

PREVISÃO DA UMIDADE RELATIVA DO AR COM MODELOS UNIVARIADOS: UMA COMPARAÇÃO ENTRE BILSTM E HÍBRIDO ROLLING VMD-BILSTM

Winicius dos Passos Soares de Souza¹

Evandro Alves Nakajima²

Fabício Correia de Oliveira³

Diego Venâncio Thomaz⁴

RESUMO: Esse artigo avaliou o desempenho da previsão univariada da umidade relativa do ar utilizando um modelo *Deep Learning* BiLSTM tradicional em contraposição a um modelo híbrido *Rolling VMD-BiLSTM*. A metodologia empregada baseou-se no uso de dados meteorológicos diários de oito municípios do Paraná (2007 a 2023). Aplicou-se a codificação cíclica para tratar a sazonalidade e o framework Optuna para a otimização dos hiperparâmetros. O grande diferencial metodológico foi a aplicação da Decomposição de Modo Variacional em janela deslizante (*Rolling VMD*), processando a série temporal de forma iterativa para mitigar o vazamento de dados (*data leakage*), garantindo um cenário preditivo realista. Os principais resultados encontrados evidenciaram a superioridade da abordagem híbrida, que reduziu o erro RMSE em 14,63% e aumentou a variância explicada (R^2) em 32,35% em relação ao modelo base. Além disso, o modelo híbrido mitigou a defasagem temporal e a subestimação de extremos climáticos observados na rede pura. Conclui-se que o acoplamento do algoritmo *Rolling VMD* à rede BiLSTM constitui uma alternativa algorítmica rigorosa e fidedigna, prevenindo vieses de antecipação e oferecendo suporte robusto para sistemas de monitoramento contínuo e emissão de alertas meteorológicos.

Palavras-chave: Umidade Relativa do Ar. *Rolling VMD*. BiLSTM.

¹ Acadêmico de Graduação do curso de Bacharelado em Ciência da Computação na UTFPR - Universidade Tecnológica Federal do Paraná.

² Professor Adjunto da UTFPR - Universidade Tecnológica Federal do Paraná, Câmpus Santa Helena. Doutor em Engenharia Química pela UNIOESTE - Universidade Estadual do Oeste do Paraná.

³ Professor Adjunto da UTFPR - Universidade Tecnológica Federal do Paraná, Câmpus Santa Helena. Doutor em Engenharia de Sistemas Agrícolas pela USP - Universidade de São Paulo.

⁴ Professor Adjunto da UTFPR - Universidade Tecnológica Federal do Paraná, Câmpus Santa Helena. Doutor em Métodos Numéricos em Engenharia pela UFPR - Universidade Federal do Paraná.

ABSTRACT: This article evaluated the performance of univariate relative humidity forecasting using a traditional BiLSTM deep learning model versus a hybrid Rolling VMD-BiLSTM model. The methodology employed was based on the use of daily meteorological data from eight municipalities in Paraná, Brazil (2007 to 2023). Cyclical encoding was applied to handle seasonality, and the Optuna framework was used for hyperparameter optimization. The main methodological differential was the application of Variational Mode Decomposition in a sliding window (Rolling VMD), processing the time series iteratively to mitigate data leakage, ensuring a realistic predictive scenario. The main results showed the superiority of the hybrid approach, which reduced the RMSE error by 14.63% and increased the explained variance (R^2) by 32.35% compared to the baseline model. Furthermore, the hybrid model mitigated the time lag and the underestimation of climatic extremes observed in the pure network. It is concluded that the coupling of the Rolling VMD algorithm to the BiLSTM network constitutes a rigorous and reliable algorithmic alternative, preventing anticipation biases and offering robust support for continuous monitoring systems and the issuance of meteorological alerts.

Keywords: Relative Humidity. Rolling VMD. BiLSTM.

RESUMEN: Este artículo buscó comparar el rendimiento de la predicción univariada de la humedad relativa del aire utilizando un modelo de aprendizaje profundo BiLSTM tradicional en contraposición a un modelo híbrido Rolling VMD-BiLSTM. La metodología empleada se basó en el uso de datos meteorológicos diarios de ocho municipios de Paraná, Brasil (2007 a 2023). Se aplicó la codificación cíclica para tratar la estacionalidad y el framework Optuna para la optimización de los hiperparámetros. El gran diferencial metodológico fue la aplicación de la Descomposición de Modo Variacional en ventana deslizante (Rolling VMD), procesando la serie temporal de forma iterativa para mitigar la fuga de datos (data leakage), garantizando un escenario predictivo realista. Los principales resultados encontrados evidenciaron la superioridad del enfoque híbrido, que redujo el error RMSE en un 14,63% y aumentó la varianza explicada (R^2) en un 32,35% en relación con el modelo base. Además, el modelo híbrido mitigó el desfase temporal y la subestimación de extremos climáticos observadas en la red pura. Se concluye que el acoplamiento del algoritmo Rolling VMD a la red BiLSTM constituye una alternativa algorítmica rigurosa y

fidedigna, previniendo sesgos de anticipación y ofreciendo un soporte robusto para sistemas de monitoreo continuo y emisión de alertas meteorológicas.

Palabras clave: Humedad Relativa del Aire. Rolling VMD. BiLSTM.

INTRODUÇÃO

A modelagem precisa de variáveis meteorológicas desempenha um papel fundamental no desenvolvimento socioeconômico global e regional. Nesse contexto, a umidade relativa do ar (UR) destaca-se como uma variável crítica, cujo monitoramento e previsão são indispensáveis em diversas áreas estratégicas. Na agricultura, o conhecimento prévio e o controle da UR são fundamentais para a adequação de práticas de manejo, para a mitigação da proliferação de fungos, bactérias e insetos, e para garantir a qualidade do produto final (VELÁSQUEZ et al., 2018; ZHOU et al., 2024). No âmbito da simulação hidrológica e gestão de recursos hídricos, a UR é um parâmetro essencial para a estimativa da evapotranspiração, servindo como dado de entrada crucial para modelos hidrológicos de base física complexos (FERREIRA et al., 2021; GIMÉNEZ; GARCÍA-GALIANO, 2018).

