

O papel da inteligência artificial no avanço da previsão de extremos de tempo e clima: Sistema Inteligente de Previsão de Extremos Climáticos

Paulo Nobre¹, Alessandra Cristina Corsi², Marcel Rodrigues de Barros³, Francisco José Lopes de Lima⁴,
Thalyta Soares dos Santos⁵, Werner Conrado Jacob Denzin⁶, Felipe Pacheco de Almeida Euphrásio⁷,
Jorge Luis Gomes⁸, Aline Fernandes Heleno⁹, Wanderley Oliveira Mendes¹⁰, Thierry Pinheiro
Moreira¹¹, Fábio José Muneratti Ortega¹², Diogo Nunes da Silva Ramos¹³, Leonardo B. L. Santos¹⁴,
Allan Rodrigues Silva¹⁵, Felipe Silva Silles¹⁶, Denis Bruno Viríssimo¹⁷, André Brasil Vieira¹⁸

Resumo

Diante do crescimento exponencial na frequência e intensidade de extremos climáticos em todos os continentes, crescimento este decorrente do

Abstract

Given the exponential growth in the frequency and intensity of extreme weather events on all continents, a growth due to global

-
- 1 PhD, climatologista, cientista sênior. Instituto Nacional de Pesquisas Espaciais (Inpe).
 - 2 Geóloga, pesquisadora. Instituto de Pesquisas Tecnológicas (IPT).
 - 3 Engenheiro de computação, pós-doutorando em Aprendizado de Máquina pela Escola Politécnica da Universidade de São Paulo (USP).
 - 4 PhD, meteorologista, pesquisador. Serviço Nacional de Aprendizagem Industrial/Centro Integrado de Manufatura e Tecnologia (Senai Cimatec).
 - 5 Doutora, meteorologista, pesquisadora. Senai Cimatec.
 - 6 Bacharel em Ciência da Computação, consultor técnico de *software*, SiDi.
 - 7 Engenheiro de Controle e Automação, bolsista. IPT.
 - 8 Doutor em Meteorologia. Inpe.
 - 9 Pesquisadora. IPT.
 - 10 Analista de sistemas. Consultor de TI – Programa Sipec.
 - 11 PhD, visão computacional, consultor técnico. SiDi.
 - 12 Engenheiro de Computação, pós-doutorando em Aprendizado de Máquina. Centro de Investigação em Agricultura Avançada e Mudanças Climáticas (Ciaam) da USP.
 - 13 PhD, meteorologista, pesquisador, Senai Cimatec.
 - 14 Pesquisador titular. Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden).
 - 15 Doutor, meteorologista, pesquisador. Senai Cimatec.
 - 16 Engenheiro de *Software*, pesquisador. IPT.
 - 17 Engenheiro de *Software*, pesquisador. IPT.
 - 18 Doutor em Ciência da Computação, pós-doutorados em Simulação Molecular (*Drug Discovery*), Biometria e Genética de Plantas, pesquisador. Senai Cimatec.

aquecimento global resultante do acúmulo de gases de efeito estufa na atmosfera, faz-se mister desenvolver a capacidade de previsão de tais extremos climáticos com maior antecedência e acurácia. Este artigo posiciona o estado da arte na capacidade prognóstica de anomalias climáticas com até um ano de antecedência pelo Modelo Brasileiro do Sistema Terrestre (BESM) e sugere caminhos de aprimoramento de tal capacidade por meio de técnicas de inteligência artificial.

Palavras-chave: Clima. Extremos climáticos. Inteligência artificial aplicada à previsão climática. Crise ambiental. Impactos ambientais. Modelagem acoplada oceano-atmosfera. Ciência e tecnologia. Previsão sazonal.

warming resulting from the accumulation of greenhouse gases in the atmosphere, it is essential to develop the ability to predict such extreme weather and climate events with greater advance and accuracy. This article presents the state of the art in the ability to predict climate anomalies with earth system models up to one year in advance and suggests ways to improve this ability through Artificial Intelligence techniques.

Keywords: Climate. Extreme climate. Artificial intelligence applied to climate prediction. Environmental crisis. Environmental impacts. Ocean-atmosphere coupled model. Science and technology. Seasonal forecast.

1. Introdução

Diante do gradual, porém persistente, aumento da concentração de gases de efeito estufa (GEE) na atmosfera global – que em 2024 ultrapassou a marca histórica de 420 ppmv, acompanhado do aumento das temperaturas da superfície dos oceanos, observado globalmente desde o início do século passado e que, em 2023, apresentou aumento médio global inédito e diante do aumento na frequência e intensidade de eventos climáticos extremos sem precedentes no Brasil e no mundo –, torna-se premente o desenvolvimento de metodologias capazes de prever tais fenômenos com maior antecedência e acurácia.

As técnicas de inteligência artificial (IA) [do Inglês, *artificial intelligence*], que vêm avançando rapidamente mundialmente, aliadas aos modelos clássicos de previsão do tempo e do clima, representam uma abordagem promissora que merece ser investigada com profundidade (Lam *et al.*, 2023). O desafio em aumentar a antecedência com a qual extremos climáticos são previstos reveste-se de especial importância nesse momento de crescimento exponencial de eventos climáticos extremos. Tal desafio é confrontado aqui pela combinação de técnicas de IA e modelagem numérica do sistema terrestre.

A precipitação é uma variável crítica para diversos setores econômicos e da sociedade em geral, mas, ao mesmo tempo, uma das mais complexas de serem previstas em modelos de circulação geral da

atmosfera (GCM) [do Inglês, *global circulation model*]. Tais modelos, como o BESM, possuem erros sistemáticos em suas previsões que precisam ser ajustados. Para mitigar esse desafio, abordagens de correção de viés foram desenvolvidas – desde técnicas estatísticas clássicas (Maraun; Widmann, 2018) até algoritmos de IA (Chantry *et al.*, 2021). Recentes avanços em modelos generativos para problemas de aprendizado profundo têm demonstrado progressos promissores. Entre estes, os modelos probabilísticos de difusão com modelos probabilísticos de difusão para redução de ruído (DDPM), [do Inglês *denoising diffusion probabilistic models*] (Ho *et al.*, 2020) demonstraram desempenho notável na geração de dados complexos em ciências atmosféricas (Price *et al.*, 2025; Li *et al.*, 2024; Mardani *et al.*, 2025). Entretanto, pesquisas específicas para o pós-processamento e a correção de viés de GCM permanecem praticamente inexploradas.

Eventos climáticos extremos que geram chuvas intensas podem deflagrar diversos processos, como escorregamentos e inundações, com graves consequências nas cidades e com impactos sociais, ambientais e econômicos.

O evento ocorrido em São Sebastião/SP, em fevereiro de 2023, foi marcado por precipitação intensa, com mais de 600 mm concentradas em menos de 24 horas (a pluviometria climatológica da região é de 300 mm/mês). As chuvas intensas provocaram diversos escorregamentos, resultando em 65 mortes (Marengo *et al.*, 2024). É importante destacar que levantamentos realizados em 2018 mostraram que o município possui 21 áreas com mais de 6.000 residências expostas a movimentos de massa e inundações (IPT, 2018). Outros eventos extremos climáticos recentes de magnitudes semelhantes, embora com dinâmicas distintas, foram registrados também em Santos e no Guarujá, em 2020, e na região metropolitana de Porto Alegre em 2024 (Valle *et al.*, 2022; Mantovani *et al.*, 2025).

Técnicas de IA demonstram notável capacidade de assimilação e processamento em tempo real de volumosos conjuntos de dados heterogêneos relacionados a eventos extremos, tais como dados meteorológicos, hidrológicos e urbanos (Materia *et al.*, 2023). Ao integrar fontes multifacetadas, como sensores ambientais, imagens de satélite multiespectrais, dados de estações meteorológicas e conteúdos derivados de plataformas digitais e redes sociais, os sistemas inteligentes promovem a identificação de padrões anômalos indicativos de iminentes eventos extremos (Neset *et al.*, 2024).

