

ARTIGO DE PESQUISA/RESEARCH PAPER

Avaliação de Desempenho de Classificadores a Partir de Dados Relacionados à Precipitação Pluviométrica Coletados por Estação Meteorológica Automática

Performance Evaluation of Classifiers Based on Rainfall-Related Data Collected by an Automatic Weather Station.

Ananias Caetano de Oliveira  [Instituto Federal do Ceará | ananiacaetano.ifce@gmail.com]

Rhyan Ximenes de Brito  [Instituto Federal do Ceará | rryan.brito@ifce.edu.br]

Maria Auxiliadora de Oliveira Chaves  [Instituto Federal do Ceará | auxiliadora.chaves09@aluno.ifce.edu.br]

Roney Nogueira de Sousa  [Instituto Federal do Ceará | roney.nogueira.sousao8@aluno.ifce.edu.br]

Adonias Caetano de Oliveira  [Instituto Federal do Ceará | adonias.oliveira@ifce.edu.br]

Paulo César de Almeida Júnior  [Instituto Federal do Ceará | paulo.almeida@ifce.edu.br]

 Bacharelado em Ciência da Computação, Instituto Federal de Educação, Ciência e Tecnologia do Ceará Campus Tianguá, AV. Tabelião Luiz Nogueira de Lima, 62324-075, Brasil.

Resumo. A previsão de precipitação é essencial para o planejamento e a gestão dos recursos hídricos, afetando áreas como agricultura, geração de energia, planejamento urbano e conservação da água. No caso da agricultura, essa previsão permite a coleta de dados precisos sobre a distribuição e quantidade das chuvas, otimizando o uso da água e aumentando a produtividade. Este estudo explora a aplicação de diferentes abordagens clássicas de aprendizado de máquina na previsão de precipitações, utilizando um conjunto de dados pluviométricos de Tianguá (CE), abrangendo etapas como pré-processamento, balanceamento de dados, avaliação de nove modelos diferentes e explicação local de um modelo. O objetivo é realizar uma análise comparativa do desempenho de algoritmos como *Logistic Regression* (LR), *Naive Bayes* (NB), *Extra Tree* (ET), *Extreme Learning Machine* (ELM), *k-nearest neighbors* (*k*-NN), *Multilayer Perceptron* (MLP), *Random Forest* (RF), *Support Vector Machines* (SVM) e um modelo ensemble. Além disso, foi aplicado o método *Local Interpretable Model-Agnostic Explanations* (LIME), visando identificar o modelo mais adequado e compreender os atributos que mais influenciam as classificações. Essa abordagem fornece insights valiosos para a melhoria da performance em estudos futuros, como a aplicação de técnicas de seleção de atributos. Entre os modelos testados, o ensemble baseado na votação majoritária de quatro algoritmos apresentou a melhor performance geral, com acurácia de 85% e excelente equilíbrio no *F1-Score*, tornando-o uma escolha robusta para aplicações que requerem previsões confiáveis. Embora o modelo NB tenha mostrado menor acurácia (76%), destacou-se pela alta precisão (91%), indicando que, quando previa chuva, quase sempre acertava, além de apresentar excelente sensibilidade para detectar ausência de precipitação (*recall* de 88%). Outros modelos registraram acurácia entre 83% e 84%, sendo alternativas viáveis conforme as necessidades específicas de cada aplicação. Ao explicar o modelo ET por meio do método LIME, a análise das dez primeiras previsões do conjunto de teste apontou que as características mais influentes para prever chuvas incluíram umidade máxima e instantânea, além de temperatura mínima e instantânea, enquanto fatores como temperatura máxima e umidade mínima foram mais relevantes para prever a ausência de chuvas.

