydro_runoff; hydro_rainfall; tmin) para máxima eficiência	Dados de Chao Lake são confidenciais; dependência de hardware de alto desempenho; ausência de validação multirregional	Explorar novas arquiteturas de atenção (temporal; grafos); aplicar estratégias de de-stationarização avançadas; expandir a previsão para horizontes mais longos
144	VPMM obteve NSE até 0.985; RMSE mínimo de 1.471 m ³ /s; mais robusto e confiável que SVM e WASVM	Incerteza na estimativa do fluxo lateral; variabilidade da umidade do solo	Ampliar dados e validar multirregionalmente; integrar novos sensores e séries mais longas
145	SMRGT obteve $R=0.927$; $MSE=0.535$; $MAE=0.318$; M-FL $R=0.917$; $MSE=0.595$; $MAE=0.338$	Conjunto de teste (~275 dias) não atingiu picos de cheia (~cinco eventos), reduzindo correlação; modelos black-box não refletem a física	SMRGT recomendado para futuras análises hidrológicas e de recursos hídricos
146	Modelo híbrido reduziu RMSE para 219.26 e elevou R^2 para 0.992; RF aumentou acurácia em 29%; shapley indicou HCC e evaporação como variáveis-chave	Dados limitados a três estações; ausência de validação espacial; dependência de condições climáticas locais	Expansão para outras bacias; integração com assimilação de dados e modelos físicos; melhoria da explicabilidade
147	LSTM-Pangu e GRU-Pangu apresentaram melhor desempenho e robustez, especialmente em previsões com lead times longos e altos fluxos	Dependência de uma única bacia e fontes de dados locais; limitação na generalização	Ampliar para outras regiões; incorporar variáveis de uso do solo e dados de radar
148	CouplingVIC-new: $NSE=0.93$; $R^2=0.92$; $KGE=0.91$; $RMSE=334.86$ m ³ /s; melhorias vs LSTM e VIC: +7.29%; +2.97%; +9.73%; -19.41% e +13.41%; +12.19%; +19.73%; -46.95%; captura melhor variação sazonal e interanual	Capacidade ainda limitada para extremos; superestima risco de AMDPF e TFAM5D e sua variável conjunta; estudo aplicado a uma única bacia (YRB)	Introduzir amostras sintéticas de cheias ou aplicar métodos de correção de erro para melhorar a simulação de extremos; testar em outras bacias
149	Adicionar chuva melhorou as estimativas; WNN apresentou os melhores resultados em todos os horizontes (ex.: $NSE=0.926$ – 0.987 a 1 dia; $R=0.546$ – 0.768 e $NSE=0.299$ – 0.585 a 30 dias)	-	-

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
150	PE-SFPM atingiu menores MAE e RMSE (ex.: ChangHua RMSE=68.29); robustez superior e melhor previsão de picos	Dados limitados para pequenas bacias; ausência de dados públicos; necessidade de calibração de janelas	Uso de transferência, few-shot e reinforcement learning para pequenos conjuntos
151	Melhores resultados com previsão de 1h e 2h de antecedência; Sem melhoras significativas na previsão para períodos de seca	Poucos dados referentes ao período de seca;	Utilizar mais dados dos períodos de seca
152	Pipeline composto com AutoML reduziu erro e atingiu NSE=0.80 (10 postos; validação); no período de cheias (abril-julho) NSE=0.71; superou modelos estatísticos e físico comparados	Dificuldade em combinar previsões entre blocos; medições insuficientes/inexatas; lacunas nos dados; NDSI menos confiável em florestas coníferas; poucos postos com descarga para calibrar SRM	Incluir deep learning (LSTM); modelos ML adicionais; modelos físicos mais sofisticados; integrar novas fontes de dados; melhorar a integração do ensemble
153	AR-REPT foi o melhor (NSE=0.845; RMSE=0.682 m3/s); modelos em ensemble melhoraram o REPT em ~26.82% (BA); 18.91% (RC); 7.69% (RS); 28.99% (AR); 28.05% (DA)	Área única; divisão treino/teste e seleção de entradas podem introduzir incertezas; ausência de variáveis adicionais (evaporação; temperatura; umidade do solo)	Aplicar a outras bacias; incorporar modelos fisicamente baseados (p.ex., SWAT, HEC-HMS) para comparação; incluir mais variáveis hidroclimáticas; avaliar generalização
154	ANN com amostras de chuva intensa teve melhor precisão (RMSE=0.017–0.172 m); ANFIS evitou ruído; SVM mais estável sob eventos extremos	Dados limitados a uma única bacia; ausência de incerteza quantitativa; menor desempenho sob chuvas muito intensas	Explorar ensembles híbridos; validação cruzada regional; integração com sistemas de alerta precoce
155	O modelo WSVR apresentou melhor desempenho em todas as estações com RMSE e MAE mais baixos e NSE mais alto; demonstrou superioridade sobre SVR, ANN e MLR	Dependência de dados locais e ausência de teste em outras bacias	Explorar outros algoritmos híbridos e metaheurísticos; ampliar áreas e variáveis climáticas
156	LSTM alcançou NSE ≥ 0.8 em todas as escalas; melhor desempenho em previsão de longo prazo; temperatura melhora previsões de curto prazo e precipitação as de longo prazo	Ausência de dados sobre operação de barragens; incerteza em previsões de longo prazo; dependência de séries temporais históricas	Incorporar regulação sazonal das mega-barragens; melhorar precisão de previsões de longo prazo; ampliar análise espacial
157	CNN-LSTM obteve menores erros (RMSE; MAE) e maiores índices normalizados (WI; LM; ENS); $0.226 \leq RMSE \leq 0.155 \text{ m}^3 \text{ s}^{-1}$ (Brisbane River); $0.196 \leq MAE \leq 0.054 \text{ m}^3 \text{ s}^{-1}$ (Teewah Creek); desempenho superior às IAs convencionais e ensembles nas janelas 1-Week; 2-Weeks; 4-Weeks; 9-Months	-	testar o modelo com outras bases de dados hidrometeorológicos
158	Previsões de 2016 quase coincidem com observações na estação de cheia; $R2 > 0.8$ e $LMI \approx 0.65$ em 1998 e 2016; RMSE=1171.9 m3 e $R2 \approx 1$ no rolling de 10 anos	Extremos anômalos (pico de 1998) difíceis de prever; extremo previsto um mês adiantado; desempenho inferior com 18m/24m-Min-Pd; Única estação hidrológica de dados	-
159	Melhor desempenho com 4 variáveis (NSE=96.7, $R^2 \approx 0.95$); previsão estável em escala diária e decenal; Radial Kernel eficaz	Limitações na previsão de descargas muito altas (anos 2008–2019); dependência de séries longas e dados locais	Explorar modelos híbridos; incluir variáveis de uso do solo e regulação de barragens; testar ensembles
160	CBMA reduziu RMSE até 55% e aumentou NSE para 0.94; desempenho superior a todos os modelos individuais e menor incerteza nas previsões	Necessidade de dados longos e múltiplas variáveis climáticas; incerteza residual associada às distribuições e funções copulares	Incluir novas fontes de dados hidrológicos; testar CBMA em outras bacias; expandir análise de incerteza; integrar variáveis locais
161	XGBoost obteve 96.35% de acurácia, superando CatBoost; desempenho consistente mesmo após balanceamento com SMOTE	Desequilíbrio de classes; necessidade de maior eficiência energética na rede de sensores	Aplicar aprendizado federado e inteligência embarcada nos sensores; otimizar consumo de energia