Este artigo descreve sinergias entre as técnicas de modelagem climática global a partir da integração numérica das equações de Navier-Stokes e das técnicas de IA desenvolvidas por grupos de *experts* no Brasil. Destarte, o artigo representa a primeira publicação conjunta, fruto da cooperação científica no âmbito do programa Sistema Inteligente para Previsão de Extremos Climáticos (Sipex), do Programa Brasileiro de Inteligência Artificial (PBlA). O artigo está estruturado como segue:

Primeiramente, descrevemos a evolução da previsão climática, como feito pela utilização do Modelo Brasileiro do Sistema Terrestre (BESM) [do Inglês, *Brazilian Earth System Model*] vinculados ao Instituto Nacional de Pesquisas Espaciais (Inpe) (Nobre *et al.*, 2013). Aqui, mostramos como a representação dinâmica de processos acoplados – oceano-atmosfera-criosfera-biosfera – permite prever o sinal de anomalias da pluviometria sobre uma grande região com meses de antecedência.

Então, exploramos a possibilidade do uso da combinação de algoritmos de IA para realizar um conjunto de tarefas, tais como: i) agregação de dados em conjunto de dados espacial e temporalmente esparsos; ii) remoção de erros sistemáticos por meio de técnicas de IA; iii) redução de escala espacial utilizando técnicas de IA a partir de previsões com baixa resolução espacial; e iv) detecção de eventos extremos de tempo e clima e seus impactos sobre as cidades. Em conclusão, indicamos alguns caminhos para estudos futuros.

2. Previsão climática a partir do Modelo Brasileiro do Sistema Terrestre (BESM)

O modelo BESM é o resultado do acoplamento do modelo atmosférico *Brazilian Global Atmospheric Model* (BAM) (Figuerola *et al.*, 2016) ao modelo oceânico *Modular Ocean Model version 6* (MOM6) por meio do acoplador *Flexible Modeling System* (FMS) da *National Oceanic and Atmospheric Administration/ Geophysical Fluid Dynamics Laboratory* (NOAA/GFDL). Integrados numericamente no tempo sobre uma grade global, representam os movimentos e as inter-relações entre a atmosfera, os oceanos, a vegetação e a cobertura de gelo. Esta seção descreve as características do modelo BESM para previsões climáticas sazonais e estudos de mudanças climáticas globais (Nobre *et al.*, 2013; 2023).

A Figura 1 mostra representações esquemáticas (a) dos passos para a inicialização acoplada oceano-atmosfera do modelo BESM e (b) sua integração no tempo via acoplador de fluxos FMS. A componente atmosférica do BESM é integrada numa grade horizontal com truncamento triangular no número de onda 62 (equivalente a ~200 Km) e 42 níveis sigma não igualmente espaçados na vertical (To62L42). A componente oceânica do BESM é integrada numa grade horizontal *lat-lon* com espaçamento uniforme de ¼ de grau e 63 níveis na vertical. As condições iniciais atmosféricas são provenientes do NOAA/*National Centers for Environment Prediction* (NCEP) [*Global Forecast System* – GFS] e oceânicas do Sistema Mercator da União Europeia. Os campos iniciais atmosféricos e oceânicos são equalizados pela integração em modo acoplado do BESM para gerar uma condição inicial para o modelo acoplado que, então, é integrado em modo prognóstico como indicado na Figura 1 (b), por 13 meses.




Figura 1 – Esquemático (a) da inicialização do modelo BESM (b) integração no tempo do modelo BESM
Fonte: Nobre et al. (2025, manuscrito em preparação).

A Figura 2 mostra histogramas das frequências de anomalias anuais de precipitação previstas e observadas sobre a bacia Amazônica para dois anos de contraste, 2024 (um ano de seca extrema) e 2008 (um ano de alta pluviosidade) sobre a Amazônia. É notável na Figura 2 que os sinais das anomalias – tanto negativas quanto positivas de precipitação sobre a bacia Amazônica – tenham sido previstos com um ano de antecedência, mostrando a capacidade de o modelo BESM prever desvios anuais de precipitação sobre a região. Não obstante, a previsão não captura os valores mais extremos dos eventos, isto é, a cauda das distribuições mostradas na Figura 2. Essa característica do modelo em representar as anomalias anuais de precipitação, sem contudo representar seus valores extremos está associada a diversos fatores, entre os quais: baixa resolução espacial e não resolução explícita dos processos físicos causadores da chuva, sendo esses contabilizados por meio de métodos paramétricos, entre outros.

Não obstante, tais resultados pioneiros na previsibilidade de anomalias pluviométricas regionais, com um ano de antecedência, representam um marco para a ciência de previsões de extremos climáticos. Os próximos passos na ciência de previsões de anomalias climáticas com antecedência de até um ano contemplam a utilização de técnicas complementares de IA, como exemplificadas nas seções que seguem neste artigo.




Figura 2 – Frequência relativa de anomalias anuais de precipitação média para a bacia Amazônica

Obs.: observada (linha tracejada) e prevista pelo modelo BESM com um ano de antecedência (sombreada em vermelho) para os períodos (a) para um ano de seca, de dezembro de 2023 a novembro de 2024; e (b) um ano chuvoso, de dezembro de 2007 a novembro de 2008.

Observações do *Global Precipitation Climatology Project* (GPCP) e previsão por conjunto do modelo BESM a partir de condições iniciais de 1-10 de novembro de 2023 e 2007, respectivamente nas figuras (a) e (b). Correção de viés por método da função de distribuição de probabilidade (PDF).

Fonte: Elaboração própria.

3. Incorporação de dados irregulares

O monitoramento por imagens capturadas por satélites artificiais revolucionou a meteorologia e a climatologia ao proporcionar uma fonte de dados com regularidade e ampla cobertura. Ainda assim, as redes de sensores em solo e no oceano continuam imprescindíveis no acompanhamento dos fenômenos naturais. A rede observacional do Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden) (Celaschi; Xavier Jr., 2016), fundamental à prevenção de riscos geo-hidrológicos no Brasil, assim como as redes *Tropical Atmosphere Oceans* (TAO), *Prediction and Research Moored Array in the Tropical Atlantic* (PIRATA) e *Research Moored Array for African-Asian-Australian Monsoon Analysis and Prediction* (RAMA), do *Global Tropical Moored Buoy Array Program* (Mcphaden et al., 2010) para monitoramento oceânico, exemplificam a vasta gama de informações disponíveis para orientar a tomada de decisões e a rápida resposta aos riscos, com uma tendência de crescimento ainda maior.

Os desafios relacionados ao processamento de fontes de dados tão díspares são enormes. Por um lado, as técnicas clássicas para modelagem dos sistemas naturais envolvem entradas de dados tabulares – para um dado instante e um dado local, tem-se um conjunto de medições. Por outro lado, a realidade das redes de sensores é muito mais complexa. Há sensores em boias oceânicas, que variam sua posição a cada medição, sensores que falham, redes descontinuadas e taxas de amostragem distintas. Diante desse cenário, há uma demanda por algoritmos e ferramentas digitais que se adequem ao problema e tornem explícitas as premissas e limitações para uma nova geração de modelos. A inteligência artificial e o aprendizado de máquina, com sua alta capacidade de consumo de dados e forte fundamentação estatística, são os paradigmas ideais para adaptar e revigorar a ciência climatológica.

3.1. Imputação de dados faltantes no cenário climatológico

Atualmente, as previsões e o monitoramento do clima estão baseados na aplicação de modelos matemáticos dos comportamentos físicos do planeta. A aderência dos resultados obtidos por esses modelos com os fenômenos reais é garantida por um processo de assimilação de dados coletados pelas redes de sensoriamento. Assim, quando os sensores falham, ou faltam dados por outras razões, o correto funcionamento dos sistemas exige que eles sejam completados artificialmente, uma prática denominada “imputação”.