Abstract. Precipitation forecasting is essential for the planning and management of water resources, affecting areas such as agriculture, energy generation, urban planning, and water conservation. In the case of agriculture, this forecasting enables the collection of accurate data on rainfall distribution and quantity, optimising water usage and increasing productivity. This study explores the application of different classical machine learning approaches to precipitation forecasting, using a pluviometric dataset from Tianguá (CE), encompassing stages such as pre-processing, data balancing, evaluation of nine different models, and local explanation of a model. The objective is to conduct a comparative analysis of the performance of algorithms such as Logistic Regression (LR), Naive Bayes (NB), Extra Tree (ET), Extreme Learning Machine (ELM), k-nearest neighbours (*k*-NN), Multilayer Perceptron (MLP), Random Forest (RF), Support Vector Machines (SVM), and an ensemble model. Additionally, the Local Interpretable Model-Agnostic Explanations (LIME) method was applied, aiming to identify the most suitable model and understand the attributes that most influence the classifications. This approach provides valuable insights for improving performance in future studies, such as the application of feature selection techniques. Among the tested models, the ensemble based on the majority vote of four algorithms demonstrated the best overall performance, with an accuracy of 85% and excellent balance in the F1-Score, making it a robust choice for applications requiring reliable predictions. Although the NB model showed lower accuracy (76%), it stood out for its high precision (91%), indicating that when it predicted rain, it was almost always correct, as well as demonstrating excellent sensitivity in detecting the absence of precipitation (*recall* of 88%). Other models recorded accuracy rates between 83% and 84%, making them viable alternatives depending on the specific needs of each application. When explaining the ET model using the LIME method, the analysis of the first ten predictions from the test set revealed that the most influential features for predicting rain included maximum and instantaneous humidity, as well as minimum and instantaneous temperature, while factors such as maximum temperature and minimum humidity were more relevant for predicting the absence of rain.

Palavras-chave: Aprendizado de Máquina, Precipitação, Inteligência Artificial Explicável, Modelos clássicos, Recursos hídricos.

Keywords: Machine Learning, Precipitation, Explainable Artificial Intelligence, Classical Models, Water Resources.

1 Introdução

Compreender e prever a precipitação é essencial para o planejamento e a gestão dos recursos hídricos, influenciando áreas como a agricultura, a geração de energia, o planejamento urbano e a conservação da água Sousa *et al.* [2021]; Dotse *et al.* [2024]; Ribeiro [2024]. No caso da agricultura, a previsão de precipitação permite a coleta de informações precisas sobre a quantidade e distribuição das chuvas, otimizando a utilização da água e aumentando a produtividade Borella *et al.* [2022]. No setor de energia, o planejamento elétrico preocupa-se com as previsões de precipitação que afetam os níveis dos reservatórios Pereira Filho *et al.* [2020].

A Inteligência Artificial (IA) demonstra extrema eficiência na previsão de precipitação. Por meio de algoritmos avançados e técnicas de Aprendizado de Máquina (ML, do inglês *Machine Learning*), a IA é capaz de processar grandes volumes de dados meteorológicos ao longo do tempo, identificando padrões e condições que são difíceis de detectar com métodos tradicionais Ardabili *et al.* [2020]; Latif and Ahmed [2023]; Danandeh Mehr *et al.* [2023]; Waqas *et al.* [2023]; Dotse *et al.* [2024]. Essa capacidade rápida de processamento e análise permite previsões precisas e realistas sobre a quantidade e a distribuição da precipitação, o que é essencial para a gestão eficiente dos recursos hídricos e a mitigação dos riscos ambientais Dotse *et al.* [2024]. Além disso, a IA pode integrar diversas fontes de dados, como imagens de satélite e informações meteorológicas, ajustando as previsões em tempo real e respondendo de forma mais eficaz a eventos extremos Parmar *et al.* [2017]; Latif and Ahmed [2023].

Apesar dos avanços em ML, especialmente por meio do aprendizado profundo, na tarefa de previsão de precipitações Ardabili *et al.* [2020]; Latif and Ahmed [2023], os algoritmos clássicos de ML também apresentam resultados promissores em um tamanho menor de modelo Parmar *et al.* [2017]; Dotse *et al.* [2024]. Ademais, muitas aplicações cotidianas de algoritmos de classificação não necessitam de modelos muito complexos Fernández-Delgado *et al.* [2014]. Considerando essas condições de aplicações, este estudo avalia o desempenho de modelos de ML na tarefa de identificar condições meteorológicas para a ocorrência ou não de precipitações, utilizando dados meteorológicos do município de Tianguá (CE).