Além dos impactos econômicos, a UR exerce uma influência direta sobre a saúde humana e a preservação ambiental. Condições de baixa umidade, quando associadas a altas temperaturas, favorecem o transporte de poluentes atmosféricos, agravando doenças respiratórias e desencadeando complicações como alergias e irritações severas. Em contrapartida, o aumento acentuado da UR e da temperatura cria um ambiente propício à proliferação de vetores responsáveis por doenças infecciosas, como a dengue, a meningite e a pneumonia (MALL et al., 2017). A variável está ainda intimamente relacionada com o risco de incêndios florestais e de pastagens, que ameaçam o ecossistema. Considerando a relevância da umidade relativa do ar em múltiplos setores, a capacidade de prever com precisão suas flutuações é de suma importância para a tomada de decisões, formulação de políticas públicas e implementação de medidas preventivas (BAYER et al., 2017; ZENKNER; NAVARRO-MARTINEZ, 2023).

A literatura recente destaca que, embora os impactos da umidade relativa sejam amplamente investigados em diversos domínios, há uma escassez de estudos focados especificamente em sua previsão contínua por meio de abordagens avançadas de aprendizado de máquina, sobretudo no contexto de modelagem de séries temporais

univariadas, uma abordagem que apresenta a vantagem operacional de não depender da disponibilidade de dados de múltiplos sensores meteorológicos simultâneos (ÖZBEK et al., 2022). Adicionalmente, o isolamento analítico de uma única variável reduz substancialmente a complexidade dimensional e o custo computacional do treinamento do modelo. Conforme destacado por Zenkner e Navarro-Martinez (2023), o desenvolvimento de modelos preditivos meteorológicos leves e flexíveis é essencial para viabilizar implementações operacionais eficientes. Esta simplificação arquitetural é, portanto, altamente vantajosa, pois confere resiliência ao sistema perante falhas de instrumentação em variáveis secundárias, facilitando a sua integração ágil em arquiteturas de computação de borda (*edge computing*) para o monitoramento contínuo e a emissão de alertas em tempo real.

Historicamente, as tentativas de previsão de variáveis meteorológicas foram dominadas por modelos estatísticos lineares, como a Média Móvel Integrada Autorregressiva (ARIMA, do inglês *Autoregressive Integrated Moving Average*) e a Média Móvel Integrada Autorregressiva Sazonal (SARIMA, do inglês *Seasonal Autoregressive Integrated Moving Average*), que frequentemente falham em capturar picos extremos e a forte não linearidade intrínseca à umidade relativa do ar. Mais recentemente, o estado da arte tem migrado para o Aprendizado Profundo (*Deep Learning*), com o uso de Redes Neurais Recorrentes, como a Memória de Longo e Curto Prazo (LSTM, do inglês *Long Short-Term Memory*) e sua variante, a Memória de Longo e Curto Prazo Bidirecional (BiLSTM, do inglês *Bidirectional Long Short-Term Memory*), e também a Unidade Recorrente Controlada (GRU, do inglês *Gated Recurrent Unit*), demonstrando superioridade na extração de padrões temporais. Adicionalmente, para contornar o alto nível de ruído dos sensores, técnicas de decomposição de séries temporais, como a Decomposição de Modo Variacional (VMD, do inglês *Variational Mode Decomposition*), têm sido empregadas para mitigar os impactos do ruído e da não-estacionariedade, otimizando o desempenho preditivo de modelos híbridos (HANOON et al., 2021). Contudo, a maioria dos trabalhos que utilizam VMD para previsão meteorológica esbarra em uma falha metodológica crítica: o vazamento de dados (*data leakage*), causado pela decomposição de todo o conjunto de dados simultaneamente, o que gera resultados irrealistas em cenários práticos. Nesse contexto, o diferencial e a principal contribuição deste trabalho residem na proposição de uma modelagem univariada aliada a uma decomposição metodologicamente segura, onde a VMD é aplicada de forma contínua,

ou "rolling", garantindo que a decomposição de cada etapa de previsão seja realizada apenas com dados disponíveis até aquele momento, prevenindo, assim, o *data leakage* e fornecendo uma avaliação de desempenho mais robusta e realista para a previsão da umidade relativa do ar (HUANG et al., 2025; JIAO; HE, 2024).

Portanto, o presente estudo teve como objetivo avaliar o desempenho da previsão univariada da umidade relativa do ar utilizando o modelo BiLSTM tradicional em contrapartida a um modelo híbrido *Rolling VMD-BiLSTM*. Buscou-se avaliar em que medida a decomposição iterativa em janela deslizante, simulando o fluxo contínuo de dados reais e prevenindo o viés de antecipação, combinada com a modelagem bidirecional de longo prazo, pode aprimorar a precisão preditiva, oferecendo uma ferramenta mais confiável e metodologicamente rigorosa para o monitoramento meteorológico.

REVISÃO DA LITERATURA

A modelagem de séries temporais de UR apresenta desafios singulares devido à sua natureza estocástica, sazonal e não linear. Historicamente, a literatura foi dominada por modelos estatísticos lineares, especificamente a família ARIMA e SARIMA. No entanto, estudos fundamentais como os de Bayer, et al. (2017) demonstraram as limitações dessas abordagens clássicas: ao assumirem linearidade e normalidade nos dados, os modelos estatísticos falham em capturar picos extremos e mudanças abruptas de regime climático, exigindo parametrizações complexas que muitas vezes inviabilizam a aplicação em tempo real.

Para superar essas barreiras e suprir essa lacuna preditiva, a última década marcou a transição para o Aprendizado Profundo (*Deep Learning*), cujas técnicas têm se mostrado altamente promissoras. Özbek, et al. (2022) e Zenkner e Navarro-Martinez (2023) comprovaram que Redes Neurais Recorrentes, especialmente a arquitetura LSTM e sua variante bidirecional (BiLSTM), superam consistentemente os métodos clássicos. A arquitetura BiLSTM, em particular, processa a janela histórica de dados em ambas as direções (cronológica e reversa), permitindo que o modelo extraia dependências bidirecionais ricas do contexto passado antes de realizar a inferência preditiva (FAN, et al., 2024). Dessa forma, ela consegue extrair padrões temporais de longo prazo que são invisíveis aos modelos autorregressivos tradicionais.