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
162	SVR-HHO apresentou melhor desempenho geral (RMSE=92.038/181.306 m ³ /s; SI=0.401/0.715; COC=0.881/0.717; WI=0.928/0.777) para prever a vazão diária no Naula basin	Subestima picos e superestima vazões baixas; faixa de calibração não cobre totalmente a de validação; poucos extremos no treino	Avaliar WOA e GWO acoplados a técnicas de ML; testar em diversas bacias em escala global
163	O modelo ABM-DDM reproduziu adequadamente a forma e magnitude dos picos de vazão; cenário 3 apresentou melhor ajuste (erro <10% no Qpk)	Sensibilidade a variações nos dados de entrada; dependência de calibração manual; tamanho limitado da amostra temporal	Testar em diferentes bacias; testar com diferentes variáveis
164	Modelo aumentou o tempo de antecedência de previsão de 2h para 3h; NSE até 0.98; representação espacial melhorou significativamente previsões de pico e tempo de resposta	Incertezas em eventos extremos; dependência da calibragem e complexidade computacional	Aplicar o modelo em outras bacias de diferentes tamanhos; testar versões em bacias karsticas e menores; avaliar sensibilidade a dados de entrada
165	Em exemplos: Tenmile (MAE teste) TL+GRU=0.1033; TL+LSTM=0.1388; TL=0.1886; Saco (MAE teste) TL+GRU=0.2255; TL+LSTM=0.3261; TL=0.4525	Risco de negative transfer; necessidade de selecionar conjunto fonte adequado; desempenho atípico em Ammonoosuc	Evitar a ocorrência de negative transfer learning demanda mais atenção em estudos futuros
166	DT atingiu Accuracy=93.22%, Precision=92.85 e Recall=92.81; modelo lida com 13 classes e média de acurácia=85.72%	Necessidade de testar em ambiente real de predição multivariada	Estudar aspectos de IoT (gestão de sensores heterogêneos; consumo de energia; eficiência) e integrar módulos de descrição contextual para melhorar explainable AI
167	Bayesian LSTM atingiu CIL de 95–100% e convergência rápida (123 passos); previsão confiável e precisa de cheias em pequenas bacias	Necessidade de calibração contínua; acúmulo de erro em previsões longas; baixa interpretabilidade física	Aplicar o modelo em períodos de maior frequência e bacias com variação mais densa; equilibrar confiabilidade e precisão
168	LSTM alcançou RMSE=0.0208 e identificou Rathnapura como principal área de impacto; bom desempenho em previsão de cheias	Número limitado de estações; ausência de dados de umidade do solo; dependência de estimativas de chuva	Ampliar número de estações; incluir contornos topográficos; validar com eventos passados; integrar dados em tempo real; usar SHAP
169	Bayesian Linear Regression apresentou menores erros (MAE=0.10–0.12; RMSE=0.14–0.16) até 12h; chuva teve baixa influência no modelo	Dados limitados; lacunas em sensores; forte complexidade hidrológica; erro cresce com o horizonte de previsão	Explorar integração de IA e dados abertos; ampliar sensores; aplicar em sistemas de alerta urbano; combinar dados sociais e mapas de impermeabilização
170	Melhor configuração ANN: 3 estações; 7 entradas; 12 neurônios; MSE validação=4,77E–05; SVM linear (4 estações; 5 entradas) MSE validação=5,07E–05	Tempo; dados; recursos humanos e financeiros; limitações de infraestrutura computacional; algumas configurações ANFIS não treinaram	Incluir outras técnicas de IA (aprendizado de máquina; sistemas especialistas; redes Bayesianas); converter TSK para Mamdani; mais entradas e novos dados; desenho experimental mais amplo; sistema computacional mais robusto
171	DL identifica a função preditiva em modo Hindcast com KGE elevado; em Forecast o desempenho decai rapidamente com o horizonte e é próximo à persistência	Dados sintéticos; sensibilidade alta à previsão de chuva futura; discrepância por usar chuva média de bacia enquanto o HLM usa chuva espacial; ausência de validação externa	Aplicar em dados reais; investigar sensibilidade à chuva futura vs. modelos físico-distribuídos; explorar limites de complexidade de processos; seleção de atributos e estratégias de coleta de dados
172	ConvLSTM obteve NSE=0.95 e R ² =0.96, superando modelos hidrológicos tradicionais; mapas de risco mostraram 630 ha de área inundável para nível de 10 m	Escassez de dados observacionais; dependência de calibração e otimização de hiperparâmetros	Integração de dados satelitais e novos modelos híbridos; aprimorar generalização e análise de incerteza

ID	Principais Achados	Limitações do Estudo	Sugestões Futuras
173	CNN-GRU obteve maior precisão e robustez; NSE=0.91; RMSE=12.3; MRE=0.22; superou LSTM, WANN e ARIMA; melhor desempenho em estações mais distantes do estuário	Influência das marés nas estações próximas ao mar; aumento do erro para previsões >5 dias	Combinar dados de maré e nível; expandir modelo para seções inferiores; uso de clustering e fatores ambientais
174	Modelo híbrido MLPQTP-EMD obteve NSE=0.84 e 91.3% de acurácia em previsão de picos; decomposição EMD aumentou precisão em 5.6%	Escassez de dados; ausência de validação em múltiplas bacias; complexidade estrutural das ANNs	Integrar ANNs a fundamentos físicos; ampliar uso para outras bacias e aplicações práticas de gestão hídrica