Os paradigmas clássicos de imputação limitam-se a minimizar a introdução de vieses estatísticos e aberrações numéricas, como descontinuidades, predominando o uso de valores médios ou interpolados, a partir dos vizinhos próximos. Como os algoritmos de aprendizado de máquina têm a capacidade de reproduzir padrões complexos a partir de exemplos semelhantes, existe um potencial de aproximar essas estimativas dos valores verdadeiros, levando a uma maior precisão por parte dos sistemas numéricos que os utilizam.

Tal possibilidade tem sido amplamente explorada pela comunidade científica (Wang *et al.*, 2024), com concepções derivadas de todas as principais famílias de modelos de aprendizado profundo. Ressaltam-se as abordagens apoiadas em redes de grafos (Liang *et al.*, 2024; Marisca; Cini; Alippi, 2022), pela adequação ao uso de dados espaço-temporais irregulares, e também as abordagens derivadas de modelos gerativos, em especial de difusão (Hu *et al.*, 2024; Liu *et al.*, 2023), por capturarem a variabilidade referente às incertezas sobre os valores faltantes.

3.2. Processamento de dados irregulares e complexos

A maior parte dos modelos estatísticos, tanto baseados em equacionamento físico quanto em aprendizado de máquina, depende de garantias de regularidade das fontes de dados, como ausência de falhas temporais e grades de medições com espaçamentos regulares e previsíveis. Todavia, a

realidade do sensoriamento é bastante diferente e enfrenta diversos desafios, por exemplo falhas esporádicas e imprevisíveis, dificuldade de instrumentação em regiões remotas, entre outros.

Em resposta a esses desafios, nos últimos anos, foram desenvolvidos métodos de IA para processar essas fontes de dados irregulares. Em especial, destacam-se as redes neurais de grafo (GNN) [do Inglês, *graph neural networks*] (Scarselli *et al.*, 2009; Veličković *et al.*, 2018). Esses modelos avançados permitem relacionar quaisquer entidades no espaço e no tempo, independentemente de suas eventuais irregularidades. A Figura 3 exemplifica como as estações pluviométricas do Cemaden, que são irregularmente distribuídas, podem ser transformadas em grafo computacional que busca correlações entre os dados coletados nos diferentes locais para compor uma representação mais rica e capaz de previsões mais acuradas e robustas a eventuais falhas de sensores individuais.

Como um exemplo de sucesso recente usando modelagem baseadas em grafos, desenvolvemos um algoritmo de detecção de eventos extremos de ressaca no litoral de Santos. Esse modelo estima, com dois dias de antecedência, a altura das ondas e da maré com aderência de até 96%, enquanto os algoritmos anteriores alcançam, em média, 92% (Barros *et al.*, 2024). Essa aderência sem precedentes foi alcançada por meio da incorporação de dados irregulares medidos no canal principal do Porto de Santos, previsões de modelos numéricos clássicos e imagens de satélite. Essa “fusão de dados” multimodais e complexos é viabilizada pela flexibilidade que o mecanismo das redes neurais de grafos introduz.




Figura 3 – Estações pluviométricas do Cemaden na região de São Sebastião e Ilha Bela, no Estado de São Paulo

Nota: As estações pluviométricas, à esquerda, podem ser modeladas como nós em um grafo computacional, à direita, e processadas por uma rede neural de grafos, viabilizando uma fusão de dados com acurácia e eficiência inéditas.

Fonte: Elaboração própria.

Outro exemplo relevante de fontes de dados irregulares são medições de variáveis oceanográficas coletadas por boias móveis que, embora forneçam medições cruciais para a modelagem dos sistemas climáticos, sofrem diversas falhas devido às condições climáticas inóspitas às quais são submetidas. Novamente, as técnicas de IA baseadas em grafos oferecem uma alternativa eficaz para incorporar os dados disponíveis sem que se precise recorrer a algoritmos complexos de pré-processamento que são suscetíveis a erros e incertezas.

Em resumo, o arcabouço crescente de fontes de dados provenientes de sensores dos mais diversos tipos oferece tanto uma oportunidade quanto um desafio para a ciência de dados. Em resposta a esses desafios, técnicas avançadas de IA foram desenvolvidas para viabilizar a integração desses dados irregulares sem necessidade de uma formulação física explícita, o que seria inviável em muitos casos.

Essas técnicas de treinamento são integradas à tarefa-fim e permitem que os modelos aprendam como utilizar essas fontes irregulares da melhor forma possível e como reagir a eventuais falhas na coleta dessas informações. Esse tipo de flexibilidade e robustez é crucial na construção de sistemas críticos que suportam a tomada de decisão em situações de desastres naturais, como no disparo de alertas antecipados para enchentes.

Portanto, o investimento no desenvolvimento e no refinamento dessas técnicas é um pilar estratégico indispensável para mitigação de impactos de desastres no ambiente que são cada vez mais frequentes e intensos devido às mudanças climáticas. O processamento em larga escala de dados irregulares, para ações de resiliência climática, é possível, mas exige o estabelecimento de parcerias e estruturas dedicadas e munidas dos recursos necessários.

4. Correção de viés da previsão climática do modelo BESM usando modelos de difusão condicionais

Esta seção propõe o uso de modelos probabilísticos de difusão com modelos probabilísticos de DDPM condicionais na correção de viés do BESM com foco no ajuste da precipitação sobre o Sudeste brasileiro. A metodologia desenvolvida integra sequências multivariadas, *embeddings* temporais e transformações estatísticas customizadas para ajustar a distribuição da precipitação diária. A Figura 4 ilustra o fluxo do processo proposto, desde os dados de entrada do BESM e *ECMWF Reanalysis version 5* (ERA5) até a geração da previsão corrigida por meio do modelo de difusão. Como principal contribuição, o trabalho demonstra que os DDPM podem ser adaptados com sucesso ao contexto climático, oferecendo uma nova abordagem para melhorar a acurácia de previsões e apoiar as decisões estratégicas em setores sensíveis ao clima.




Figura 4 – Metodologia de correção de viés do BESM usando modelos de difusão

Nota: (a) Dados de entrada: previsões BESM e referência ao ERA5. (b) Modelo de difusão com processo de adição e remoção de ruído. (c) Previsão corrigida com viés reduzido.

Fonte: Elaboração própria.

4.1. Dados e métodos

O estudo utiliza duas fontes de dados: previsões climáticas do BESM a serem corrigidas pelo DDPM; reanálises meteorológicas do ERA5. Para o BESM, foi usado um *ensemble* de 10 membros de previsões retrospectivas (*hindcasts*), com resolução horizontal de 1,875° (cerca de 208 km), para o período de 1993-2023. Quatro variáveis com valores diários foram selecionadas como preditores: precipitação, pressão na superfície, pressão no nível médio do mar e temperatura à superfície. Como dado de referência observacional para correção do BESM, usou-se a quinta geração de reanálise atmosférica do *European Centre for Medium-Range Weather Forecasts* (ECMWF), conhecida como ERA5 (Hersbach *et al.*, 2020). O ERA5 possui resolução horizontal de 0,25° (aprox. 27 km) e temporal em escala horária, sendo necessário um pós-processamento desses dados para equivalência de grade e tempo com o BESM. Com o objetivo de avaliar a eficácia da metodologia proposta, selecionou-se um estudo de caso representativo, correspondente ao evento de precipitação intensa registrado em 2 de dezembro de 2021. O BESM possui cobertura global, mas o estudo foi concentrado sobre a Região Sudeste, cobrindo uma área aproximada de 10° x 10° de latitude e longitude.

4.2. Resultados e discussões

Os resultados quantitativos demonstraram melhorias substanciais na acurácia das previsões quando comparadas ao ERA5 (dado observado), considerando os meses de dezembro de 2020 a 2023 na Região Sudeste: partindo de um RMSE de 14,26 mm/dia no BESM nativo, a correção de viés utilizando o método QM (Tong *et al.*, 2021) reduziu esse valor para 13,51 mm/dia. O DDPM do Centro Integrado de Manufatura e Tecnologia (Cimatec) avançou ainda mais, atingindo 12,12 mm/dia (aproximadamente 10,32% mais preciso que o método QM), enquanto a estratégia *ensemble* alcançou o melhor resultado com 11,58 mm/dia, representando uma melhoria de aproximadamente 14,28% em relação à correção de viés com o método QM.