Apesar da robustez das redes neurais, as séries temporais de umidade relativa do ar são caracterizadas por altos níveis de ruído, o que frequentemente limita o desempenho de modelos preditivos isolados. A previsão univariada baseada apenas em dados brutos encontra um teto de desempenho. Para mitigar esse problema e contornar os desafios inerentes aos dados meteorológicos, consolidou-se o uso de técnicas de decomposição de sinal. Durante muitos anos, a Decomposição Modal Empírica (EMD, do inglês *Empirical Mode Decomposition*) e sua variante *Ensemble* EMD (EEMD) foram o padrão para tratar a não estacionariedade. Contudo, a literatura recente aponta que a EMD sofre de graves deficiências matemáticas, principalmente o fenômeno da mistura de modos (*mode mixing*), onde oscilações de diferentes escalas são erroneamente agrupadas em uma única Função de Modo Intrínseco (GYAMERAH; OWUSU, 2024).

O estado da arte atual para o pré-processamento de sinais é a VMD. Conforme validado por Jiao e He (2024) e Fan, et al. (2024), a VMD é um método avançado que supera a EMD ao utilizar uma formulação variacional rigorosa. Ela decompõe a série original em subsinais mais estáveis, denominados Funções de Modo Intrínseco (IMFs, do inglês *Intrinsic Mode Functions*), cada um com uma banda de frequência específica (JIAO; HE, 2024). Ao contrário de métodos empíricos tradicionais, essa formulação matemática mitiga o fenômeno de *aliasing* de frequência central e isola efetivamente o ruído de alta frequência das tendências meteorológicas reais, facilitando o aprendizado da rede neural subsequente.

A combinação da VMD com a BiLSTM resulta em modelos híbridos que capturam tanto as características de frequência quanto as dependências temporais, otimizando a precisão da previsão (HUANG et al., 2025). Entretanto, a aplicação clássica dessa abordagem híbrida enfrenta um desafio metodológico crítico: o vazamento de dados (*data leakage*). A decomposição de todo o conjunto de dados simultaneamente (treino e teste) permite que informações futuras influenciem o treinamento do modelo, gerando resultados ilusórios e uma superestimação do desempenho preditivo (JI et al., 2023).

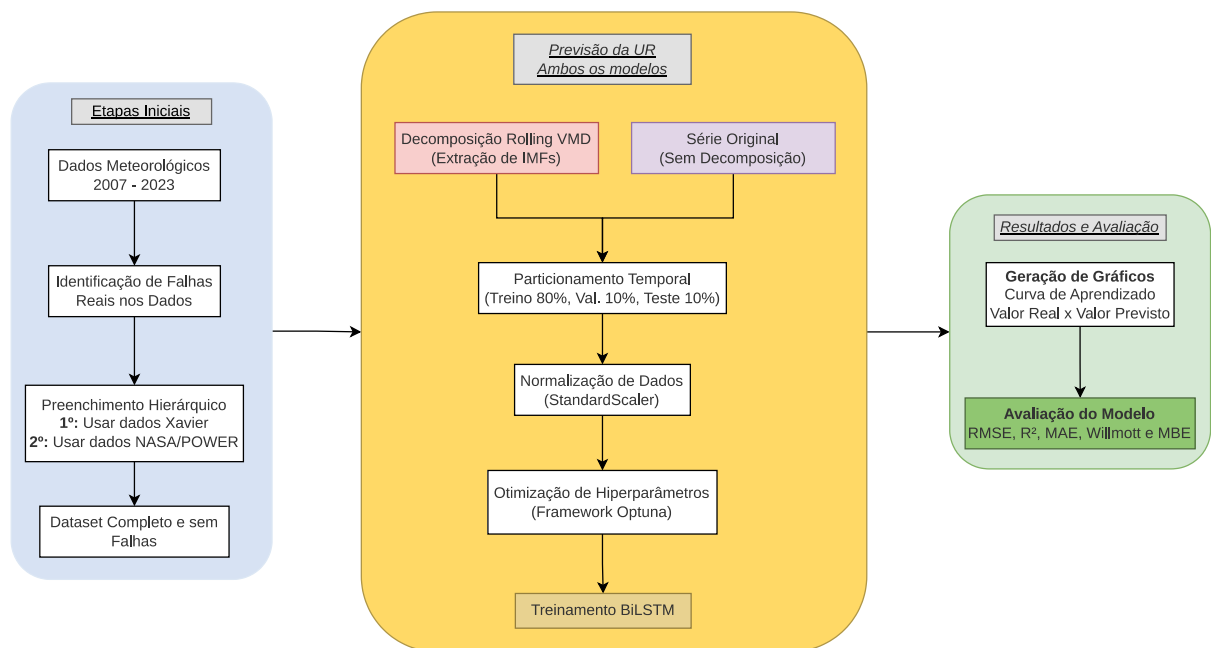
Para garantir a integridade científica da avaliação preditiva em cenários reais, Liu, et al. (2022) alertam que é mandatório o uso da abordagem *Rolling* VMD (Decomposição em Janela Deslizante). Neste método, a decomposição é recalculada iterativamente a cada passo de tempo, utilizando estritamente os dados históricos disponíveis até o momento da inferência, simulando com fidelidade o fluxo contínuo de dados em tempo real e prevenindo

o viés de antecipação. Apesar da complexidade computacional inerente à VMD iterativa, essa metodologia rigorosa assegura que o modelo híbrido opere em um ambiente que reflete com precisão as restrições de dados observadas em aplicações práticas, elevando a robustez e a confiabilidade das previsões (BALCI et al., 2023).

MÉTODOS

A seleção da área de estudo visou garantir a homogeneidade climática, fator crucial para a robustez do modelo. Para isso, utilizou-se a classificação do Global Yield Gap Atlas (GYGA), selecionando a zona climática 6801, que abrange oito municípios que apresentam estações meteorológicas de superfície do Instituto Nacional de Meteorologia (INMET) da região do estado do Paraná. O fluxograma dos principais estágios da pesquisa pode ser observado na Figura 1.

Figura 1 – Fluxograma dos principais estágios da pesquisa.



Fonte: Autoria Própria (2026).

A latitude, longitude e altitude das localidades avaliadas podem ser observadas na Tabela 1.

Tabela 1 – Localização, altitude e o período de coleta dos municípios avaliados na pesquisa.