APÊNDICE G- DADOS DO BLOCO DE QUALIDADE

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
1	alerta precoce; previsão operacional; apoio à gestão	Alta dados ERA5/ALOS abertos; descrição completa do modelo e validação	Médio Validação concentrada em um único evento de 2024; sem replicação externa multi-regional.
2	Alerta precoce de inundações urbanas; apoio à decisão em monitoramento em tempo real	Média método detalhado; uso de WEKA; dados experimentais; sem código aberto	Médio Base de dados curta (1 mês); sem validação externa; modelos simulados não aplicados em campo
3	Alerta precoce; apoio à decisão; gestão de risco; visualização espacial online	Média descrição detalhada de dados e método, mas sem código ou dataset público	Médio Dependência de dados limitados; ausência de validação externa e compartilhamento de código
4	alerta precoce; apoio à gestão; previsão operacional	Média método detalhado; código e dados não disponibilizados	Médio Base de dados pública, mas sem código e sem validação externa.
5	Previsão de vazão; sistemas de alerta de inundações e seca; gestão de recursos hídricos	Média descrição detalhada do modelo e dados, mas sem disponibilização de código ou dados abertos	Baixo Uso de bases amplas (CAMELS-US e CL); validação cruzada aplicada; resultados consistentes
6	Prevenção de inundações; otimização de energia hidrelétrica; apoio à gestão de recursos hídricos	Alta dados detalhados, metodologia completa, parâmetros explícitos e fontes citadas	Baixo Dados extensos; calibração robusta; validação em múltiplas escalas temporais
7	sistema de alerta precoce; apoio ao manejo de inundações; operação do reservatório	Média descrição detalha dados; arquitetura e partições, porém sem código/dados abertos	Médio Estudo em única bacia sem validação externa; divisão interna 70/15/15; várias análises mas sem teste em outras bacias
8	Sistema de Alerta; Planejamento e Gestão de Riscos; Apoio à decisão em tempo real	Média metodologia e parâmetros detalhados, mas sem disponibilização de dados/código	Baixo Dados de longo período; múltiplas validações regionais; métodos descritos com clareza
9	Gestão de recursos hídricos; controle de inundações; operação de reservatórios	Média boa descrição do método, hiperparâmetros e divisão dos dados; "Data Availability Statement: Not applicable"; sem código/dados abertos	Médio Um único estudo de caso (Fuchun/Qiantang) sem validação externa; subestima picos de vazão
10	Previsão de inundações; alerta precoce; apoio à gestão de risco	Média descrição detalhada; dados apresentados; sem código público	Baixo Base de dados extensa; validação temporal robusta; ausência de sinais de viés evidente
11	Sistema de apoio à decisão para prevenção e mitigação de inundações; alerta precoce; planejamento de emergência	Média descrição detalhada dos dados e parâmetros; sem código público	Baixo Base de dados extensa; validação completa; método comparativo transparente
12	Alerta precoce; previsão operacional; apoio à gestão de risco e formulação de políticas	Alta uso de frameworks públicos; descrição detalhada do processo e parâmetros de treinamento	Baixo Extensa base de dados de 78 anos, múltiplas fontes, validação cruzada em 5 clientes, metodologia detalhada e métricas transparentes
13	Alerta e operação informada por previsão; otimização robusta multiobjetivo para controle de inundações	Média metodologia detalhada; dados operacionais locais; sem código/dados públicos declarados	Médio Estudo de caso único (LSM) com dados locais; sem código/dados públicos; validação apenas com eventos históricos
14	Gestão de recursos hídricos; previsão de inundações; apoio à tomada de decisão em áreas montanhosas	Média dados descritos; métricas detalhadas; mas sem código público	Baixo Dados extensos de 40 anos; validação robusta; resultados consistentes
15	Sistema de alerta precoce de inundações; apoio à gestão de recursos hídricos; planejamento de mitigação	Média dados e método descritos; sem código público; dados sob solicitação	Baixo Dados extensos; métricas robustas; análise estatística e validação confiáveis

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
16	Previsão de inundações; sistemas de alerta rápido	Alta metodologia, parâmetros e resultados descritos detalhadamente, reprodutível com TensorFlow/Keras	Médio Base sintética; ausência de validação com dados observados reais.
17	Previsão operacional de vazão diária; gestão e operação de reservatórios; mitigação de inundações locais	Média descrição detalhada de dados, parâmetros e validação; sem código ou dados abertos	Médio Estudo limitado a três estações no Irã; sem dados externos; não reproduzível sem acesso às séries originais
18	Redução de riscos de inundações; apoio ao controle de inundações; gestão de recursos hídricos	Média metodologia detalhada; uso de MATLAB informado; sem código/dados públicos declarados	Médio Estudo de caso único (bacia do Gamasiab); sem validação externa; dependência de dados locais
19	Previsão de inundações; emissão de alertas de risco; suporte a sistemas de gestão de desastres	Média descrição detalhada de parâmetros e metodologia; ausência de código ou dados públicos	Médio Conjunto de dados limitado a uma bacia; ausência de validação externa; frameworks não especificados
20	Alertas de inundações; previsão horária para sistemas de aviso precoce	Média dados detalhados; equações e parâmetros informados; sem código público	Baixo Grande conjunto de dados; múltiplas métricas; validação cruzada robusta; incerteza mínima (d-factor=0.00036)
21	Previsão de vazão; gestão integrada de recursos hídricos; planejamento de obras hidráulicas	Média descrição detalhada dos dados e equações; sem código público	Baixo Longa série temporal; comparação direta com modelo base; uso de métricas múltiplas e validação temporal
22	Previsão de vazão; gestão de recursos hídricos; prevenção de inundações	Média dados detalhados e metodologia completa; sem código público	Baixo Longa série temporal; 14 estações; múltiplas métricas e modelos comparados; validação robusta
23	Previsão de nível da água; mitigação de inundações; suporte à gestão urbana	Média descrição detalhada da metodologia e dados; sem código público	Baixo Longa série temporal; validação robusta; múltiplas métricas e comparação com três modelos de referência
24	Previsão antecipada de inundações; gestão de risco de inundação; alerta precoce	Média dados e equações detalhados; código MATLAB mencionado mas não aberto	Baixo Longa série temporal; múltiplas métricas; comparação com modelos clássicos; uso de dados reais de satélite e calibração externa
25	Previsão operacional de inundações; apoio à defesa civil; planejamento hídrico	Média dados abertos do HydroPortail e protocolo detalhado; sem código público	Baixo Extensa série temporal; múltiplas estações; validação cruzada temporal robusta; comparação entre 12 modelos distintos
26	Sistema de alerta precoce; previsão operacional; suporte à gestão hídrica; redução de risco de desastres	Média descrição detalhada; código Python e MATLAB citados; dados não públicos	Baixo Longa série temporal; validação cruzada robusta; comparação múltipla; métricas completas e replicáveis
27	Alerta de inundações de curto prazo; apoio à gestão hídrica; integração em gêmeo digital	Alta dados públicos SAIH; scripts e detalhes de pré-processamento/modelagem disponibilizados no repositório citado no artigo	Médio Estudo focado em uma bacia e dois pontos; ~3 anos de dados; sem validação externa independente
28	Simulação de vazão em áreas úmidas onde modelos físicos forem insuficientes	Média metodologia e resultados detalhados, mas sem disponibilização de código ou dados	Baixo Base de dados extensa; validação robusta e comparação entre múltiplos modelos
29	Previsão de vazão diária; apoio à gestão de recursos hídricos; mitigação de inundações; operação de reservatórios	Média descrição detalhada de parâmetros e métricas; código parcialmente descrito; sem dados públicos	Médio Estudo de caso único; ausência de validação externa; dados limitados a uma estação
30	Gestão de recursos hídricos; previsão de inundações; apoio à mitigação de riscos	Média descrição metodológica detalhada mas ausência de código e dados abertos	Baixo Conjunto de dados extenso; validação cruzada temporal robusta; comparação múltipla entre modelos