Os resultados espaciais estão consolidados na Figura 5. A análise comparativa revela um padrão consistente, indicando que o modelo Cimatec DDPM reproduziu as estruturas espaciais e a magnitude dos eventos observados no ERA5 em diferentes localizações. O BESM nativo, sem correção de viés (quarta coluna), tende a gerar campos de precipitação espacialmente superestimados quando comparados ao ERA5 (última coluna). O método de correção pelo método QM (segunda coluna), embora ajuste a magnitude geral, criou padrões distintos na comparação com a referência das reanálises. Em contraste, o modelo de IA criado para remoção de viés (primeira coluna) demonstra capacidade de gerar campos de precipitação com estruturas espaciais mais próximas ao *ground truth* do ERA5. Uma das principais contribuições do modelo Cimatec DDPM é a capacidade de aprender a distribuição de probabilidade condicional. Tal característica permite que o modelo não apenas corrija o viés médio, mas também reproduza o caráter estatístico completo do clima observado, incluindo a sua variabilidade e a frequência de eventos extremos.




Figura 5 – Precipitação acumulada do dia 2 dez. 2021 do modelo BESM sem e com correção *versus* a referência observacional do ERA5 (linha superior) e da diferença destes modelos com o ERA5 (linha inferior)

Obs.: Na linha superior, os mapas mostram a precipitação total acumulada (mm) para o período de 2021-12-02: (a) BESM corrigido por IA (Cimateg DDPM); (b) BESM corrigido pelo método QM (Tong *et al.*, 2021); (c) *ensemble* (IA + QM)/2; (d) BESM nativo (sem correção de viés); e (e) ERA5 (dado observado). Na linha inferior, as diferenças de precipitação *versus* ERA5 são apresentadas por meio do desvio médio absoluto (mm) para cada método de correção em comparação ao ERA5.

Fonte: Elaboração própria

4.3. Considerações gerais

As melhorias metodológicas apresentadas demonstram implicações diretas para aplicações operacionais e de impacto. A reprodução mais fiel das distribuições de precipitação, corrigindo tanto a frequência de dias secos quanto a magnitude de eventos extremos, é um avanço crucial para estudos de impacto hidrológico, que dependem da precisão desses dados para modelar a resposta de bacias hidrográficas (Teutschbein; Seibert, 2012). A capacidade do modelo Cimatec DDPM de gerar campos espacialmente coerentes é particularmente relevante para a previsão de perigos localizados em áreas urbanas, como inundações repentinas e deslizamentos, que são diretamente influenciados por núcleos de precipitação intensa. Essa capacidade pode aprimorar os sistemas de suporte à decisão da defesa civil, permitindo a transição de alertas generalizados para avisos direcionados e mais eficazes. A redução do viés sistemático na previsão de precipitação se traduz em benefícios socioeconômicos tangíveis, especialmente na mitigação de perdas associadas a eventos hidrometeorológicos extremos.

Para o Sudeste brasileiro, uma região de alta relevância agrícola e com complexa gestão de recursos hídricos, a maior acurácia na previsão de extremos climáticos e de períodos de seca pode igualmente aprimorar a operação de reservatórios, gerando benefícios para a segurança hídrica e energética da nação. O aprimoramento da capacidade preditiva fortalece as estratégias de adaptação climática, fornecendo base técnica e sólida para planos municipais e estaduais alinhados às metas de acordos globais. No contexto da Conferência das Partes (COP30) [do Inglês, *Conference of the Parties*], a demonstração de uma tecnologia nacional avançada para a correção de viés em modelos climáticos posiciona o Brasil como um desenvolvedor de soluções para desafios globais, com potencial de transferência tecnológica para outros países em desenvolvimento que enfrentam limitações similares em seus sistemas de previsão climática.

5. Redução de escala

Prever o clima com mais precisão exige que os cientistas usem grades muito detalhadas para representar o oceano e a atmosfera – como se estivessem ampliando uma imagem para enxergar os mínimos detalhes. No entanto, quanto mais fina essa grade, maior a quantidade de cálculos que precisam ser feitos. Mesmo com supercomputadores, processar esses dados com alta resolução torna-se extremamente lento e, em muitos casos, impossível dentro de prazos razoáveis.

Apesar da dificuldade em se obter esses dados com alta resolução, eles são fundamentais. Quanto mais detalhadas forem as informações sobre o oceano e a atmosfera, maior a chance de detectar com antecedência eventos climáticos extremos, como enchentes, ondas de calor ou fortes tempestades. Essa previsão é essencial para que os órgãos responsáveis possam agir a tempo, proteger a população e mitigar os danos e prejuízos.

Uma solução promissora para esse desafio vem dos avanços recentes em IA. Técnicas modernas, originalmente desenvolvidas para melhorar imagens, agora também são aplicadas aos dados climáticos para aumentar sua resolução; reduzindo a necessidade de cálculos demorados. Esses métodos utilizam grandes volumes de dados históricos e modelos computacionais capazes de identificar padrões complexos, com possibilidade de refinar os resultados utilizando restrições matemáticas e físicas (Harder *et al.*, 2023). Com isso, conseguem gerar versões mais detalhadas e confiáveis das informações oceânicas e atmosféricas. Embora tenham surgido no campo do processamento de imagens, já foi demonstrado que essas tecnologias funcionam muito bem com dados climáticos (Rampal *et al.*, 2024).

O uso de IA representa alternativa muito mais rápida e econômica em comparação com os métodos tradicionais de simulação climática. Em vez de depender de supercomputadores para gerar previsões detalhadas a partir de um conjunto de condições iniciais, a IA consegue aprimorar previsões já existentes com alta eficiência. Isso permite que centros de monitoramento climático tenham acesso a dados mais precisos em menos tempo e com custos reduzidos – o que é essencial para responder, de forma ágil, a eventos extremos. A Figura 6 ilustra esse processo, ou seja, os dados climáticos de baixa resolução são refinados espacialmente por meio de IA.




Figura 6 – Ilustração do processo de redução de escala em dados oceânicos (temperatura da superfície do mar)
Fonte: Elaboração própria.

Para exemplificar a aplicabilidade da técnica ao contexto do projeto, foram realizados experimentos para redução de escala: BESM GCM (100 km) para ERA (25 km) e BESM GCM (100 km) para a grade das previsões oceânicas Mercator¹⁹ (8.3 km) – respectivamente, 4x e 12x como fatores de redução. Essa metodologia objetiva principalmente avaliar quão próximas as novas imagens geradas ficariam tanto em relação ao ERA e Mercator quanto em relação aos dados observados das boias do projeto PIRATA. Esse processo pode ser visualizado na Figura 7.




Figura 7 – Diagrama de fluxo da redução de escala

Obs.: Esse diagrama de escala parte de dados com medições espaçadas por 100 km (GCM) e resulta em dados com maior resolução, assemelhando-se a bases de dados, como ERA5 (25 km) e Mercator (8.3 km). Para validação do poder de reconstrução da IA, os valores são comparados com medições reais feitas por boias, fornecidas na base de dados PIRATA

Fonte: Elaboração própria. Dados elaborados com base em: <https://www.pmel.noaa.gov/tao/drupal/disdel/>.

19 Programa da União Europeia para previsões oceânicas.

Para ambos os experimentos, a redução de escala foi sobre a temperatura da superfície dos oceanos, e os períodos utilizados dos conjuntos de dados (GCM, ERA e Mercator) foram: 1993 a 2015 (para aprendizado de máquina); 2016 a 2018 (para validação); e 2019 a 2021 (para teste). O modelo de IA empregado foi o apresentado por Lim *et al.* (2017).

Após executá-los e de acordo com a Figura 8, os resultados demonstraram que: i) com o uso da técnica de redução de escala (*downscaling*), via IA, ao aumentar a resolução das imagens do GCM, observou-se maior poder preditivo das imagens geradas com um erro absoluto médio (MAE) [do Inglês, *mean absolute error*] em relação às imagens de comparação (ERA) de 0.47°C; e ii) para cada boia do PIRATA, ao comparar a média dos desvios do *downscaling* em relação à média de cada um dos demais conjuntos de dados, observou-se *performance* bem próxima ao ERA, reduzindo o desvio do GCM em média: 60%.