Município	Latitude (°)	Longitude (°)	Altitude (m)	Período de Coleta
Castro	-24,79960871	-49,841671920	1017	2007 a 2021
Colombo	-25,30627281	-49,188483959	951	2017 a 2022
Curitiba	-25,47790945	-49,288244482	922	2007 a 2022
Dois Vizinhos	-25,75016221	-53,075368757	547	2008 a 2017
Inácio Martins	-25,63433971	-51,197468739	1209	2007 a 2022
Ivaí	-24,98717841	-50,859871177	806	2007 a 2022
Laranjeiras do Sul	-25,34618856	-52,383043014	891	2017 a 2022
São Mateus do Sul	-25,90820886	-50,441984003	776	2012 a 2022

Fonte: Instituto Nacional de Meteorologia – INMET (2026).

Utilizaram-se os dados meteorológicos históricos dos oito municípios. Foram coletados dados diários, provenientes das estações da superfície do INMET, tendo como variável de interesse a umidade relativa do ar (UR (%)). O tratamento inicial da série consistiu no preenchimento de falhas observacionais de forma hierárquica: primeiramente, as lacunas foram supridas utilizando a base de dados em grade XAVIER para o período compreendido até o ano de 2019. Os dados que permaneceram faltantes após essa etapa foram, em seguida, preenchidos com as estimativas do projeto NASA/POWER, consolidando um conjunto de dados contínuo e sem falhas. Este processo de preenchimento de falhas garantiu a construção de uma série temporal meteorológica perfeitamente contínua, coesa e isenta de falhas, estabelecendo uma base sólida para a modelagem preditiva.

Adicionalmente, considerando a forte influência da sazonalidade na umidade relativa do ar – caracterizada por oscilações anuais pronunciadas, como picos de umidade no inverno e quedas no verão em regiões subtropicais como o Paraná – procedeu-se à engenharia de *features* temporais para capturar explicitamente esses padrões periódicos. Representações lineares do tempo, como o dia sequencial do ano, apresentam uma descontinuidade matemática abrupta na transição de dezembro para janeiro, o que pode induzir artefatos nos modelos e comprometer a generalização. Para sanar essa limitação e representar o tempo de

forma contínua e cíclica, aplicou-se uma codificação trigonométrica padrão em séries temporais, também conhecida como *Cyclical Encoding* (BIN; HE, 2023), transformando o dia do ano d em duas variáveis predictoras independentes, pelas funções $f_1(d) = \text{sen}\left(\frac{2\pi}{365}\right)$ e $f_2(d) = \text{cos}\left(\frac{2\pi}{365}\right)$.

Esta transformação projeta a cronologia anual num espaço bidimensional circular, permitindo que a arquitetura BiLSTM reconheça matematicamente a adjacência entre o final de um ano e o início do subsequente, preservando a continuidade temporal. Estudos recentes em previsão de séries temporais com *Deep Learning* corroboram que a aplicação do seno e cosseno garante que a distância euclidiana entre o último período de um ciclo e o primeiro do ciclo seguinte seja mantida (BIN; HE, 2023). Dessa forma, garante-se uma modelagem otimizada das oscilações climáticas, mitigando perdas de desempenho nos extremos do calendário.

MODELAGEM COMPARATIVA E ROLLING VMD

O principal objetivo analítico desta pesquisa consiste em avaliar e comparar o desempenho de um modelo preditivo univariado puro baseado em redes BiLSTM em contraposição a um sistema híbrido, que acopla o algoritmo de decomposição deslizante à arquitetura BiLSTM.

A VMD é um método de processamento de sinais adaptativo e não-recursivo que decompõe uma série temporal $f(t)$ num conjunto de K sub-sinais ou IMFs, denotados por $u_k(t)$, garantindo que a informação total do sinal é preservada e permitindo que cada IMF represente uma componente distinta da série original (JIANG, 2023). Cada modo oscila em torno de uma frequência central específica ω_k . Matematicamente, a decomposição é formulada como um problema de otimização variacional restrito, que visa minimizar a soma das larguras de banda estimadas para cada modo (Eq. 1).

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right|_2^2 \right\} \quad (1)$$

Onde: $\{u_k\}$ representa o conjunto dos K modos intrínsecos (IMFs) resultantes da decomposição; $\{\omega_k\}$ são as respectivas frequências centrais de cada modo; $\delta(t)$ é a função

impulso (Delta de Dirac); j é a unidade imaginária ($j^2 = -1$); t é o tempo e ∂_t indica a derivada parcial em relação ao tempo. O operador $*$ denota a convolução espacial, utilizada para calcular o sinal analítico via Transformada de Hilbert, enquanto o termo $e^{-j\omega_k t}$ desloca o espectro de frequência do modo para a banda base. Por fim, $\|\cdot\|_2^2$ representa a norma L_2 ao quadrado.

Para o escopo deste estudo, os parâmetros da VMD não foram definidos de forma empírica, mas integrados à esteira de otimização automatizada do modelo. A partir dessa sintonia, os parâmetros de decomposição convergiram para um número de modos $K = 10$ e um fator de penalidade ou termo de balanceamento de fidelidade dos dados $\alpha = 3200$, com uma tolerância de convergência mantida em $\tau = 1.5 \times 10^{-7}$. Computacionalmente, a decomposição foi operacionalizada através da biblioteca *vmdbpy* em ambiente Python. Para o escopo preditivo deste trabalho, extraíram-se exclusivamente os modos intrínsecos resultantes da decomposição no domínio do tempo (u_k). Esses modos foram estruturados em uma matriz, na qual cada coluna representa um modo extraído e cada linha um ponto temporal, compondo o conjunto de atributos (*features*) de entrada para a rede neural.

O erro metodológico sistemático e severo amplamente reportado na literatura de previsão híbrida é a ocorrência de *Data Leakage* decorrente de aplicação do algoritmo de decomposição à série temporal completa, antes de realizar o particionamento temporal dos dados (GUO et al., 2023; HE et al., 2022). Tal prática introduz indevidamente informações estatísticas do futuro (conjunto de teste) no passado (conjunto de treino), gerando resultados de precisão artificialmente elevados, ilusórios e inaplicáveis no mundo real.

Para contornar definitivamente esta limitação, implementou-se a abordagem de *Rolling VMD* (VMD em janela deslizante). Neste paradigma, que simula fielmente o cenário operacional de previsão meteorológica, a série não é decomposta na sua totalidade de forma simultânea. O algoritmo é executado iterativamente, aplicando-se exclusivamente a cada janela de observação histórica individual. Para garantir a estabilidade espectral do algoritmo e permitir a identificação clara das frequências centrais dos modos, a dimensão da janela de decomposição do VMD foi estabelecida em 90 passos temporais ($t - 90$ até $t - 1$), capturando ciclos macro-meteorológicos equivalentes a três meses. Em cada passo do janelamento iterativo, este sinal passado é decomposto, e apenas os dados da matriz u referentes ao último instante de tempo são preservados para compor o conjunto de atributos

(features). Posteriormente, para o treinamento da rede neural BiLSTM, estruturou-se uma janela de *look-back* mais focada, utilizando os 45 passos temporais mais recentes de todas as features para prever o instante subsequente.