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
31	Previsão e alerta de inundações; apoio a planejamento de engenharia; gestão de emergências	Média descrição metodológica e dos dados; sem código/dados públicos declarados	Médio Estudo em uma única bacia com 12 eventos e sem validação externa; viés de subestimação para altos fluxos em T longos
32	Gestão de recursos hídricos; previsão de inundações; irrigação	Média detalhamento completo dos parâmetros e dados, mas ausência de código aberto	Baixo Longa série temporal; dados observacionais de 19 anos; múltiplas métricas e validação robusta
33	Apoio à gestão de recursos hídricos; controle de inundações	Alta descrição detalhada de dados, parâmetros e desempenho; dados da ANRH são acessíveis	Baixo Conjunto de dados adequado; metodologia claramente descrita; comparação entre múltiplos modelos e métricas robustas
34	Apoio a alertas locais de inundação; sistemas de decisão para autoridades	Baixa não disponibiliza código nem dados brutos, apenas descrição resumida	Médio Dados limitados a seis estações; ausência de validação externa; ruído nos dados de radar
35	Apoio ao dimensionamento de estruturas hidráulicas; modelagem regional de inundações	Média dados detalhados e métricas completas, mas sem código aberto	Médio Dados de 181 bacias, sem validação externa e viés em altas recorrências
36	Previsão de vazão; gestão de recursos hídricos; operação de reservatórios; suporte à transferência hídrica Tagus-Segura	Média arquitetura e parâmetros descritos, código acessível em repositório público	Médio Modelos sem validação externa; dependência de séries longas e múltiplas fontes de dados
37	Previsão operacional de vazão; alerta de inundações em tempo real	Alta dados abertos e metodologia detalhada; uso de bibliotecas públicas	Baixo Extensa base de dados; validação independente; descrição metodológica completa e comparação entre seis modelos
38	Sistema de alerta precoce de inundações; gestão de recursos hídricos regionais	Média dados disponíveis sob solicitação; protocolo descrito, mas sem código aberto	Baixo Conjunto de dados adequado; validação cruzada temporal; comparação entre modelos bem descrita
39	Previsão de níveis de inundação; apoio à gestão de riscos; alerta precoce	Média parâmetros e métricas bem descritos; código MATLAB informado, mas não aberto	Médio Amostra restrita a uma única bacia; sem validação externa; dependência de calibração local
40	Planejamento de gestão de risco; suporte à decisão em emergências; transparência para equipes de resposta	Alta dados públicos; detalhamento do processo de modelagem e interpretabilidade via LIME/SHAP	Médio Base genérica sem contexto geográfico real; risco de sobreajuste com $R^2=1.00$
41	Sistema de alerta precoce; validação cruzada para monitoramento de nível d'água; suporte à gestão de risco	Alta dados públicos; detalhes completos de treinamento e ferramentas; código descrito	Baixo Dados abertos; múltiplas métricas; validação cruzada entre estações garante robustez
42	Gestão de recursos hídricos; avaliação de risco de inundações; apoio à tomada de decisão	Alta links de dados e repositório de código declarados no artigo; bibliotecas abertas e fluxo metodológico descrito	Médio Estudo em uma única bacia (THRB); ausência de validação externa dedicada; possíveis erros por não incluir mudanças de uso do solo
43	Previsão de inundações; alerta precoce; suporte à decisão; gestão hídrica	Alta dados e equações detalhados; pseudo-código completo; metodologia totalmente descrita	Médio Dados de uma única bacia; ausência de validação externa; sensibilidade a dados de chuva e interferência humana
44	Gestão de recursos hídricos; alerta de inundações; previsão operacional diária	Média descrição detalhada de dados e equações; ausência de código aberto	Médio Base de dados única; sem validação cruzada em múltiplas bacias; sensibilidade a parâmetros meteorológicos
45	Previsão operacional; apoio à gestão de recursos hídricos; mitigação de inundações	Média dados e metodologia detalhados; código não disponível	Médio Base de dados única; ausência de validação cruzada e de incerteza quantitativa explícita
46	Gestão de recursos hídricos; previsão de vazão; mitigação de inundações	Média descrição detalhada, mas sem disponibilização de código/dados	Médio Base única; sem validação externa; calibração local e dependência de dados hidrométricos

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
47	Sistema de alerta; controle do túnel SMART em Kuala Lumpur; apoio à gestão de inundações	Baixa dados não públicos; necessidade de solicitação aos autores	Médio Dados limitados a uma única bacia; ausência de validação externa; variação de qualidade dos sensores
48	alerta operacional de vazão; apoio à gestão de recursos hídricos; otimização de operações de reservatórios; medidas de conservação de água e fauna; mitigação de efeitos de mudança climática	Média descrição detalhada; dados públicos de origem, previsões serão disponibilizadas; sem código aberto declarado	Médio Dados e previsões limitados (apenas duas estações para GFS); sem validação externa explícita; forte dependência da qualidade dos dados e de escolhas de hiperparâmetros
49	Previsão operacional de vazão; apoio à mitigação de inundações; gestão de recursos hídricos	Média metodologia detalhada, mas sem código ou dados anexos	Baixo Dados públicos e longas séries temporais; validação explícita e comparativa robusta
50	Previsão de inundações em bacias com poucos dados; apoio à gestão hídrica; mitigação de desastres	Média metodologia completa, mas dados são confidenciais	Baixo Conjunto amplo de bacias; métricas robustas; melhora consistente com transferência entre regiões
51	Gestão de recursos hídricos; preparação para desastres; suporte a previsões hidrometeorológicas sub-sazonais operacionais	Alta código e dados declarados como disponíveis; metodologia e períodos de calibração/validação detalhados	Baixo Série longa (1981–2019); teste fora da amostra (2016–2019); uso de métricas determinísticas e probabilísticas; comparação contra baselines (EC; QM; XAJ)
52	Previsão operacional de inundações; apoio à tomada de decisão	Média metodologia detalhada; código não disponibilizado	Baixo Uso de múltiplos modelos e validação operacional real em ambiente governamental
53	Gestão operacional de reservatórios; mitigação de riscos de inundação	Média descrição detalhada da metodologia, mas sem código ou dados abertos	Baixo Base de dados extensa (13 anos) e erro quantificado com resultados consistentes
54	Alerta precoce; apoio à tomada de decisão	Baixa sem código/dados públicos; descrição focada no caso e nos resultados	Médio Estudo baseado em duas estações e poucos eventos de teste; seleção de intervalos específicos; ausência de validação externa
55	Previsão operacional de nível d'água urbano; controle de inundações	Alta protocolo detalhado, dados descritos, mas sem código aberto	Baixo Base de dados extensa; validação cruzada robusta; múltiplos testes e métricas consistentes
56	Previsão; modelagem de rotas de inundações em canais naturais	Alta parâmetros detalhados; equações explícitas; software identificado	Baixo múltiplas métricas, comparações e replicação numérica possível
57	Previsão operacional em tempo real; alerta antecipado de inundações	Alta protocolo detalhado; dados identificados; métricas e parâmetros completos	Baixo ampla base de dados; múltiplas métricas; validação cruzada e comparação robusta
58	Sistema operacional de alerta em tempo real; gestão de riscos	Alta código TensorFlow, dados ERA5/SNIRH públicos, parâmetros detalhados, OpenDA documentado	Baixo Séries longas e múltiplos eventos testados; validação temporal e multifonte; sem indicativos de viés amostral significativo
59	Previsão de inundações; apoio à gestão de recursos hídricos	Alta dados e parâmetros descritos detalhadamente e reprodutíveis com base nas equações e tabelas fornecidas	Baixo modelo validado em duas estações e base extensa, com métricas consistentes
60	Planejamento agrícola; mitigação de inundações	Média metodologia descrita, mas sem disponibilização de código ou dados abertos	Baixo múltiplas métricas; longo período de dados; comparação entre modelos e validação temporal robusta
61	Apoio à previsão operacional de vazão; mitigação de inundações	Média metodologia e métricas detalhadas; dados MOPEX públicos; sem código ou ferramentas explicitadas	Baixo Séries longas e múltiplas bacias; comparação sistemática com baselines; sem indícios de viés amostral explícito no texto