Considerando que o conjunto de dados Ximenes de Brito *et al.* [2025] deste trabalho não foi amplamente avaliado em estudos anteriores Sousa *et al.* [2021], é significante uma investigação dos modelos clássicos na predição de precipitações, bem como explicação de como as previsões são obtidas. Por isso, este estudo exploratório visa contribuir com uma análise comparativa de desempenho dos algoritmos *Logistic Regression* (LR), *Naive Bayes* (NB), *Extra Tree* (ET), *Extreme Learning Machine* (ELM), *k-nearest neighbors* (*k*-NN), *Multilayer Perceptron* (MLP), *Random Forest* (RF), *Support Vector Machines* (SVM) e um modelo ensemble na identificação de precipitações. Para avaliação de desempenho foram adotadas as métricas de acurácia, precisão, sensibilidade (ou *recall*) e medida-F1 (F1-macro).

Ademais, a decisão de cada um dos modelos avaliados neste estudo pode ser questionada, pois o desempenho dos modelos de ML pode variar conforme o conjunto de dados.

Assim, como contribuição deste trabalho, é abordado a ex-
plicabilidade de um modelo utilizando o método *Local Interpretable Model-Agnostic Explanations* (LIME) Ribeiro *et al.* [2016] para determinar o modelo mais adequado para previsão. Essa análise é útil para determinar os atributos do conjunto de dados que mais influenciam na classificação, ou seja, mostrar caminhos para melhorar a classificação em trabalhos futuros que podem, por exemplo, aplicar seleção de atributos.

O restante deste artigo está organizado da seguinte forma. A Seção 2 relata os trabalhos relacionados com este estudo, enquanto o material e os métodos são apresentados na Seção 3. A Seção 4 apresenta os resultados e discute os achados desta estudo. Finalmente, a Seção 5 contém as principais considerações deste estudo.

2 Trabalhos Relacionados

Diversos estudos de revisão analisaram a previsão de chuvas utilizando modelos de aprendizado de máquina (ML), destacando a superioridade de Redes Neurais Artificiais (RNAs) sobre técnicas estatísticas tradicionais Parmar *et al.* [2017]. Revisões recentes focaram na avaliação de modelos de IA, incluindo RNAs e aprendizado profundo, com destaque para a eficácia de modelos híbridos que combinam técnicas como transformação wavelet e bootstrapping, especialmente em contextos como a Tailândia Waqas *et al.* [2023].

A eficácia de modelos híbridos de ML para previsão de chuvas também foi analisada comparando-os com modelos ML individuais, destacando como a integração de técnicas de pré-processamento de dados e algoritmos de otimização melhora a precisão e reduz a incerteza nas previsões Dotse *et al.* [2024]. A aplicabilidade de modelos de ML, como a regressão por vetor de suporte, mostrou-se dependente da região climática, necessitando de ajustes para diferentes contextos geográficos Latif and Ahmed [2023]. Além disso, estudos exploratórios com Redes Neurais Convolucionais (CNNs) demonstraram a eficácia de arquiteturas como VGGNet e LeNet na previsão de precipitações pluviométricas Sousa *et al.* [2021], e modelos híbridos como CNN-LSTM foram validados para previsão de secas meteorológicas, superando modelos de referência Danandeh Mehr *et al.* [2023].

Em contraste com os trabalhos de Sousa, Brito e Ximenes Sousa *et al.* [2021] e Danandeh Mehr *et al.* Danandeh Mehr *et al.* [2023] que exploram modelos de aprendizado profundo, este estudo primário realiza uma análise comparativa de desempenho de modelos clássicos, mais especificamente, modelos baseados em distância (*k*-NN), em probabilidade (NB), em otimização (SVM), *ensemble* e redes neurais (ELM e MLP) na tarefa de classificação de condições para ocorrência de chuvas. Ademais, este estudo realiza uma exploração de um modelo explicativo para compreender os atributos que mais influenciam na saída de predição dos modelos, o que não foi abordado por nenhum dos trabalhos relacionados.

3 Materiais e Métodos

Esta seção descreve os procedimentos metodológicos adotados neste trabalho, dividida em duas subseções: (i) Conjunto de dados e pré-processamento; e (ii) Treinamento, avaliação e explicação dos modelos.