Em cada passo do janelamento iterativo, o sinal passado é decomposto, e apenas os dados da matriz u referentes ao último instante de tempo são preservados para compor o conjunto de atributos (*features*). Este rigor metodológico configura o principal trunfo desta pesquisa: ao isolar hermeticamente as janelas temporais, impede-se categoricamente que qualquer valor futuro influencie a extração das IMFs do passado. Desta forma, garante-se a preservação absoluta da causalidade temporal, assegurando que o desempenho do modelo híbrido é estritamente realista e isento de correlações espúrias.

PARTICIONAMENTO TEMPORAL E NORMALIZAÇÃO

A confiabilidade da avaliação em modelos de *Deep Learning* requer um esquema rigoroso de divisão dos dados. A série temporal foi particionada de forma estritamente cronológica, alocando 80% dos dados iniciais para a fase de treinamento, 10% para validação (otimização de hiperparâmetros) e os últimos 10% para o conjunto de teste (avaliação final do modelo).

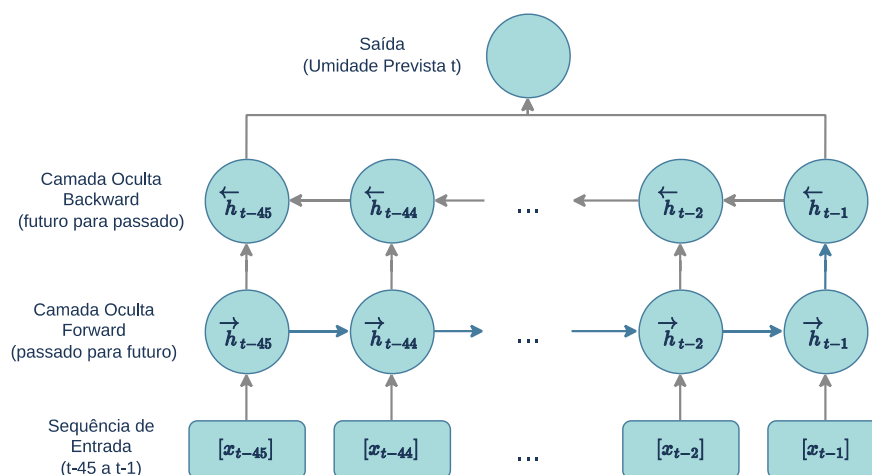
Para acelerar a convergência do gradiente e mitigar a instabilidade numérica, os dados foram submetidos a um processo de normalização estatística utilizando o método *StandardScaler* (Z-score), dado por $z = \frac{x-\mu}{\sigma}$. Essa transformação mapeia os dados para uma distribuição com média zero e desvio padrão unitário.

Onde x é o valor original da umidade, μ é a média aritmética da amostra de treinamento e σ , o seu respectivo desvio padrão. É fundamental ressaltar que os parâmetros de centralização e escala foram estimados exclusivamente a partir do conjunto de treinamento, sendo posteriormente aplicados aos dados de validação e teste para evitar a contaminação cruzada das informações (ZHANG et al., 2023). A estruturação sequencial dos dados foi baseada numa técnica de janelamento deslizante com 45 passos temporais para prever o passo de tempo subsequente.

OTIMIZAÇÃO E ARQUITETURA BILSTM

A arquitetura BiLSTM estende as capacidades das redes LSTM tradicionais ao processar a sequência de dados em duas direções simultâneas: no sentido direto (passado para o futuro) e no reverso (futuro para o passado), conforme esquematizado na Figura 2. Esta propagação bidirecional (*forward* e *backward*) permite que o modelo capture dependências temporais complexas em ambas as orientações da série histórica, aprimorando significativamente a precisão das previsões (YU et al., 2024).

Figura 2 – Estrutura esquemática da rede neural BiLSTM aplicada à previsão da umidade relativa do ar, ilustrando o processamento bidirecional da janela temporal de 45 passos.



Fonte: Autoria Própria (2026).

Para garantir a máxima eficácia preditiva sem depender de seleções arbitrárias, a definição dos hiperparâmetros foi conduzida através do *framework* de otimização Optuna. Foram exploradas configurações típicas de redes recorrentes como por exemplo, número de unidades LSTM, taxa de aprendizado, taxa de *Dropout* e tamanho de *batch*, por meio de uma busca sistemática. Cada modelo foi submetido a 80 *trials* independentes, tendo como critério objetivo a minimização do Erro Quadrático Médio (MSE) no conjunto de validação, o que assegura comparações consistentes entre as configurações e maior confiabilidade nos resultados obtidos (MULIA et al., 2025).

Um diferencial técnico implementado para maximizar a eficácia computacional foi a utilização de algoritmos de poda (*pruning*). Empregou-se o *HyperbandPruner* para o modelo univariado puro e o *MedianPruner* para o modelo híbrido, integrados através do

TFKerasPruningCallback. Essa abordagem interrompe prematuramente o treino de arquiteturas não promissoras, alocando os recursos de processamento exclusivamente para as configurações com maior potencial de convergência.

As arquiteturas finais otimizadas, selecionadas pelo *framework* Optuna por meio de 80 *trials* independentes com critério de minimização do Erro Quadrático Médio no conjunto de validação, que apresentam a melhor capacidade de generalização para a previsão da umidade relativa do ar, encontram-se sumarizadas e comparadas na Tabela 2. Para ambos os modelos univariado e híbrido VMD-BiLSTM, a estrutura base resultou no empilhamento de duas camadas ocultas BiLSTM, permitindo capturar dependências temporais complexas em ambas as direções da sequência histórica (YU P, et al., 2024). De modo a mitigar o sobreajuste (*overfitting*), incorporou-se uma técnica de regularização L2 aliada a uma taxa de *Dropout* otimizada, práticas consolidadas para estabilizar o treinamento de redes recorrentes profundas. A rede foi acoplada a uma camada densa de saída com ativação linear para regressão do valor contínuo e compilada utilizando o otimizador adaptativo Adam, amplamente reconhecido por sua robustez e eficiência em convergência para modelos LSTM/BiLSTM.