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
62	Sistema de suporte à decisão; alerta precoce; gestão de riscos; mitigação de risco de inundações	Alta código em Python disponível no suplemento; metodologia e parâmetros descritos em detalhe	Baixo Ampla base de dados; validação cruzada; métricas transparentes e detalhadas
63	Alerta precoce; apoio à logística humanitária; planejamento de resposta	Média bibliotecas e fontes de dados descritas; sem código disponível	Médio Período curto; métricas perfeitas sem validação externa; divisão treino-teste não especificada
64	Apoio à gestão de risco; alerta precoce; planejamento e resposta emergencial	Média descrição detalhada de algoritmos e métricas; sem código público	Baixo Ampla base temporal (1987–2023); validação cruzada robusta; comparação múltipla de modelos reduz viés
65	Gestão de recursos hídricos; planejamento turístico sustentável	Média metodologia bem descrita; dados fechados por órgãos estatais	Médio Dados restritos; validação limitada a um único lago e ausência de replicação externa
66	Previsão operacional de inundações extremas; alerta antecipado	Alta dados públicos ECMWF; parâmetros e métricas detalhados	Baixo Ampla base temporal e validação quantitativa robusta; métodos comparativos e métricas bem documentadas
67	Previsão operacional em tempo real; alerta de inundações para mitigação de desastres	Média metodologia detalhada, sem código ou dados abertos	Médio conjunto de dados único e ausência de validação externa reduzem robustez
68	Previsão de vazão diária para apoio à previsão de inundações; gestão de eventos	Média metodologia e hiperparâmetros descritos; sem código/dados abertos no corpo do artigo	Médio Estudo de caso único (União da Vitória/Iguaçu); sem validação externa; horizonte curto (1 dia)
69	previsão de inundações; previsão de secas; mitigação de desastres; gestão de recursos hídricos	Média metodologia detalhada, mas sem código ou dados abertos	Médio Estudos em duas bacias; sem validação cruzada externa; restrição temporal curta
70	Gestão de recursos hídricos; previsão de inundações	Média descrição detalhada de métodos, mas sem código público	Baixo uso de dados reais, múltiplas estações e validação temporal reduzem viés
71	Planejamento de prevenção; controle de inundações; previsão operacional de vazão	Média descrição dos modelos; métricas e cenários; sem código/dados abertos	Médio Um único rio; validação apenas temporal; sem validação externa explícita
72	alerta e previsão de inundações de curto prazo; apoio à gestão	Média descrição razoável dos esquemas/modelos; sem código/dados abertos declarados	Médio Estudo de caso único (março/2016) e sem validação externa explícita
73	Gestão de risco de inundação; suporte à decisão	Média metodologia detalhada, porém dados restritos e sem disponibilização pública	Baixo validação temporal e métricas múltiplas reduzem risco de viés
74	Previsão de inundações; modelagem de chuva-vazão	Média descrição completa da metodologia mas sem código público	Baixo validação temporal com múltiplos eventos e bom desempenho reduzem risco de viés
75	Planejamento e operação de reservatórios; mitigação de riscos de inundação	Alta detalhamento completo de parâmetros, equações e dados utilizados	Baixo uso de múltiplas divisões de dados e métricas objetivas reduz risco de viés
76	Previsão operacional de vazão e inundações; apoio à gestão de reservatórios; mitigação de secas	Média descrição detalhada dos métodos, sem código/dados abertos	Baixo Validação cruzada adequada em duas estações; bons indicadores de ajuste; sem indícios de overfitting
77	Previsão de inundações; apoio à gestão de riscos; operação de reservatórios	Média metodologia detalhada mas sem disponibilização de código ou dados	Baixo uso de múltiplas métricas e comparação cruzada entre modelos reduz risco de viés
78	Estimativa regional de inundações de projeto; apoio ao planejamento; gestão de risco de inundação	Média métodos e variáveis descritos; sem código/dados abertos completos	Médio Amostragem aleatória 80/20 sem validação externa; estudo restrito a uma região específica
79	Operação de reservatórios; Controle de inundações	Média métodos e variáveis descritos; sem código/dados abertos completos	Médio sem validação externa; período dos dados não informado
80	Sistema de alerta de inundações; previsão de curto a médio prazo	Média dados detalhados e uso de ferramentas conhecidas, mas sem código aberto	Médio base de dados pequena e sem validação externa

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
81	Previsão de inundações em pequenas bacias montanhosas; sistemas de alerta; resposta emergencial	Média dados e metodologia detalhados, mas sem código ou dados abertos	Baixo Validação temporal e comparação quantitativa consistente; sem sinais de sobreajuste ou viés amostral
82	Sistema IoT de alerta; previsão antecipada de inundações	Média descrição detalhada de sensores e arquitetura, mas sem código ou dados públicos	Médio modelo preliminar; dados históricos limitados; sem validação física
83	Previsão operacional de inundações; suporte ao sistema de alerta	Média metodologia detalhada, mas sem código ou dados públicos	Médio base pequena e heterogênea; sem validação externa completa
84	alerta precoce de inundação; previsão de inundações	Média descrição detalhada de sensores e arquitetura, mas sem código ou dados públicos	Médio Um único local (2015); divisão simples treino/teste; sem validação externa; sem comparação com outros modelos
85	apoio à gestão; planejamento; previsão operacional	Média descrição razoável, sem código/dados completos	Médio O artigo não especifica a estratégia de validação e não fornece dados ou código aberto
86	Previsão em tempo real de vazão; alerta precoce; apoio à gestão de inundações	Média descrição razoável de métodos e dados, mas sem código ou dados públicos	Médio Conjunto de dados pequeno e restrito à China; sem validação externa
87	Alerta precoce; previsão em tempo real; gestão de risco de inundações	Média descrição detalhada dos métodos e calibração, porém sem código ou dados públicos	Baixo Ampla calibração e validação; dados e metodologia bem descritos, reduzindo viés significativo
88	alerta precoce; informação ao usuário via aplicativo Android; previsão e status de inundação	Média descrição do método, parâmetros e fonte de dados; sem código ou dados abertos	Médio Único estudo em uma bacia; divisão 50/50 sem validação externa; sem comparação com outros modelos
89	sistema de alerta precoce; apoio na tomada decisões; preparação contra riscos de inundação	Média descrição metodológica razoável; sem código/dados abertos	Médio dados de uma única bacia; sem validação externa
90	Previsão operacional; alerta precoce de nível d'água	Alta protocolos, equações e parâmetros detalhados, dados com origem e período especificados	Baixo Base de dados extensa (17 anos) e validação cruzada documentada
91	Previsão operacional; alerta precoce; suporte à gestão de risco de inundações	Média protocolos e dados bem descritos, porém sem código público	Baixo Dados amplos (13 anos), validação temporal e metodologia documentada
92	Apoio à gestão de recursos hídricos; operação de barragens; alerta precoce; gestão de secas; planejamento de infraestrutura	Média dados e S1 Data disponibilizados; sem código	Médio Estudo de um único caso; sem validação externa; fonte de dados local; entradas restritas à vazão defasada
93	Alerta precoce; apoio à decisão em transporte; previsão operacional em tempo real	Média descrição detalhada, mas sem código/dados abertos	Baixo Modelos avaliados em múltiplos eventos e ruas com boa validação cruzada e comparação com modelo físico (TUFLOW)
94	Alerta precoce; previsão operacional em tempo quase real; apoio à gestão de risco	Alta metodologia detalhada; dados disponíveis mediante solicitação	Baixo Dados hidrodinâmicos e estatísticos robustos; validação cruzada e comparação sistemática indicam baixa probabilidade de viés
95	Sistema de alerta de inundações; previsão operacional diária	Média metodologia bem detalhada e parâmetros reproduzíveis, mas sem dados/código públicos	Médio Série curta e restrita a dois pontos de medição; sem validação espacial externa
96	previsão adaptativa de inundações; previsão operacional em gêmeo digital; preparação para desastres	Alta código aberto no GitHub	Médio Ausência de detalhes claros sobre validação externa e escopo/área de estudo nos trechos disponíveis
97	Alerta precoce; previsões operacionais públicas em tempo real	Alta dados de reanálise/reprevisões e modelos/figuras disponibilizados; protocolo detalhado	Baixo Validação out-of-sample no tempo e no espaço; múltiplos esquemas de cross-validation; comparação conservadora com benchmark calibrado