3.1 Conjunto de dados e pré-processamento

O conjunto de dados Ximenes de Brito *et al.* [2025], denominado Conjunto de Dados Tianguá (A368) de Precipitações, foi coletado por meio de uma estação meteorológica automática localizada em Tianguá, um município do Estado do Ceará. Ela pode ser encontrada no banco de dados do Instituto Nacional de Meteorologia (INMET) do Brasil. Os dados foram coletados entre 15/03/2018 e 11/05/2021, gerando assim um total de 27655 registros. O conjunto de dados pode ser acessado na seção Disponibilidade de dados e materiais.

O conjunto de dados é composto por 19 atributos, as quais representam as grandezas relativas à temperatura do ar, umidade relativa do ar, temperatura do ponto de orvalho, pressão atmosférica do ar, velocidade do vento, direção do vento, intensidade da rajada do vento e radiação solar, em que algumas dessas categorias variam entre valor instantâneo, mínimo e máximo.

Com a finalidade de mitigar os efeitos do *overfitting*, durante a etapa de pré-processamento de dados, as amostras que possuíam atributos ausentes ou informações redundantes foram descartadas. Além dessas informações, também foram descartadas informações que não estavam relacionadas com o processo de classificação, tais como os atributos data, hora e radiação, por não possuírem aplicação ou conterem metade dos registros nulos, como foi o caso para o terceiro excluído.

A quantidade de colunas foi reduzida para 16 colunas, sendo uma coluna o atributo alvo ou variável desfecho. Essa variável desfecho, chuva (mm), foi tratada considerando a ocorrência de chuvas na região. Sendo assim, as classes foram codificadas de forma que as que foram consideradas “0” são dadas como a “Não ocorreu precipitações”, já as classes codificadas como “1”, são referentes ao caso de “Ocorreu precipitações” a presença de chuva.

Para garantir o balanceamento do conjunto de dados, ou seja, manter a mesma quantidade de amostras por classe foi utilizada a técnica *Random Undersampling*. Essa técnica de balanceamento consiste na remoção aleatória de amostras da classe majoritária. Ela foi escolhida por ser uma das estratégias mais simples para lidar com dados desbalanceados, reduzir a pressão sobre o armazenamento de dados e também melhorar o tempo de execução. No entanto, a remoção de dados pode levar à perda de informações úteis Mishra [2017]. Após toda a etapa de pré-processamento, restaram 2.886 amostras de 27.695 ao todo do conjunto de dados original. A Figura 1a exibe o equilíbrio entre as amostras por classe, isto é, 1.443 amostras por classe.

Foi utilizado a técnica t-SNE que permite visualizar dados de alta dimensão, como este conjunto dados de precipitações, de modo que cada ponto de dados refere-se a uma localização em um mapa bidimensional ou tridimensional. As visualizações produzidas pelo t-SNE são significativamente melhores do que aquelas produzidas pelas outras técnicas em quase todos os conjuntos de dados Maaten and Hinton [2008]. Observa-se pela Figura 1b que a predição de precipitações é um problema não linear, ou seja, um problema de difícil classificação.

3.2 Treinamento, avaliação e explicação dos modelos

Os algoritmos foram implementados em Python usando a biblioteca *Scikit-learn* Pedregosa *et al.* [2011] realizando ajuste fino dos algoritmos pelo método *GridSearch*. O conjunto de dados foi dividido em 80% para treinamento e validação dos algoritmos mediante a validação cruzada *10-fold* e 20% para teste dos modelos. Foi treinado um modelo de ensemble *Voting Classifier* a partir de modelos de aprendizado de máquina já treinados (LR, *k*-NN, SVM e RF). Esse modelo combina as previsões dos quatro modelos usando votação majoritária para classificar uma instância do conjunto de teste.

As métricas utilizadas neste artigo foram baseadas na matriz de confusão, conforme mostrado na Tabela 1. As métricas são calculadas com base nos seguintes valores dispostos na matriz: Verdadeiro positivo (VP), Verdadeiro negativo (VN), Falso positivo (FP) e Falso negativo (FN).

O desempenho dos algoritmos foi analisado conforme as conhecidas métricas Sokolova and Lapalme [2009]: acurácia (Equação 1), precisão (Equação 2), sensibilidade ou *recall* (Equação 3), e *F1-Score macro* (Equação 4).