Tabela 2 – Hiperparâmetros otimizados pelas execuções do Optuna para as arquiteturas preditivas.

Hiperparâmetro	Modelo BiLSTM Puro	Modelo Híbrido VMD-BiLSTM
Look Back	45	45
K	-	10
Alpha	-	3200
Tol	-	0,00000015
<i>Learning Rate</i>	0,007	0,0025
<i>Dropout</i>	0,14	0,4
Regularização L2	0,0004	0,00001
Camada Oculta	128 / 32	64 / 32
Tamanho do Lote	128	256

Fonte: Autoria própria (2026).

Durante o processo de treino, a estabilidade e a convergência do gradiente foram otimizadas através do uso simultâneo de duas funções *callbacks* fundamentais: *EarlyStopping*, com monitoramento da perda no conjunto de validação e tolerância (*patience*) de 10 épocas, e *ReduceLROnPlateau*, que ajusta dinamicamente a taxa de aprendizado (*learning rate*) caso o erro estagne, garantindo um refinamento preciso dos pesos sinápticos.

O treinamento foi executado recorrendo a uma unidade de processamento gráfico (NVIDIA RTX 3060). Para acelerar o treino e reduzir o consumo de memória VRAM sem sacrificar a estabilidade numérica, ativou-se a API de precisão mista (*Mixed Precision*). Adicionalmente, para assegurar a reprodutibilidade integral dos resultados, todas as *seeds* estocásticas foram mixadas e as operações convolucionais e recorrentes do backend (cuDNN) foram configuradas para o modo determinístico.

MÉTRICAS DE AVALIAÇÃO

O desempenho preditivo dos modelos foi avaliado e comparado com base em cinco métricas estatísticas de erro e ajustamento amplamente consolidadas e recomendadas na literatura hidrometeorológica para avaliações robustas de precisão, viés e capacidade preditiva em séries temporais, fornecendo uma análise complementar e multidimensional dos resultados (YU P, et al., 2024; ZHANG X, et al., 2023). Essas métricas são apresentadas na Tabela 3:

Tabela 3 – Métricas Estatísticas de Erro e Ajustamento.

Métrica	Fórmula	Interpretação
RMSE	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	Mede a magnitude dos erros quadráticos médios, penalizando discrepâncias maiores e sensível a outliers.
MAE	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	Avalia o erro médio absoluto, robusto a outliers e interpretável em unidades originais dos dados.

MBE

$$MBE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)$$

Quantifica o viés sistemático das previsões, indicando tendência de super ou subestimação.

R^2

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

Representa a proporção da variância explicada pelo modelo, com valores próximos a 1 indicando bom ajuste.

d

$$d = 1 - \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{\sum_{i=1}^n (|y_i - \bar{y}| + |\hat{y}_i - \bar{y}|)}$$

Avalia a proximidade entre observados e previstos, com $d=1$ para previsão perfeita, superior ao R^2 em séries não lineares.

Nas equações apresentadas, y_i representa o valor empírico observado da umidade relativa do ar, \hat{y}_i é o valor estimado pelo modelo preditivo, \bar{y} corresponde à média aritmética dos valores observados e n é o tamanho total da amostra avaliada. Destaca-se que a métrica d refere-se ao Índice de Concordância de Willmott.

RESULTADOS

A avaliação do desempenho preditivo dos modelos univariados para a previsão da Umidade Relativa (UR) do ar foi realizada utilizando o conjunto de dados de teste (referente aos 10% finais da série cronológica). Os dados de saída foram submetidos ao cálculo das métricas estatísticas estabelecidas na metodologia, permitindo quantificar a magnitude do erro e o grau de ajustamento de cada arquitetura perante dados não vistos durante a fase de treinamento.

A síntese dos resultados quantitativos, alcançados após o processo de otimização de hiperparâmetros conduzido pelo *framework* Optuna, encontra-se detalhada nas Tabelas 4 e 5. A Tabela 4 apresenta o desempenho da rede BiLSTM tradicional alimentada com os dados brutos, enquanto a Tabela 5 expõe as métricas obtidas pela abordagem híbrida *Rolling VMD-BiLSTM*.

Tabela 4 – Desempenho preditivo do modelo univariado BiLSTM puro para a Umidade Relativa do ar no conjunto de teste.

Métrica	Valor Obtido
RMSE	7,7199
MAE	6,0644
MBE	0,5716
R^2	0,4559
d	0,7738

Fonte: Autoria própria (2026).

Tabela 5 – Desempenho preditivo do modelo híbrido *Rolling* VMD-BiLSTM para a umidade relativa do ar no conjunto de teste.

Métrica	Valor Obtido
RMSE	6,5903
MAE	5,0751
MBE	-0,0953
R^2	0,6034
d	0,8548

Fonte: Autoria própria (2026).

A comparação entre os resultados evidencia diferenças quantitativas de desempenho entre as abordagens. Observou-se no modelo *Rolling* VMD-BiLSTM uma queda no RMSE de 7,7199 para 6,5903 (uma redução de 14,63%) e no MAE de 6,0644 para 5,0751 (uma redução de 16,31%) em relação ao modelo BiLSTM puro.


No que tange ao viés preditivo, o MBE revelou comportamentos distintos. A arquitetura baseada em dados brutos registrou um MBE positivo de 0,5716, apontando para uma subestimação residual ao longo da série de testes. O modelo com acoplamento da VMD em janela deslizante apresentou um MBE de -0,0953, valor mais próximo da neutralidade estatística.

A análise do ajuste de variância demonstra que o modelo BiLSTM puro obteve um R^2 de 0,4559. Com o janelamento *Rolling* VMD, o R^2 aumentou para 0,6034, o que representa

um incremento percentual de 32,35%. O d acompanhou essa métrica, passando de 0,7738 no modelo puro para 0,8548 no modelo híbrido.


O comportamento dinâmico do ajustamento entre os valores observados e previstos ao longo do tempo pode ser visualizado nas Figuras 2 e 3, que apresentam recortes temporais da série de teste para o modelo puro e híbrido, respectivamente.

Figura 2 – Comparativo temporal entre os valores observados de UR (%) e os valores previstos pelo modelo BiLSTM (puro) no conjunto de teste.



Fonte: Autoria própria (2026).