Figura 8 – *Performance* da IA

Obs.: (a) Os pontos correspondem à média do erro de diferentes *datasets* em relação à observação das boias do conjunto PIRATA. A partir dos dados do modelo de maior escala, GCM, os resultados da aplicação da IA aproximaram-se dos modelos de reanálise, ERA5 e Mercator; (b) ao comparar o erro médio do GCM e da IA em relação a cada boia, observa-se grande redução do erro com a aplicação da IA; (c) É descrita a porcentagem de redução do desvio obtida pelo IA em comparação ao GCM; e (d) Em média, a IA reduziu 60% do desvio do GCM.

Fonte: *Elaboração própria.*

6. Detecção de eventos extremos de tempo e clima e seus impactos sobre as cidades

Esta seção demonstra um arcabouço para a aplicação de IA para eventos extremos, tal como aquele proposto por Camps-Valls *et al.* (2025), que engloba três componentes fundamentais para a compreensão de tais eventos: detecção, previsão e avaliação de impactos (*vide* Figura 9). A etapa de detecção visa a localizar e caracterizar eventos anômalos em tempo e espaço, buscando identificar quando e onde podem ocorrer. Em seguida, o componente preditivo atua na projeção de tais eventos no futuro com base em séries temporais e dados observacionais multiescalares. Por fim, a avaliação de impactos permite estimar os efeitos esperados sobre a população, a infraestrutura e os sistemas ecológicos urbanos.




Figura 9 – Arcabouço para aplicação de IA na compreensão de eventos extremos

Fonte: Adaptado de Camps-Valls *et al.* (2025).

A articulação desses três componentes em um *pipeline* coeso potencializa não apenas a resposta emergencial em desastres naturais, mas também a formulação de políticas públicas fundamentadas e a melhoria contínua das estratégias de resiliência climática (Camps-Valls *et al.*, 2025).

A seguir são elencadas algumas abordagens possíveis de aplicação de diversas técnicas de IA sob as perspectivas do ora mencionado arcabouço, com base no contexto de eventos extremos de alto impacto potencial, como aqueles já citados anteriormente.

6.1. Detecção

A detecção de anomalias em séries temporais climáticas, especialmente aquelas associadas a eventos extremos, pode ser aprimorada por meio da combinação de modelos de IA e variáveis meteorológicas complementares. Para um estudo inicial de identificação automatizada de anomalias, no contexto do presente trabalho, foi testado o modelo proposto por Munir *et al.* (2019), que utiliza uma abordagem baseada em redes neurais convolucionais (CNN) [do Inglês, *convolutional neural network*] para detecção não supervisionada. O modelo realiza a previsão do

próximo valor da série a partir de uma janela de histórico e compara essa previsão com o valor observado, utilizando a diferença entre ambos – medida pela média acrescida de dois desvios-padrão – como escore de anomalia. Essa técnica mostrou-se especialmente eficaz na identificação de anomalias pontuais, contextuais e discordantes, mesmo em séries que apresentam tendência, sazonalidade e ruído.

No contexto do evento climático extremo ocorrido em São Sebastião em fevereiro de 2023, o modelo foi aplicado aos dados de precipitação diária da reanálise ERA5 entre 2020 e 2023. O modelo identificou os dias 18 e 19 de fevereiro como anômalos em relação ao padrão histórico quando aplicado na variável de precipitação (Figura 10), indicando sua capacidade de detectar eventos extremos com base em desvios significativos da normalidade climática na região estudada.




Figura 10 – Detecção de anomalias de precipitação acumulada no evento em São Sebastião

Obs.: No eixo X (índice diário na série histórica a partir de 4 dez. 2022) eixo Y (valor padronizado da precipitação diária acumulada).

Fonte: Elaboração própria.

Contudo, experimentos de redução de escala via IA, tais como aqueles citados na seção 5 (deste artigo: Redução de escala), podem proporcionar benefícios significativos para detecção e análise de eventos climáticos extremos, especialmente para sistemas de alerta social e econômico, tais como:

- Maior precisão espacial: a redução de escala de 100 km para 25 km (ERA) e 8,3 km (Mercator) permite identificar eventos climáticos extremos com muito maior detalhamento geográfico. Isso é crucial para alertas localizados, possibilitando avisos específicos para comunidades costeiras, portos, plataformas petrolíferas e rotas de navegação que antes ficavam “invisíveis” pela baixa resolução do GCM.
- Redução significativa de incertezas: a diminuição do erro absoluto médio para 0,4-0,5°C e a redução de 60% no desvio em relação aos dados observacionais das boias PIRATA representam melhoria substancial na confiabilidade das previsões.

Isso permite que gestores de risco tomem decisões mais assertivas sobre evacuações, suspensão de atividades marítimas ou acionamento de protocolos de emergência.

6.2. Previsão

A tarefa de previsão (*forecasting*), em cenários de eventos extremos, tem sido utilizada para mitigar impactos e apoiar processos de tomada de decisão. Técnicas de previsão baseadas em IA vêm se consolidando como ferramentas robustas para antecipar o comportamento de variáveis críticas, como intensidade de chuvas (Shi *et al.*, 2021), ventos (Liu *et al.*, 2020) e propagação de incêndios (Andrianarivony *et al.*, 2024).

Um avanço importante nesta área é o Prithvi Weather-Climate (Prithvi-WxC), um modelo fundacional desenvolvido em colaboração entre a *National Aeronautics and Space Administration* (Nasa) e a *International Business Machines Corporation* (IBM) (Schmude *et al.*, 2024). O Prithvi-WxC é projetado para replicar dinâmicas atmosféricas em múltiplas escalas e lidar com informações faltantes, utilizando uma arquitetura hierárquica baseada em transformadores. O modelo já foi aplicado em tarefas, como previsão de trajetória e intensidade de furacões, parametrização de ondas gravitacionais e redução de escala (*downscaling*) de modelos climáticos, demonstrando avanços na eficiência e na capacidade de representação de processos físicos em modelos meteorológicos e climáticos (Schmude *et al.*, 2024).

Complementarmente, novos *frameworks* de previsão espaço-temporal têm expandido as possibilidades de modelagem de eventos extremos dinâmicos. O GraphCast (Lam *et al.*, 2023), desenvolvido pela DeepMind, é um modelo baseado em grafos que realiza previsões globais

de tempo com resolução de 0,25 grau, utilizando dados históricos do ERA5. O modelo é capaz de prever variáveis, como pressão atmosférica e vento em até 10 dias, com precisão superior a modelos tradicionais e com menor custo computacional, permitindo previsões mais rápidas e detalhadas em escala global (Lam *et al.*, 2023).

Por sua vez, o GenCast (Price *et al.*, 2025), também da DeepMind, adota uma abordagem baseada em modelos de difusão para previsão de tempo em médio prazo, gerando conjuntos de previsões (*ensemble forecasting*). Isso permite representar não apenas o cenário mais provável, mas também a incerteza associada às diferentes evoluções possíveis do sistema atmosférico, o que é especialmente relevante em situações de risco elevado (Price *et al.*, 2025).

Essas abordagens demonstram como o avanço de *frameworks* baseados em IA está tornando o *forecasting* mais capaz de representar fenômenos extremos com maior detalhamento e eficiência, apoiando o desenvolvimento de ferramentas para avaliação e gestão de riscos associados a esses eventos.

6.3. Impacto sobre as cidades

A identificação antecipada de impactos sobre as cidades torna-se também essencial. É fundamental desenvolver métodos inovadores para a detecção de eventos extremos, visando ao aprimoramento dos sistemas de alerta precoce e à redução do número de fatalidades (Santos *et al.*, 2020). Uma comunicação eficaz do risco contribui para melhor preparo e resposta, com potencial de salvar vidas (Campos-Valls *et al.*, 2025; Marengo *et al.*, 2024; Valle *et al.*, 2022). A partir de alertas bem estruturados e de estratégias robustas de mitigação, baseadas em modelagem precisa, as avaliações de risco podem ser implementadas para proteger comunidades e infraestruturas vulneráveis (Mantovani *et al.*, 2025).