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (1)$$

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (2)$$

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (3)$$

$$F1\text{-Score} = \frac{2 \times (\text{Precisão} \times \text{Sensibilidade})}{\text{Precisão} + \text{Sensibilidade}} \quad (4)$$

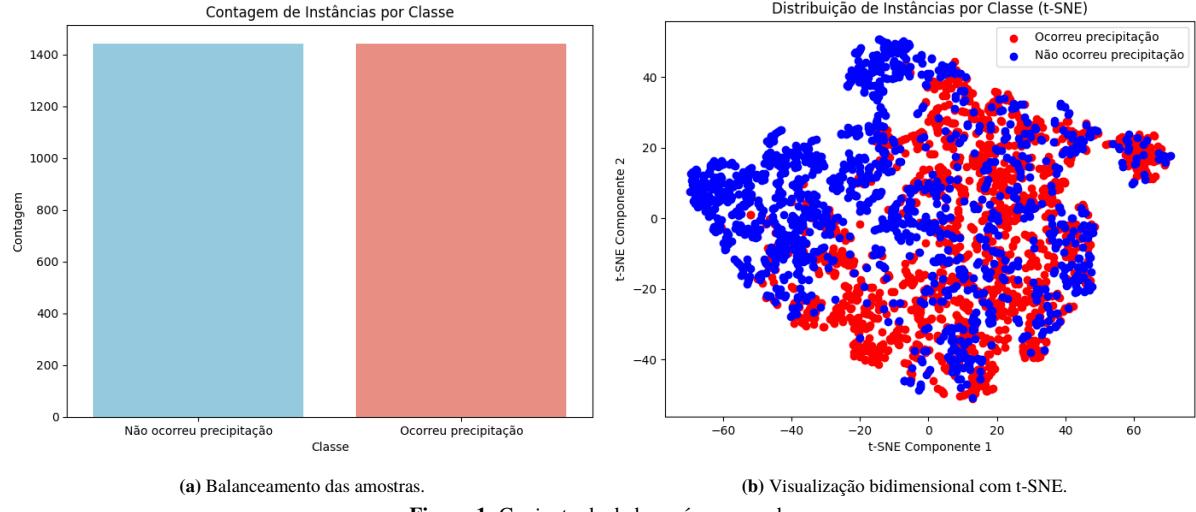
Para explicar alguns dos modelos de classificação utilizados neste trabalho, utilizamos o método LIME Ribeiro *et al.* [2016], da área de Inteligência Artificial Explicável (do inglês *Explainable Artificial Intelligence*, XAI). O LIME é uma versão de modelos substitutos locais, ou seja, ferramentas interpretativas que auxiliam na compreensão das previsões por instância de modelos de ML (explicação local). Este método XAI permite esclarecer o comportamento de qualquer modelo de classificador, tornando-se independente do modelo Molnar [2020].

Devido à limitação de páginas, analisaremos o gráfico do LIME apenas de um modelo. Contudo, o script, as matrizes de confusão dos modelos e os gráficos do LIME podem ser acessados na seção Disponibilidade de dados e materiais. Ademais, há limitações de explicação da biblioteca python LIME em relação ao SVM, por isso o modelo Ensemble não foi explicado por ser baseado no SVM.

4 Resultados e Discussões

A Tabela 2 apresenta os resultados de desempenho de nove modelos de ML. A Tabela 2 compara esses modelos em quatro métricas: Acurácia, Precisão, Sensibilidade e F1-Score macro.

Observa-se pela Tabela 2, que o Ensemble é o modelo com a maior acurácia e F1-score (85,0%), o que significa que, em geral, ele fez mais classificações corretas em comparação



(a) Balanceamento das amostras.

(b) Visualização bidimensional com t-SNE.

Figura 1. Conjunto de dados pré-processado.