Figura 3 – Comparativo temporal entre os valores observados de UR e os valores previstos pelo modelo Rolling VMD-BiLSTM no conjunto de teste.



Fonte: Autoria própria (2026).

A análise visual do comportamento preditivo do modelo BiLSTM puro (Figura 2) denota que a curva de valores previstos apresenta menor amplitude de variação em relação à série observada. Especificamente, durante os eventos de saturação atmosférica (registros empíricos próximos a 100% de umidade), a linha projetada pelo modelo tende a formar platôs

em faixas inferiores, evidenciando subestimação dos extremos superiores da distribuição. De forma análoga, nos vales caracterizados por acentuada queda de umidade (tempo seco), as estimadas projetadas permanecem acima dos valores reais medidos. Constata-se, adicionalmente, uma defasagem visual temporal (*lag*) nas reversões de tendência, onde o modelo puro registra as oscilações agudas do clima com atraso perceptível em relação ao instante de ocorrência do evento.

No contexto prático e operacional, essa defasagem temporal e a incapacidade do modelo BiLSTM puro de capturar a magnitude real dos extremos – conforme visualizado na Figura 2 e quantificado pelo RMSE de 7,7199 e R^2 de 0,4559 na Tabela 4 (YU et al., 2024; ZHANG et al., 2023) – representam limitações críticas para aplicações em tempo real. A subestimação estrutural de picos de saturação atmosférica e o atraso no registro das reversões climáticas abruptas comprometem a antecipação ágil de cenários de risco, como alertas para mitigação da proliferação de fungos fitopatogênicos na agricultura ou prevenção do agravamento de doenças respiratórias em populações vulneráveis durante secas severas.

Em contraste, a trajetória temporal gerada pelo modelo híbrido *Rolling* VMD-BiLSTM (Figura 3) exibe considerável sobreposição morfológica à série observada, mitigando o efeito de suavização identificado na arquitetura univariada padrão. Ao rastrear as flutuações diárias de alta frequência com alinhamento de fase e corrigir a defasagem temporal (*lag*) observada anteriormente, a abordagem híbrida comprova ser uma ferramenta metodologicamente mais rigorosa e confiável para o monitoramento meteorológico e para a tomada de decisões preventivas.

DISCUSSÃO

Os resultados obtidos indicam que a decomposição prévia da série temporal de umidade relativa do ar afeta diretamente o ajuste preditivo dos modelos avaliados. O modelo híbrido *Rolling* VMD-BiLSTM apresentou métricas de erro inferiores em relação ao modelo univariado base, registrando redução de 14,64% no RMSE e incremento de 32,35% no R^2 . Estes dados sugerem que o isolamento de ruídos de alta frequência e a extração de IMFs auxiliam na otimização dos pesos sinápticos na arquitetura da rede recorrente.

A análise do comportamento preditivo do modelo BiLSTM puro (Figura 2) demonstra que a curva de valores previstos apresenta menor amplitude de variação em

relação à série observada. Durante os eventos de saturação atmosférica (registros empíricos próximos a 100% de umidade), a linha projetada pelo modelo tendeu a suavizar a resposta em faixas inferiores, indicando a subestimação dos extremos superiores da distribuição. De forma análoga, nos vales caracterizados por queda de umidade, as estimativas projetadas permaneceram acima dos valores mais medidos. Constatou-se, adicionalmente, uma defasagem visual temporal (*lag*) nas reversões de tendência, cenário no qual o modelo computou as variações meteorológicas com atraso em relação ao instante de ocorrência do evento empírico.

No contexto de aplicação operacional, a defasagem temporal e a subestimação da magnitude dos extremos pelo modelo univariado base — conforme ilustrado na Figura 2 e quantificado pelo RMSE de 7,7199 e R^2 de 0,4559 na Tabela 4 — constituem restrições técnicas para sistemas de monitoramento contínuo. O retardo no registro de reversões climáticas e a suavização de picos de saturação atmosférica interferem na antecipação de cenários de risco, o que pode limitar a utilidade do modelo para a emissão de alertas como a formulação de alertas para mitigação da proliferação de fungos fitopatogênicos na agricultura ou a prevenção do agravamento de doenças respiratórias durante secas severas.

As estimativas geradas pelo modelo híbrido *Rolling VMD-BiLSTM* (Figura 3), em contrapartida, apresentam maior alinhamento à série observada, atenuando o efeito de suavização identificado na arquitetura univariada padrão. Ao rastrear as flutuações diárias com alinhamento de fase e reduzir a defasagem temporal (*lag*), a abordagem híbrida demonstra potencial como uma ferramenta metodológica viável e de maior precisão estatística para o monitoramento meteorológico e suporte à tomada de decisão.

Estes achados estão em consonância com a literatura recente, que aponta vantagens na transição de modelos estatísticos clássicos para abordagens de *Deep Learning* acopladas a técnicas de processamento de sinais (HANOON et al., 2021; ZENKNER; NAVARRO-MARTINEZ, 2023). Um aspecto metodológico enfatizado neste estudo é a mitigação do *data leakage*. Conforme alertado por Liu et al. (2022) e Ji et al. (2023), a aplicação do VMD convencional sobre a totalidade da série temporal pode introduzir viés de antecipação, o que tende a gerar métricas de desempenho enviesadas. Ao adotar o *Rolling VMD*, buscou-se garantir que a decomposição em cada instante ocorresse estritamente com dados históricos,

visando obter métricas de desempenho mais condizentes com cenários práticos de previsão contínua.

No que tange às características da modelagem, a natureza univariada da abordagem apresenta implicações teóricas e práticas. Por um lado, constitui uma limitação estrutural, visto que omite as interações termodinâmicas da UR com outras variáveis meteorológicas, como temperatura e pressão atmosférica, que podem influenciar sua dinâmica (PIGNATELLI; ROMOLI; VIGNOLI, 2025). Por outro lado, a capacidade do modelo *Rolling VMD-BiLSTM* de explicar a variância dos dados ($R^2 = 0,6034$) utilizando exclusivamente os registros históricos da própria variável evidencia a viabilidade matemática da extração de padrões temporais por meio da decomposição iterativa. Como limitação computacional, ressalta-se que a execução sequencial do *Rolling VMD* eleva substancialmente o custo de processamento, impondo possíveis restrições para implementações de *nowcasting* (pequena escala) em arquiteturas de computação de borda (*edge computing*).