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
98	previsão de inundações; sistema de alerta precoce; gestão de recursos hídricos	Média descrição do método e ambiente computacional; sem código/dados abertos declarados	Médio Dados principais de uma estação; validação concentrada em bacias chinesas; ausência de código/dados públicos declarados
99	Previsão operacional em tempo real para pequenas bacias; apoio à gestão hídrica	Alta uso de TensorFlow; parâmetros, fórmulas e fontes de dados detalhadas	Baixo Dependência de dados locais; ausência de validação externa; interpretabilidade limitada dos resultados
100	Previsão de vazão horária; apoio à gestão de risco de inundação	Média protocolo detalhado, mas ausência de código e dados abertos	Baixo Comparação com múltiplos modelos; série longa e métricas robustas; porém sem validação externa
101	Alerta precoce de inundações; apoio operacional à gestão urbana	Média descrição detalha dados; arquitetura e parâmetros do MLP; sem código/dados públicos	Médio Dados de uma única cidade; ~7 meses; sem validação externa; número limitado de sensores e variáveis efetivamente usadas no modelo
102	Alerta precoce; previsão operacional de nível d'água; apoio à gestão de inundações	Média parâmetros e partições descritos; sem código/dados abertos	Médio Único rio/local; validação apenas temporal 80/20; sem validação externa
103	Alerta precoce; previsão de severidade de inundações; apoio à mitigação e preparação	Média descrição do método, métricas e fontes; sem código/dados completos disponibilizados	Médio Sem validação externa; rótulos discretos vs. saídas contínuas; possível desequilíbrio e viés nos dados
104	Previsão e antecipação de inundação; integração em sistemas de alerta precoce multiriscos	Média metodologia detalhada, uso de ferramentas e dados oficiais; sem código ou dados abertos declarados	Médio Aplicado em uma única bacia; ausência de validação externa; dependência de parâmetros ajustados e dados locais
105	Prevenção de inundações; avaliação de risco iminente; apoio à mitigação de inundações	Média metodologia e dados descritos; sem código/dados abertos	Médio Avaliado em duas bacias sem validação externa; ausência de código pode indicar risco de sobreajuste
106	previsão de inundações em tempo real; operação de reservatório; escalonamento de controle de inundações; gestão de recursos hídricos	Média descrição razoável; bibliotecas declaradas; dados "disponíveis sob solicitação"; sem código aberto explícito	Médio Estudo em uma única bacia; sem validação externa; entradas limitadas; flutuação de desempenho no teste
107	Gestão operacional de recursos hídricos; previsão diária de inundações	Média dados e metodologia descritos, sem código ou base abertos	Médio Validação temporal adequada, mas conjunto único e ausência de código limitam replicação
108	Alerta precoce de inundações urbanas; previsão operacional em tempo real	Alta protocolo detalhado; parâmetros completos e acesso a dados instrumentais descritos	Baixo Uso de dados reais contínuos; validação cruzada robusta; sem indícios de viés experimental
109	Previsão de vazão; operação de reservatórios; alerta hidrológico	Média descrição metodológica completa, mas sem código ou dados abertos	Médio Conjunto pequeno; um único ponto de medição; validação limitada a uma bacia
110	Previsão de inundações; sistemas de alerta; suporte à gestão de riscos	Alta descrição detalhada de parâmetros, datasets e arquitetura, com tabelas completas	Médio Conjuntos limitados a três bacias; ausência de validação cruzada externa
111	Previsão de inundações; apoio à gestão hídrica	Alta parâmetros, datasets e configuração detalhados; dados disponíveis mediante solicitação	Médio Dependência de uma única estação e ausência de validação externa completa
112	sistema de alerta precoce; detecção de futuras inundações; suporte à gestão de desastres	Média descrição metodológica e métricas apresentadas, sem disponibilização explícita de código/dados	Médio Dados desbalanceados; ausência de validação externa/lugares específicos declarados no conjunto