Tabela 1. Matriz de confusão

		Classes preditas		Total	
		Positivo	Negativo	$VP + FP$	$FN + VN$
Classes reais	Positivo	VP	FP	$VP + FN$	$FN + VN$
	Negativo	FN	VN		
Total	$VP + FN$	$FP + VN$			

Tabela 2. Resultados em % de cada modelo

Modelo	Acurácia	Ocorreu precipitação?	Precisão	Recall	F1-Score
LR	83,0	Não (0)	80,0	87,0	83,0
		Sim (1)	87,0	80,0	83,0
NB	76,0	Não (0)	62,0	88,0	72,0
		Sim (1)	91,0	69,0	78,0
ET	84,0	Não (0)	82,0	87,0	84,0
		Sim (1)	87,0	82,0	84,0
RF	84,0	Não (0)	82,0	87,0	84,0
		Sim (1)	86,0	81,0	84,0
SVM	84,0	Não (0)	81,0	88,0	84,0
		Sim (1)	88,0	81,0	85,0
<i>k</i>-NN	81,0	Não (0)	76,0	86,0	81,0
		Sim (1)	87,0	77,0	82,0
MLP	84,0	Não (0)	80,0	87,0	84,0
		Sim (1)	87,0	81,0	84,0
ELM	84,0	Não (0)	80,0	89,0	84,0
		Sim (1)	89,0	81,0	85,0
Ensemble	85,0	Não (0)	83,0	87,0	85,0
		Sim (1)	87,0	82,0	85,0

aos outros modelos de forma equilibrada em *recall* e precisão. Os modelos LR, ET, RF, SVM, *k*-NN, MLP e ELM mostram boas acuráncias entre 83% a 84%, mas não se destacam em todos os critérios como o Ensemble. Apesar do NB ter a menor acurácia (76%), se destacou com a melhor precisão (91,0%), o que significa que quando o NB previu precipitação, quase sempre estava correto. Também uma das mais alta sensibilidade (88,0%), indicando excelente capacidade de detectar ausência de precipitação, após ELM com 89% de *recall*.

Devido às limitações do LIME descritas na subseção 3.2, apresentamos uma explicação local apenas para o modelo ET,

pois apresentou resultados promissores, mais especificamente nas métricas de *F1-Score* e *recall* em relação os modelos ELM, MLP e RF. Das dez primeiras predições do conjunto de teste explicadas pelo LIME, muitas tiveram probabilidade acima de 80% de ocorrer ou não precipitação. Assim, escolhemos a predição com probabilidade mais equilibrada: 34% de não ocorrer precipitação (classe 0) e 66% de ocorrer precipitação (classe 1).

A Figura 2 mostra que as características mais relevantes para prever a ocorrência de precipitação (Classe 1) foram as relacionadas à umidade máxima e instantânea, assim como à temperatura mínima e instantânea. Estas características tive-

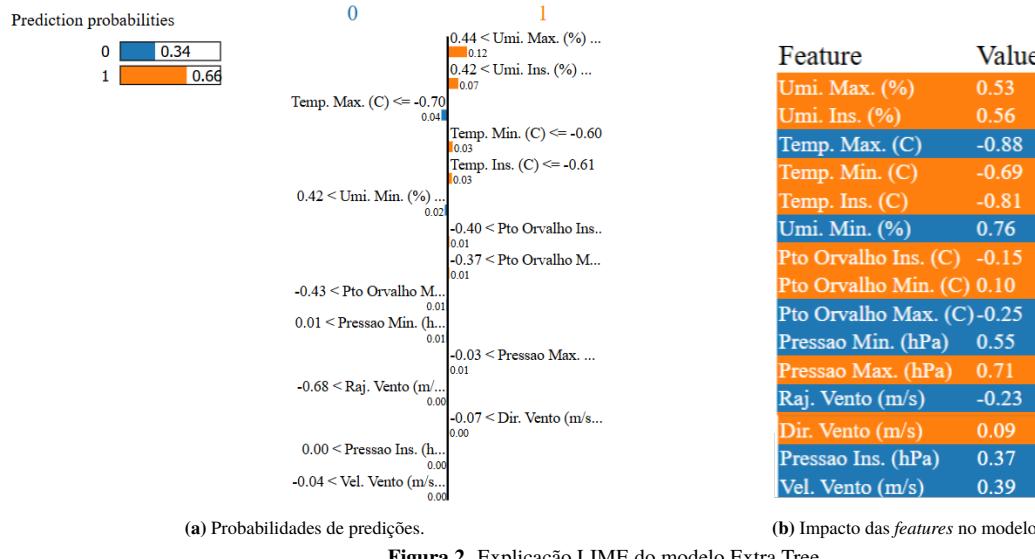


Figura 2. Explicação LIME do modelo Extra Tree.

ram maior peso na decisão do modelo ET. Por outro lado, a temperatura máxima e a umidade mínima foram mais influentes para prever a ausência de precipitação (Classe 0).