CONCLUSÃO

O presente estudo cumpriu o seu objetivo ao quantificar o impacto da decomposição iterativa em janela deslizante (*Rolling VMD*) acoplada a uma rede neural recorrente bidirecional (BiLSTM) na previsão univariada da umidade relativa do ar. A principal variável de controle metodológico da pesquisa consistiu na supressão do viés de antecipação (*data leakage*), garantindo que a extração de características do sinal ocorresse estritamente com dados históricos. Esta abordagem assegura que as métricas de avaliação alcançadas possuem representatividade e validade prática para cenários reais de previsão.

A síntese dos resultados demonstrou que a arquitetura híbrida resultou em maior precisão estatística face ao modelo base, evidenciada pela redução da magnitude do erro e pelo incremento na variância explicada. Operacionalmente, a decomposição prévia mitigou a defasagem temporal (*lag*) e reduziu a subestimação de extremos, limitações que afetam a rede padrão. Conclui-se, portanto, que a modelagem *Rolling VMD-BiLSTM* se constitui como uma alternativa algorítmica rigorosa e fidedigna para a predição de séries meteorológicas, oferecendo suporte robusto a sistemas de monitoramento contínuo e emissão de alertas.

REFERÊNCIAS

- BALCI, M. et al. Multiple decomposition-aided long short-term memory network for enhanced short-term wind power forecasting. *IET Renewable Power Generation*, v. 18, n.3, p. 331-347, 2023.
- BAYER, F. M. et al. Kumaraswamy autoregressive moving average models for double bounded environmental data. *Journal of Hydrology*, v. 555, p. 385-396, 2017.
- BIN, F.; HE, J. A short-term photovoltaic power prediction model using cyclical encoding and STL decomposition based on LSTM. [S. l.], p. 260-266, 2023.
- FAN, Y. et al. BiLSTM-MLAM: A Multi-Scale Time Series Prediction Model for Sensor Data Based on Bi-LSTM and Local Attention Mechanisms. *Sensors*, v. 24, n. 12, p. 3962, 2024.
- FERREIRA, A. et al. Evaluation of Evapotranspiration in Brazilian Cerrado Biome Simulated with the SWAT Model. *Water*, v. 13, n. 15, p. 2037, 2021.
- GIMÉNEZ, P. O.; GARCÍA-GALIANO, S. G. Assessing Regional Climate Models (RCMs) Ensemble-Driven Reference Evapotranspiration over Spain. *Water*, v. 10, n. 9, p. 1181, 2018.
- GLOBAL YIELD GAP ATLAS. Climate zones. [S. l.], 2025. Disponível em: <https://www.yieldgap.org/web/guest/climate-zones>. Acesso em: 26 fev. 2026.
- GUO, S. et al. Monthly runoff prediction using the VMD-LSTM-Transformer hybrid model: a case study of the Miyun Reservoir in Beijing. *Journal of Water and Climate Change*, v. 14, n. 9, p. 3221-3236, 2023.
- GYAMERAH, S. A.; OWUSU, V. Short- and long-term weather prediction based on a hybrid of CEEMDAN, LMD, and ANN. *PLoS ONE*, v. 19, n. 7, p. e0304754, 2024.
- HANOON, M. S. et al. Developing machine learning algorithms for meteorological temperature and humidity forecasting at Terengganu state in Malaysia. *Scientific Reports*, v. 11, n. 1, 2021.
- HE, M. et al. Can sampling techniques improve the performance of decomposition-based hydrological prediction models? Exploration of some comparative experiments. *Applied Water Science*, v. 12, n. 8, 2022.
- HUANG, M. L. et al. A Deep Learning Model Integrating EEMD and GRU for Air Quality Index Forecasting. *Atmosphere*, v. 16, n. 9, p. 1095, 2025.
- JI, Q. et al. Short-term prediction of the significant wave height and average wave period based on the variational mode decomposition-temporal convolutional network-long short-term memory (VMD-TCN-LSTM) algorithm. *Ocean science*, v. 19, n. 6, p. 1561-1578, 2023.

- JIANG, X. A combined monthly precipitation prediction method based on CEEMD and improved LSTM. PLOS ONE, v. 18, n. 7, p. e0288211, 2023.
- JIAO, X.; HE, Z. A novel coupled rainfall prediction model based on stepwise decomposition technique. Scientific Reports, v. 14, n. 1, 2024.
- LIU, C. et al. A Prediction Method with Data Leakage Suppression for Time Series. IEEE Access, 2022.
- MALL, R. K. et al. Impact of climate variability on human health: A pilot study in a tertiary care hospital of Eastern Uttar Pradesh, India. MAUSAM, v. 68, n. 3, p. 429-438, 2017.
- MULIA, I. E. et al. Multi-horizon prediction of tropical cyclone intensity and its interpretability with temporal fusion transformer. Scientific Reports, v. 15, n. 1, p. 31284, 2025.
- NASA. Prediction Of Worldwide Energy Resources (POWER). Surface meteorology and Solar Energy (SSE). Disponível em: <https://power.larc.nasa.gov/>. Acesso em: 26 fev. 2026.
- ÖZBEK, A. et al. Daily average relative humidity forecasting with LSTM neural network and ANFIS approaches. Research Square, 2022.
- PIGNATELLI, A. et al. A study of the radon seasonality with temporal dummy variables. Scientific Reports, v. 15, n. 1, 2025.
- VELÁSQUEZ, A. C. et al. Plant and pathogen warfare under changing climate conditions. Current biology, v. 28, n. 10, p. R619-R634, 2018.
- XAVIER, A. C. et al. New improved Brazilian daily weather gridded data (1961–2020). International Journal of Climatology, v. 42, n. 16, p. 8390-8404, 2022.
- YU, P. et al. Crustal permeability generated through microearthquakes is constrained by seismic moment. Nature Communications, v. 15, n. 1, 2024.
- ZENKNER, G.; NAVARRO-MARTINEZ, S. A flexible and lightweight deep learning weather forecasting model. Applied Intelligence, 2023.
- ZHANG, X. et al. Comparative study of rainfall prediction based on different decomposition methods of VMD. Scientific Reports, v. 13, n. 1, p. 20127, 2023.
- ZHOU, J. et al. Progress in Research on Prevention and Control of Crop Fungal Diseases in the Context of Climate Change. Agriculture, v. 14, n. 7, p. 1108, 2024.