No contexto dos alertas antecipados, tecnologias como sensores de baixo custo para monitoramento de encostas e modelos de IA têm demonstrado grande potencial na detecção precoce de instabilidades e na geração de mapas de suscetibilidade das regiões (Otero *et al.*, 2022; Alcântara *et al.*, 2025). Além disso, os sistemas que permitem o envio de notificações sonoras por celular reforçam a importância de estratégias integradas ao fortalecimento da gestão de risco em regiões vulneráveis.

Nesse sentido, outra estratégia para a temática de cenários de risco é o monitoramento de redes sociais digitais. Tais dados podem ser utilizados para abastecer sistemas de alerta antecipado, contribuindo tanto na componente de ameaça (natural) quanto de impactos (sociais). Tal estratégia é particularmente interessante em contextos em que as técnicas convencionais de coleta de dados podem ser insuficientes (Drews *et al.*, 2023). Há uma desvantagem fundamental devido à sua

natureza reativa – os usuários precisam testemunhar ou ser afetados por uma inundação antes de publicar a respeito dela. Contudo, tal limitação pode ser utilizada exatamente para detecção das regiões mais atingidas.

Como estudo de caso, Hossaki *et al.* (2023) cunharam o termo “pluviômetro social”, que considera menções a alagamentos em plataformas, por exemplo o Twitter, como fonte complementar de dados ao monitoramento de chuva. Hossaki *et al.* (2023; 2025) demonstraram dois pontos fundamentais, tomando a cidade de São Paulo como área de estudo:

1. Em dias com alagamentos, a atividade nas redes sociais sobre o dicionário previamente determinado no contexto de inundações é maior do que em dias sem alagamentos.
2. Há correlação significativa entre séries temporais dos diferentes domínios: redes sociais, pluviômetros e estações hidrológicas.

Ressaltam-se, em especial, duas vantagens da análise com base em redes sociais: baixo custo de início de operação e manutenção [mesmo com a compra de acesso de *Application Programming Interface* (API) específicas], e ganho de antecipação; alguns termos são relativos a “nuvens cinzas”, que precedem as chuvas e seus impactos. A integração dessa base com dados meteorológicos e de impacto convencionais oferece uma estratégia mais abrangente e resiliente para cenários de risco de inundações – componente de ameaça (natural) e de impactos (sociais).

Por fim, é importante lembrar que alertas de risco de desastres vão além de alertas meteorológicos, devendo incorporar previsões de nível e vazão em diferentes trechos de rios e de umidade no solo e fator de segurança em diferentes porções de encostas. Ferramentas baseadas em IA são promissoras também nesse contexto (Duque *et al.*, 2024; Soares *et al.*, 2025). Além disso, é indispensável levar em consideração as vulnerabilidades do lugar, das pessoas, das infraestruturas e dos serviços expostos a cada ameaça. Novamente, as técnicas de matemática aplicada, no geral, e de IA, em particular, são auspiciosas (Santos *et al.*, 2017; Santos *et al.*, 2023).

7. Conclusões e próximos passos

Em conclusão, como visto nas seções acima, a IA mostra-se uma potente ferramenta tanto para a agregação de informações em bases de dados esparsos, quanto para a redução de escala e para a redução de vieses da previsão numérica gerada por modelo numérico do sistema terrestre. O artigo demonstra, assim, que a combinação de métodos consagrados de modelagem climática e técnicas de IA representam uma nova e promissora ferramenta para a previsão de eventos climáticos extremos, tais como secas e inundações de enormes proporções, com antecedência de meses e seus impactos na sociedade.

Os próximos passos desta pesquisa, já em curso, constituem na aplicação dos métodos de IA delineados neste artigo para um evento climático extremo, utilizando para tanto as bases de dados globais e os locais disponíveis, como previsões numéricas com alta resolução espaço-temporal, séries históricas de dados observados em estações continentais e oceânicas e imagens de satélites.

Agradecimentos

Os autores agradecem ao suporte financeiro da Secretaria de Transformação Digital (Setad), do Ministério da Ciência, Tecnologia e Inovação (MCTI), ao Projeto Sistema Inteligente de Previsão de Extremos Climáticos (Siphec/PBIA) e à Financiadora de Estudos e Projetos (Finep) pelo financiamento do Projeto Sistema Multiusuário para Detecção, Previsão e Monitoramento de Manchas de Óleo no Mar (SisMOM), referência Finep nº 1576/21.

Ao Instituto de Pesquisas Tecnológicas (IPT) e à Fundação de Amparo à Pesquisa do Estado de São Paulo (Fapesp), por meio do “Plano de Desenvolvimento Institucional na área de transformação digital: manufatura avançada e cidades inteligentes e sustentáveis (PDIp)” (Processo nº 2017/50348-2) e “EcoSustain: ciência de dados e computação para o meio ambiente” (Processo nº 2023/00811-0).

Ao SiDi por todo suporte, apoio e parceria no desenvolvimento do projeto e contribuição técnica e científica na construção do conhecimento.

Ao Centro de Inteligência Artificial e Aprendizado de Máquina (Ciaam) e ao Centro de Inteligência Artificial (C4AI) da Universidade de São Paulo (USP) pela parceria técnica e científica e participação na concepção metodológica do projeto.

Ao Serviço Nacional de Aprendizagem Industrial/Centro Integrado de Manufatura e Tecnologia (Senai Cimatec) e ao seu Centro de Supercomputação para Inovação Industrial (CS2I) por todo o suporte técnico e computacional para a execução das atividades deste projeto.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (Processo 446053/2023-6) e ao projeto do Instituto Nacional de Ciência, Tecnologia e Inovação (INCT) para Mudanças Climáticas Fase II (Processo Fapesp nº 2014/50848-9).

Ao MCTI e à Diretoria de Hidrografia e Navegação (DHN) pelos apoios financeiro e de navio para manutenção da rede de boias ancoradas do Projeto PIRATA, em parceria com a NOAA/EUA, *French National Research Institute for Sustainable Development (IRD) MétéoFrance/França*.