5 Considerações Finais e Trabalhos Futuros

O presente artigo relatou um comparativo de diferentes arquiteturas de classificadores para a problemática de previsão de precipitações pluviométricas em uma cidade do interior do Ceará. O Ensemble demonstrou a maior acurácia e um bom F1-Score, tornando-se uma escolha robusta para previsões de precipitação. O Naive Bayes, apesar de sua menor acurácia geral, mostrou-se altamente eficaz em prever a ocorrência de precipitação (alta precisão) e a ausência de precipitação (alto recall). Pode ser útil em aplicações onde esses aspectos são mais críticos. SVM, RF e ET mostraram bons equilíbrios entre as métricas, sendo alternativas viáveis dependendo das necessidades específicas da aplicação.

Este possui limitações relacionadas à análise completa das explicações de todos os modelos ML avaliados e ausências de modelos de aprendizagem profunda, tais como CNNs e Redes Neurais Recorrentes. Como trabalhos futuros, sugere-se avaliar o desempenho dos modelos com dados mais recentes de precipitação e sua aplicação no planejamento agrícola da Serra de Ibiapaba, visando aprimorar a tomada de decisão para otimização de recursos hídricos.

Declarações complementares

Agradecimentos

Este trabalho foi apoiado pelo Programa Institucional de Bolsas de Iniciação Científica (PIBIC) e Programa de Iniciação Científica e Tecnológica Voluntária (PICTV) do Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE).

Contribuições dos autores

Ananias CO: Redação, revisão e edição; coleta de dados; experimentos computacionais; metodologia; análise e discussão dos resultados. Rhyan XB: Coordenação e orientação do projeto; revisão. Maria AOC: Formatação, Redação, revisão e edição; discussão dos resultados. Roney NS: Redação, revisão e edição; experimentos computacionais.

Adonias CO: Formatação; revisão e submissão; experimentos computacionais; metodologia. Paulo CAJ: Coorientação; revisão. Todos os autores revisaram e aprovaram o manuscrito final

Conflitos de interesse

Os autores declaram que não têm nenhum conflito de interesses.

Disponibilidade de dados e materiais

O conjunto de dados de precipitações coletado e analisado neste estudo está disponível em <https://zenodo.org/records/14914786>. O material suplementar relacionado ao código em Python e gráficos podem ser acessados por meio de <https://github.com/adonias-caetano/ifce-pibic-2021-pictv-2024-chuva-tiangua.git>.

Outras informações relevantes

Durante a preparação deste trabalho, os autores usaram o Microsoft Copilot para aprimorar a redação e estrutura do texto, além de corrigir erros ortográficos e gramaticais. Após utilizar esta ferramenta/serviço, os autores revisaram e editaram o conteúdo conforme necessário e assumem total responsabilidade pelo conteúdo do artigo publicado.

Referências

- Ardabili, S., Mosavi, A., Dehghani, M., and Várkonyi-Kóczy, A. R. (2020). Deep Learning and Machine Learning in Hydrological Processes Climate Change and Earth Systems a Systematic Review. In Várkonyi-Kóczy, A. R., editor, *Engineering for Sustainable Future*, pages 52–62, Cham. Springer International Publishing. DOI: 10.1007/978-3-030-36841-8_5.
- Borella, L. d. C., Borella, M. R. d. C., and Corso, L. L. (2022). Climate analysis using neural networks as supporting to the agriculture. *Gestão Produção*, 29:e06. DOI: 10.1590/1806-9649-2022v29e06.
- Danandeh Mehr, A., Rikhtehgar Ghiasi, A., Yaseen, Z. M., Sorman, A. U., and Abualigah, L. (2023). A novel intelligent deep learning predictive model for meteorological drought forecasting. *Journal of Ambient Intelligence and Humanized Computing*, 14(8):10441–10455. DOI: 10.1007/s12652-022-03701-7.
- Dotse, S.-Q., Larbi, I., Limantol, A. M., and De Silva, L. C.