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
113	alerta precoce de inundações; previsão operacional; apoio à gestão de riscos	Média descrição detalhada de dados/métodos e hiperparâmetros; sem código/dados abertos	Médio Estudo em 4 bacias na Carolina do Sul; sem validação externa; NWM não calibrado localmente
114	Apoio à gestão ambiental; Apoio à gestão de inundações	Alta descrição detalhada de metodologia, dados simulados e configuração de rede	Baixo Dados simulados bem controlados e validação cruzada robusta
115	Alerta rápido; apoio à gestão e tomada de decisão; estratégias de mitigação de inundações	Baixa dados não públicos; contactar autor; ausência de código/detalhes completos	Médio Estudo focado em um único rio; validação não descrita; dados não públicos
116	Previsão operacional; alerta de inundações; apoio à gestão de riscos	Alta descrição detalhada de dados, predição e métricas	Baixo Conjunto de dados extenso; validação temporal robusta; métricas múltiplas e consistentes
117	previsão rápida de risco de inundação; alerta precoce; apoio à gestão; mapeamento de risco	Média metodologia detalhada; sem código/dados abertos explícitos	Médio Uso extensivo de cenários de projeto e poucos dados medidos; sem validação externa independente
118	sistemas de alerta precoce; previsão em tempo real; apoio à tomada de decisão em gestão de risco de inundações	Média dados descritos e métricas completas; sem código disponibilizado explícito	Médio Dados esparsos; sem validação externa; período curto (mensal 2012–2017)
119	Gerenciamento de risco de inundações; Sistema de alerta precoce	Alta descrição detalhada de dados, predição e métricas	Baixo Conjunto de dados extenso; validação temporal robusta; múltiplas métricas
120	Alerta precoce; previsão operacional de inundações em pequenas bacias	Alta descrição detalhada de dados, parâmetros e metodologia	Baixo Ampla base de dados multidimensional; validação robusta e comparação entre modelos
121	Previsão de níveis de inundação; apoio a políticas de mitigação de inundações	Alta metodologia detalhada, fórmulas explícitas e dados de fonte pública	Baixo Conjunto amplo (48 estados); validação cruzada robusta; múltiplas métricas quantitativas
122	previsão de afluência ao reservatório em eventos de tufão; apoio à operação de reservatórios; controle de inundações; gestão e planejamento de recursos hídricos	Média descrição detalhada do método; dados “mediante solicitação”; sem código aberto	Médio Única bacia; 13 eventos; sem validação externa independente; parâmetros de correção fixos no tempo.
123	operação de reservatórios; mitigação de inundações e secas; gestão e planejamento de recursos hídricos; controle de inundações; gestão ambiental	Alta Software and data availability declarado: “HydroForecast-SHAPGPR”; código/dados informados no texto	Médio estudo de um único caso (Yalong River Basin) e ausência de validação externa explícita.
124	Sistema de alerta de inundações; previsão operacional	Alta dados públicos ANA, SGB, PDIRnow; metodologia detalhada e reprodutível	Baixo Ampla base temporal e espacial; validação cruzada e teste independente robustos
125	Operação de reservatórios; gestão de recursos hídricos; irrigação; geração hidrelétrica; alerta a estresses ambientais	Média descrição de métodos e métricas; sem código/dados abertos	Médio Dados de um único sistema (AHD); sem validação externa; particionamentos distintos entre modelos
126	Gestão e operação de reservatórios; previsão de vazão; mitigação de inundações	Média descrição detalhada, mas sem disponibilização de dados ou código	Baixo Dados extensos e validação cruzada com três estações; desempenho consistente entre algoritmos
127	Previsão antecipada; mitigação de inundações; suporte ao planejamento hídrico	Média metodologia e métricas detalhadas, mas sem código ou dados abertos	Baixo Amostra extensa (24 estações); múltiplos experimentos e métricas; validação cruzada robusta
128	Apoio à gestão de inundações; operação de reservatórios; previsão de vazão em tempo real	Média dados e código parcialmente abertos; descrição detalhada de parâmetros	Baixo Estudos em duas bacias; comparação quantitativa; métricas múltiplas e transparência na metodologia
129	previsão/alerta de inundações; apoio a departamentos de controle de inundações	Média descrição do modelo e parâmetros; fontes de dados indicadas; sem código/dados abertos completos	Médio Estudo de caso único; preenchimento de dados faltantes; sem validação externa

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
130	Monitoramento de inundações; apoio à gestão; operação de dispositivos de mitigação de inundação	Média descrição metodológica detalhada; dados institucionais sem código/dados abertos; validação não explicitada	Médio Três eventos em rios de uma mesma região; sem validação externa reportada
131	Previsão de inundações; modelagem hidrológica em tempo real; apoio à gestão; mitigação de inundações	Média detalhamento completo de equações, dados e protocolos, sem código público	Baixo Base sintética e real validadas; parâmetros físicos consistentes; métricas bem documentadas
132	Previsão de inundações; segurança de barragens; mitigação de riscos; suporte à gestão de recursos hídricos	Média descrição detalhada de métodos e métricas; dados "on request"; sem código aberto	Médio Seleção de eventos extremos; amostras limitadas (p.ex., 360 pontos para Lake Carl Blackwell); sem validação externa multi-região
133	Prevenção de inundações; apoio à gestão de recursos hídricos; planejamento e operação	Média dados da WSC e configuração do ANFIS detalhadas; sem código disponibilizado	Médio Bacia única; sem validação externa; apenas vazão como entrada; diferença calibração/validação mencionada como potencial limitação
134	Previsão mensal de inundações; suporte à gestão hídrica; mitigação de desastres	Média dados e metodologia detalhados; código sob solicitação	Baixo Dados extensos (50 anos); duas estações; validação temporal explícita; métricas robustas
135	Gestão de risco de inundações e secas; planejamento de recursos hídricos; produção de energia elétrica; projeto de infraestrutura urbana; irrigação	Média descrição do procedimento e divisão de dados; sem código/dados abertos declarados	Médio único posto e período limitado; sem validação externa explícita
136	alerta precoce de inundações; previsão operacional; apoio à gestão de risco de inundação	Alta dados públicos CAMELS/ERA5-Land/ECMWF-IFS e código aberto disponibilizado	Médio Estudo concentrado em CONUS; sensível à qualidade da previsão de precipitação; aplicação a bacias grandes indicada como futura
137	Previsão local de inundações; alerta precoce; mitigação	Média descrição técnica detalhada, sem divulgação de código/dados	Baixo Modelo validado com métricas quantitativas; amostragem representativa limitada
138	gestão e controle de recursos hídricos; mitigação de desastres por inundação	Média descrição razoável; dados comprados; sem código/dados abertos	Médio dados limitados; omissão de estações; ausência de validação externa; resultados sensíveis à correção de viés
139	Previsão de inundações em tempo real; suporte a sistemas de alerta em eventos de tufão	Média descrição detalhada do método e dados, mas sem disponibilização pública dos dados	Baixo Modelos comparados quantitativamente; validação com dados reais; resultados consistentes
140	Previsão de nível do rio em tempo real; apoio a sistemas de alerta de inundação	Média metodologia detalhada, sem código público	Baixo validação quantitativa, múltiplas métricas e análise comparativa robusta
141	Previsão operacional de inundações; alerta de curto prazo; suporte à gestão hídrica	Alta código, parâmetros e bibliotecas declarados; dados e metodologia detalhados	Baixo Modelos bem validados; dados extensos; validação cruzada entre bacias reduziu risco de viés
142	Alerta precoce de inundações; monitoramento em tempo real	Alta código, parâmetros e equações fornecidos; dados e períodos declarados	Médio Dados de uma única estação; ausência de validação externa multirregional
143	Alerta de inundação; previsão operacional; integração em sistemas IoT hidrológicos	Alta dados e scripts descritos; parâmetros; fórmulas; conjuntos públicos	Baixo Dados amplos; validação cruzada; dois conjuntos independentes; descrição detalhada de métodos e métricas
144	Previsão e monitoramento de inundações; suporte à gestão hídrica	Alta dados, parâmetros e critérios estatísticos descritos detalhadamente	Baixo Dados extensos; validação com 9 eventos; métodos e métricas documentados
145	prevenção de desastres; uso eficiente de recursos hídricos; planejamento de obras hídricas	Média descrição de dados; divisão treino/teste e arquitetura; sem código	Médio único rio; 1095 dias; sem validação externa; picos de cheia pouco representados