Referências

- ALCÂNTARA, E.; BAIÃO, C.F.; GUIMARÃES, Y.C.; MANTOVANI, J.R.; MARENGO, J.A. Machine learning approaches for mapping and predicting landslide-prone areas in São Sebastião (Southeast Brazil). **Natural Hazards Research**, v. 5, n. 2, p. 247-261, 2025. Disponível em: https://www.researchgate.net/profile/Jose-Mantovani-4/publication/385061537_Machine_Learning_Approaches_for_Mapping_and_Predicting_Landslide-Prone_Areas_in_Sao_Sebastiao_Southeast_Brazil/links/6714d4ee09ba2doc760ea787/Machine-Learning-Approaches-for-Mapping-and-Predicting-Landslide-Prone-Areas-in-Sao-Sebastiao-Southeast-Brazil.pdf?_tp=eyJjb250ZXh0b2p7ImZpcnNoUGFnZSI6InB1YmxpY2FoaW9uIiwicGFnZSI6InB1YmxpY2FoaW9uIn19
- ANDRIANARIVONY, H.S.; Akhloufi, M.A. Machine learning and deep learning for wildfire spread prediction: a review. **Fire**, v. 7, n. 12, p. 482, 2024. Disponível em: <https://www.mdpi.com/2571-6255/7/12/482/pdf?version=1734515358>
- BARROS, Marcel *et al.* Early detection of extreme storm tide events using multimodal data processing. **Proceedings of the AAI Conference on Artificial Intelligence**, v. 38, n. 20, p. 21923-21931, 2024. Disponível em: <https://ojs.aaai.org/index.php/AAI/article/view/30194/32120>
- CAMPS-VALLS, G.; FERNÁNDEZ-TORRES, M.-Á.; COHRS, K.-H.; HÖHL, A. *et al.* Artificial intelligence for modeling and understanding extreme weather and climate events. **Nature Communications**, v. 16, n. 1, p. 1919, 2025. Disponível em: https://www.researchgate.net/publication/389277932_Artificial_intelligence_for_modeling_and_understanding_extreme_weather_and_climate_events/fulltext/67bcb606207c0c20fa95906a/Artificial-intelligence-for-modeling-and-understanding-extreme-weather-and-climate-events.pdf?_tp=eyJjb250ZXh0b2p7ImZpcnNoUGFnZSI6InB1YmxpY2FoaW9uIiwicGFnZSI6InB1YmxpY2FoaW9uIn19
- CELASCHI, Sergio; XAVIER JR, Ademir L. Status of a Brazilian Automatic Hydro-meteorological territorial network. In: SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES (SBRT2016), 34, 2016, Santarém, Brasil. **Anais...** Santarém, Brasil. 2016. Disponível em: <https://biblioteca.sbrrt.org.br/articlefile/1474.pdf>
- CHANTRY, M.; CHRISTENSEN, H.; DUEBEN, P.; PALMER, T. Opportunities and challenges for machine learning in weather and climate modelling: hard, medium and soft AI. **Philosophical Transactions. Series A, Mathematical, Physical, and Engineering Sciences**, v. 379, n. 2194, 2021. Disponível em: <https://royalsocietypublishing.org/doi/reader/10.1098/rsta.2020.0083>
- DREWS, M.; STEINHAUSEN, M.; LARSEN, M.A.D.; DØMGÅRD, M.L.; HUSZTI, L.; RÁCZ, T.; WORTMANN, M.; HATTERMANN, F.F.; SCHRÖTER, K. The utility of using Volunteered Geographic Information (VGI) for evaluating pluvial flood models. **Science of the Total Environment**, v. 894, n. 164962, 2023. Disponível em: <https://backend.orbit.dtu.dk/ws/portalfiles/portal/336967697/1-s2.0-S0048969723035854-main.pdf>

DUQUE, J.S.; SANTOS, R.; ARTEAGA, J.; OYARZABAL, R.S.; SANTOS, L.B.L. Nonlinear hydrological time series modeling to forecast river level dynamics in the Rio Negro Uruguay basin. **Chaos, An Interdisciplinary Journal of Nonlinear Science**, v. 34, n. 5, 3132, 2024. DOI:10.1063/5.0201784

FIGUEROA, Silvio N.; BONATTI, José P.; KUBOTA, Paulo Y. *et al.* The Brazilian global atmospheric model (BAM): performance for tropical rainfall forecasting and sensitivity to convective scheme and horizontal resolution. **Weather and Forecasting**, v. 31, n. 5, p. 1547-72, 2016. Disponível em: https://journals.ametsoc.org/downloadpdf/view/journals/wefo/31/5/waf-d-16-0062_1.pdf

HARDER, P.; HERNANDEZ-GARCIA, A.; RAMESH, V.; YANG, Q.; SATTEGERI, P.; SZWARCMAN, D.; WATSON, C.D.; ROLNICK, D. Hard-constrained deep learning for climate downscaling. **Journal of Machine Learning Research**, v. 24, n. 1, 2023. Disponível em: <https://www.jmlr.org/papers/volume24/23-0158/23-0158.pdf>

HERSBACH, H.; BELL, B.; BERRISFORD, P.; HIRAHARA, S. *et al.* The ERA5 global reanalysis. **Quarterly Journal of the Royal Meteorological Society**, v. 146, p. 1999-2049, 2020. Disponível em: <https://rmets.onlinelibrary.wiley.com/doi/epdf/10.1002/qj.3803>

HO, J.; JAIN, A.; ABBEEL, P. Denoising diffusion probabilistic models. **Advances in Neural Information Processing Systems**, v. 33, p. 6840-6851, 2020. Disponível em: <https://arxiv.org/pdf/2006.11239>

HOSSAKI, V.Y.; NEGRI, R.G.; SANTOS, L.B.L.; MENDES, T.S.G.; BRESSANE, A. Combining social media data and meteorological sensors for urban flood detection: a statistical analysis in São Paulo City. **Earth Science Informatics**, v. 18, n. 3, 2025. DOI:10.1007/s12145-025-01802-3

HOSSAKI, V.Y.; SERON, W.F.M.S.; NEGRI, R.G.; LONDE, L.R.; TOMÁS, L.R.; BACELAR, R.B.; ANDRADE, S.C.; SANTOS, L.B.L. Physical- and social-based rain gauges – a case study on urban flood detection. **Geosciences**, v. 13, n. 4, 2023. Disponível em: <https://www.mdpi.com/2076-3263/13/4/111/pdf?version=1680745325>

HU, Junfeng; LIU, Xu; FAN, Zhencheng; LIANG, Yuxuan; ZIMMERMANN, Roger. Towards unifying diffusion models for probabilistic spatio-temporal graph learning. In: SIGSPATIAL '24: ACM International Conference On Advances In Geographic Information Systems, 32., Atlanta GA USA. 2024. **Anais ... Atlanta GA USA: 2024**. p. 135-146. Disponível em: <https://dl.acm.org/doi/pdf/10.1145/36787173691235>. Acesso em: 20 fev. 2025.

INSTITUTO DE PESQUISAS TECNOLÓGICAS DO ESTADO DE SÃO PAULO - IPT. **Elaboração do plano municipal de redução de riscos (PMRR) para o município de São Sebastião, SP**. Relatório Técnico Nº 155131–205 SDECTI/Patem. São Paulo: IPT. 2018. Disponível em: https://www.sidec.sp.gov.br/map_risco/uploads/doc1637073821.pdf

LAM, R.; SANCHEZ-GONZALEZ, A.; WILLSON, M.; WIRNSBERGER, P. *et al.* Learning skillful medium-range global weather forecasting. **Science**, 382, p. 1416-1421, 2023. Disponível em: <https://www.science.org/doi/10.1126/science.adiz336>

MARISCA, Ivan; CINI, Andrea; ALIPPI, Cesare. Learning to reconstruct missing data from spatiotemporal graphs with sparse observations. **Advances in Neural Information Processing Systems**, v. 35, p. 32069-32082, 2022. Disponível em: <https://arxiv.org/pdf/2205.13479>

MATERIA, S.; GARCÍA, L.P.; VAN STRAATEN, C.O.S.; MAMALAKIS, A.; CAVICCHIA, L.; COUMOU, D.; DE LUCA, P.; KRETSCHMER, M.; DONAT, M. Artificial intelligence for climate prediction of extremes: State of the art, challenges, and future perspectives. **WIREs Climate Change**, v. 15, n. 6, 2024. Disponível em: <https://wires.onlinelibrary.wiley.com/doi/epdf/10.1002/wcc.914>

MCPHADEN, Michael J. *et al.* The global tropical moored buoy array. **Proceedings of OceanObs**, v. 9, p. 668–682, 2010. Disponível em: https://www.aoml.noaa.gov/phod/docs/McPhaden_TheGlobalTropical.pdf

MUNIR, M.; SIDDIQUI, S.A.; DENGEL, A.; AHMED, S. DeepAnT: A deep learning approach for unsupervised anomaly detection in time series. **IEEE Access**, v. 7, 1991-2005, 2019. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8581424>

NESET, T.-S.; VROTSOU, K.; ANDERSSON, L.; NAVARRA, C.; SCHÜCK, F.; EDSTRÖM, M.M.; RYDHOLM, C.; VILLARO, C.G.; KUCHER, K.; LINNÉR, B. Artificial intelligence in support of weather warnings and climate adaptation. **Climate Risk Management**, v. 46, n. 2, p. 100673, 2024. Disponível em: https://www.researchgate.net/profile/Kostiantyn-Kucher/publication/386081715_Artificial_intelligence_in_support_of_weather_warnings_and_climate_adaptation/links/6749d59b790d154bf9b57590/Artificial-intelligence-in-support-of-weather-warnings-and-climate-adaptation.pdf?_tp=eyJlb250ZXh0bip7ImZpcnNoUGFnZSI6InB1YmxyY2FoaW9uIiwicGFnZSI6InB1YmxyY2FoaW9uIn19

NOBRE, Paulo; SIQUEIRA, Leo S.P.; ALMEIDA, Roberto A.F. de *et al.* Climate simulation and change in the Brazilian climate model. **Journal of Climate**, v. 26, n. 17, p. 6716-32, 2013. Disponível em: http://www.researchgate.net/profile/Mabel_Costa/publication/273635330_Climate_Simulation_and_Change_in_the_Brazilian_Climate_Model/links/5507ab7b0cf26ff5f7ed28d.pdf

NOBRE, Paulo; VEIGA, Sandro F.; GIAROLLA, Emanuel *et al.* AMOC decline and recovery in a warmer climate. **Scientific Reports**, v. 13, n. 1, p. 15928, 2023. Disponível em: <https://www.nature.com/articles/s41598-023-43143-5.pdf>

OTERO, M.D.; ABREU, A.E.S.; ASKARINEJAD, A.; GUIMARÃES, M.P.P.; MACEDO, E.S.; CORSI, A.C.; ALMEIDA, R.Z.H. Use of low -cost accelerometers for landslides monitoring: results from a flume experiment. **Soils and Rocks**, v. 45, n. 3, 2022. Disponível em: <https://pure.tudelft.nl/ws/portalfiles/portal/132988397/380.pdf>

PRICE, I.; SANCHEZ-GONZALEZ, A.; ALET, F.; ANDERSSON, T.R.; EL-KADI, A.; MASTERS, D.; EWALDS, T.; STOTT, J. Probabilistic weather forecasting with machine learning. **Nature**, n. 637, p. 84-104, 2025. Disponível em: <https://www.nature.com/articles/s41586-024-08252-9.pdf>

PRICE, I.; SANCHEZ-GONZALEZ, A.; ALET, F.; EWALDS, T. *et al.* GenCast: Diffusion-based ensemble forecasting for medium-range weather. **arXiv**. 2023. Disponível em: <https://arxiv.org/pdf/2312.15796>

RAMPAL, N.; HOBEICHI, S.; GIBSON, P.; MEDINA, J.; ABRAMOWITZ, G.; BEUCLER, T.; GONZÁLEZ-ABAD, J.; CHAPMAN, W.; GUTIÉRREZ, J. Enhancing regional climate downscaling through advances in machine learning. **Artificial Intelligence for the Earth Systems**, v. 3, n. 2, 2024. Disponível em: <https://journals.ametsoc.org/downloadpdf/view/journals/aies/3/2/AIES-D-23-0066.1.pdf>

SANTOS, A.S.; CORSI, A.C.; TEIXEIRA, I.C.; GAVA, V.L.; FALCETTA, F.A.M.; MACEDO, E.S.; AZEVEDO, C.S.; LIMA, K.T.B.; BRAGHETTO, K.R. Brazilian natural disasters integrated into cyber-physical systems: computational challenges for landslides and floods in urban ecosystems. **2020 IEEE International Smart Cities Conference (ISC2)**, Piscataway, NJ, USA, 2020, p. 1-8. DOI: 10.1109/ISC251055.2020.9239011

SANTOS, L.B.L.; SOARES, G.G.; GARG, T.; JORGE, A.A.S.; LONDE, L.R.; REANI, R.T.; BACELAR, R.B.; OLIVEIRA, C.E.S.; FREITAS, V.L.S.; SOKOLOV, I.M. Vulnerability analysis in complex networks under a flood risk reduction point of view. **Frontiers in Physics**, v. 11, n. 1, 2023. Disponível em: <https://www.frontiersin.org/journals/physics/articles/10.3389/fphy.2023.1064122/pdf>

SANTOS, L.B.L.; CARVALHO, T.; ANDERSON, L.O.; RUDORFF, C.; MARCHEZZINI, V.; LONDE, L.R.; SAITO, S.M. An RS-GIS-based comprehensive impact assessment of floods – a case study in Madeira River, Western Brazilian Amazon. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 9, p. 1614-1617, 2017. DOI:10.1109/LGRS.2017.2726524

SCARSELLI, F.; GORI, M.; AH CHUNG TSOI; HAGENBUCHNER, M.; MONFARDINI, G. The Graph neural network model. **IEEE Transactions on Neural Networks**, v. 20, n. 1, p. 61-80, 2009. Disponível em: https://ro.uow.edu.au/articles/journal_contribution/The_graph_neural_network_model/27757629/1/files/50520873.pdf

SCHMUDE, J.; ROY, S.; TROJAK, W.; JAKUBIK, J.; CIVITARESE, D.S.; SINGH, S.; KUEHNERT, J.; ANKUR, K.; GUPTA, A.; PHILLIPS, C.E.; KIENZLER, R.; SZWARCMAN, D.; GAUR, V.; SHINDE, R.; LAL, R.; DA SILVA, A.; GUEVARA DIAZ, J.L.; JONES, A.; PFREUNDSCUH, S.; LIN, A.; SHESHADRI, A.; NAIR, U.; ANANTHARAJ, V.; HAMANN, H.; WATSON, C.; MASKEY, M.; TSENGDAR, J. Prithvi WxC: Foundation Model for Weather and Climate. 2024. Preprint (arXiv:2409.13598). Disponível em: <https://arxiv.org/pdf/2409.13598>

SHI, X.; GAO, Z.; LAUSEN, L.; WANG, H.; YEUNG, D.; WONG, W.; WOO, W. Deep learning for precipitation nowcasting: A benchmark and a new model. **Scientific Reports**, v. 11, n. 1, 2021. Disponível em: <https://arxiv.org/pdf/1706.03458>

SOARES, J.A.J.P.; OZELIM, L.C.S.M.; BACELAR, L.; RIBEIRO, D.B.; STEPHANY, S.; SANTOS, L.B.L. (2025). ML4FF: A machine-learning framework for flash flood forecasting applied to a Brazilian watershed. **Journal of Hydrology**, v. 652, p. 132674, 2025. <https://doi.org/10.1016/j.jhydrol.2025.132674>

TEUTSCHBEIN, C.; SEIBERT, J. Bias correction of regional climate model simulations for hydrological climate-change impact studies: review and evaluation of different methods. **Journal of Hydrology**, v. 456-457, p. 12-29, 2012. <https://doi.org/10.1016/j.jhydrol.2012.05.052>

TONG, Y.; GAO, X.; HAN, Z.; XU, Y.; XU, Y.; GIORGI, F. Bias correction of temperature and precipitation over China for RCM simulations using the QM and QDM methods. **Climate Dynamics**, v. 57, p. 1425-1443, 2021. Disponível em: <https://link.springer.com/content/pdf/10.1007/s00382-020-05447-4.pdf>

VALLE, V.A.S.; ABREU, J.V.; FERNANDEZ, C.A.S. Desastre relacionado às chuvas intensas na Baixada Santista em março de 2020: a experiência das Defesas Cíveis de Guarujá e Santos. **Revista Brasileira de Geologia de Engenharia e Ambiental – RBGEA**, v. 12, n. 1, 2022. Disponível em: <https://www.abge.org.br/downloads/9.pdf>

VELIČKOVIĆ, Petar; CUCURULL, Guillem; CASANOVA, Arantxa; ROMERO, Adriana; LIÒ, Pietro; BENGIO, Yoshua. Graph Attention Networks. In: SIXTH INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS 2018, **Anais...** 2018. Disponível em: <https://openreview.net/forum?id=rjXMpikCZ>. Acesso em: 26 maio. 2024.

WANG, Jun; DU, Wenjie; CAO, Wei; ZHANG, Keli; WANG, Wenjia; LIANG, Yuxuan; WEN, Qingsong. Deep learning for multivariate time series imputation: a survey. **arXiv**, 2024. Disponível em: <http://arxiv.org/abs/2402.04059>. Acesso em: 13 fev. 2025.