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
146	Previsão inundações; suporte a alertas precoces; gestão de recursos hídricos	Alta Dados e métodos descritos detalhadamente; ferramentas open source; métricas completas	Baixo Conjunto de dados amplo; múltiplos testes e validação cruzada; baixo risco de sobreajuste
147	Previsão operacional de vazão; alerta de inundações	Alta arquitetura, dados e métricas detalhadas	Baixo Uso de validação temporal e múltiplas métricas quantitativas robustas
148	gestão e alocação de recursos hídricos; operação de engenharia hidráulica; prevenção de desastres de inundações e secas	Média descrição detalhada do método; fontes de dados citadas; dados “disponíveis sob solicitação”; sem código aberto	Médio Estudo em uma única bacia; sem validação externa; amostra de cheias escassa; não considera regulação antrópica pós-2013
149	Alerta e controle de inundações; Previsão operacional; Apoio à gestão de recursos hídricos; segurança hídrica; irrigação; operação de reservatórios	Média descrição do método e divisões de dados; sem código aberto; dados “disponíveis sob solicitação”	Médio Aplicação em uma única bacia com validação interna; ausência de validação externa; dados de 10 estações em um único sistema
150	Previsão operacional de inundações; apoio à gestão de risco	Alta modelo, parâmetros e métricas totalmente descritos	Baixo Três conjuntos de dados reais; validação cruzada robusta; comparações detalhadas
151	Gerenciamento de inundações em bacias	Baixa dados não públicos; ausência de código; validação incompleta	Médio Sem validação externa; dados limitados; validação não descrita explicitamente
152	previsão operacional de inundações; alerta e apoio à decisão; análise do estado do rio	Média código aberto; dados completos sob licença; protocolo descrito	Médio Validação em 10 postos de uma única bacia; dados proprietários; sem validação externa
153	alerta precoce; mitigação de inundações; apoio ao planejamento; gestão de recursos hídricos	Média descrição metodológica detalhada; uso de WEKA; sem código/dados abertos	Médio Única bacia; sem validação externa entre bacias; possível sobreajuste mitigado por ensembles
154	Previsão operacional; alerta de inundações	Alta dados e parâmetros bem descritos	Baixo Conjunto de dados bem definido; validação cruzada aplicada; comparação entre três modelos robustos
155	Gestão e previsão de recursos hídricos; suporte a medidas de mitigação de inundações	Alta dados e código disponíveis mediante solicitação; descrição detalhada do protocolo	Baixo Conjunto de dados robusto; validação cruzada clara; múltiplos modelos comparativos
156	Gestão de recursos hídricos; mitigação de secas e inundações; apoio ao planejamento estratégico	Alta dados públicos e protocolos detalhados	Baixo Dados abertos; validação robusta; comparação com múltiplos modelos e análise de sensibilidade de variáveis
157	previsão de vazão	Média descrição de arquitetura/hiperparâmetros e métricas; sem código/dados abertos declarados	Médio Dois locais australianos; entrada apenas de vazão; sem validação externa explícita no texto
158	controle de inundações; mitigação de desastres; gestão de recursos hídricos; alocação de água	Média descrição razoável do método e critérios; sem código/dados explicitados	Médio Estudo em uma única estação; sem validação externa; dependência de uma série histórica única
159	Gestão de reservatórios; previsão de inundações; operação hídrica	Alta dados públicos, metodologia e hiperparâmetros detalhados	Baixo Série longa (2006–2020); validação robusta; NSE > 0.9 em múltiplos períodos
160	Previsão de inundações; gestão de reservatórios; planejamento hídrico regional	Alta dados, fórmulas e parâmetros detalhados	Baixo Série temporal extensa; validação cruzada robusta; redução de erro e incerteza bem documentadas
161	Previsão nacional de condições fluviais; alerta precoce; gestão de riscos de inundação	Alta dados abertos do DEFRA e descrição completa dos parâmetros	Baixo Uso de base pública; métricas robustas; validação cruzada explícita
162	otimização da gestão de recursos hídricos; operações de reservatórios; manejo de bacias; gestão urbana da água	Média procedimentos e divisão descritos; ferramentas informadas; sem código/dados abertos	Médio Única bacia; período sazonal limitado; sem validação externa; erros em extremos

ID	Aplicação Prática	Reprodutibilidade	Risco de Viés
163	Apoio à previsão de inundações; apoio à gestão	Média metodologia e variáveis bem descritas, mas sem código ou dados públicos	Médio Amostra limitada e sem validação cruzada externa
164	Previsão de inundações repentinas; alerta precoce; apoio à evacuação e interrupção de tráfego	Média dados e protocolo detalhados; ausência de código público	Baixo Base de dados extensa; validação cruzada rigorosa; incerteza e overfitting mitigados com regularização
165	sistema de alerta precoce; operação de reservatórios; geração de energia hidrelétrica; mitigação e controle de inundações; gestão de recursos hídricos	Média arquitetura e hiperparâmetros descritos; sem código disponibilizado	Médio 10 bacias MOPEX de uma região; sem validação externa independente.
166	sistema de alerta precoce; sistema de monitoramento de inundações	Média dados abertos citados; sem código; descrição razoável do procedimento	Médio Um único conjunto de dados (RBD) e apenas validação cruzada interna; sem validação externa
167	Previsão probabilística de inundações; suporte à gestão de riscos; prevenção de desastres hídricos	Média metodologia detalhada, mas sem código ou dados abertos	Médio Base restrita a uma bacia e ausência de validação cruzada geográfica
168	Alerta precoce; previsão operacional; apoio à gestão de desastres	Média metodologia detalhada, mas sem código/dados abertos	Médio Conjunto de dados restrito a uma bacia; sem validação cruzada geográfica
169	Sistema de alerta precoce; gestão de drenagem urbana; mitigação de desastres	Média descrição detalhada de modelos e parâmetros, mas sem código/dados públicos	Médio Dados limitados e ausência de validação externa quantitativa
170	Alerta e previsão antecipada para apoiar planos de emergência; redução de danos	Média descrição do método e métricas; uso de MATLAB; sem código/dados abertos	Médio Amostra restrita a 5 estações; divisão 70/30 sem validação externa; limitações computacionais
171	Apoio à previsão de inundações; determinação da resposta da bacia	Média descrição detalhada; dados “disponíveis sob solicitação”; sem código aberto declarado	Médio Ambiente virtual sintético; sem validação externa; desempenho depende de conhecimento/qualidade da chuva futura
172	Gestão de risco de inundação; planejamento urbano; alerta precoce	Média metodologia detalhada e métricas explícitas, mas dados não disponíveis publicamente	Médio Ausência de dados públicos e validação restrita à bacia do Ouémé
173	Previsão de nível d'água operacional; apoio à navegação; planejamento e segurança de vias navegáveis	Média metodologia e resultados detalhados, mas sem disponibilização de código ou dados	Baixo Base de dados extensa; validação robusta e comparação entre múltiplos modelos
174	Previsão de inundações; operação hidrelétrica; apoio à gestão de recursos hídricos	Média metodologia detalhada e dados parcialmente acessíveis sob política de agência	Baixo Grande base de dados; validação robusta; métricas consistentes