- (2024). A review of the application of hybrid machine learning models to improve rainfall prediction. *Modeling Earth Systems and Environment*, 10(1):19–44. DOI: 10.1007/s40808-023-01835-x.
- Fernández-Delgado, M., Cernadas, E., Barro, S., and Amorim, D. (2014). Do we Need Hundreds of Classifiers to Solve Real World Classification Problems? *The journal of machine learning research*, 15(1):3133–3181. Disponível em <https://jmlr.org/papers/v15/delgado14a.html>.
- Latif, S. D. and Ahmed, A. N. (2023). A review of deep learning and machine learning techniques for hydrological inflow forecasting. *Environment, Development and Sustainability*, 25(11):12189–12216. DOI: 10.1007/s10668-023-03131-1.
- Maaten, L. v. d. and Hinton, G. (2008). Visualizing data using t-SNE. *Journal of machine learning research*, 9(Nov):2579–2605. Disponível em <http://jmlr.org/papers/v9/vandermaaten08a.html>.
- Mishra, S. (2017). Handling imbalanced data: Smote vs. random undersampling. *Int. Res. J. Eng. Technol.*, 4(8):317–320. Disponível em <https://www.irjet.net/archives/V4/i8/IRJET-V4I857.pdf>.
- Molnar, C. (2020). *Interpretable Machine Learning*. Leanpub.
- Parmar, A., Mistree, K., Sompura, M., et al. (2017). Machine learning techniques for rainfall prediction: A review. In *International conference on innovations in information embedded and communication systems*, volume 3. Disponível em <https://www.researchgate.net/publication/319503839>.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12:2825–2830. Disponível em <https://jmlr.org/papers/v12/pedregosa11a.html>.
- Pereira Filho, A. J., Pinto, M. A. R. C., Manfredini, L., Lima, F. A. d., Pinto, A. C. e. C., Moribe, C. H., Vemado, F., and Silva Júnior, I. W. d. (2020). Sistema Integrado de Estimativa e Previsão de Precipitação para Bacias Hidrográficas da CESP. *Revista Brasileira de Meteorologia*, 35(4):529–552. DOI: 10.1590/0102-7786352023.
- Ribeiro, M. T., Singh, S., and Guestrin, C. (2016). "Why Should I Trust You?": Explaining the Predictions of Any Classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '16, page 1135–1144, New York, NY, USA. Association for Computing Machinery. DOI: 10.1145/2939672.2939778.
- Ribeiro, P. L. (2024). Análise e previsão de secas no norte de Minas Gerais utilizando machine learning. Dissertação de Mestrado, Pós-Graduação em Gestão e Regulação de Recursos Hídricos, Curso de Mestrado Profissional em Rede Nacional em Gestão e Regulação de Recursos Hídricos (PROFÁGUA), Universidade Federal de Itajubá. Disponível em <https://repositorio.unifei.edu.br/jspui/handle/123456789/4130>.
- Sokolova, M. and Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4):427–437. DOI: 10.1016/j.ipm.2009.03.002.
- Sousa, R., Brito, R., and Ximenes, J. (2021). Avaliação de Desempenho Utilizando Diferentes Arquiteturas de Aprendizagem Profunda a Partir de Dados Relacionados a Precipitação Pluviométrica Coletados por Estação Meteorológica Automática. In *Anais do XIV Encontro Unificado de Computação do Piauí e XI Simpósio de Sistemas de Informação*, pages 168–175, Porto Alegre, RS, Brasil. SBC. DOI: 10.5753/enucompi.2021.17768.
- Waqas, M., Humphries, U. W., Wangwongchai, A., Dechpichai, P., and Ahmad, S. (2023). Potential of Artificial Intelligence-Based Techniques for Rainfall Forecasting in Thailand: A Comprehensive. *Water*, 15(16). DOI: 10.3390/w15162979.
- Ximenes de Brito, R., DE OLIVEIRA, A. C., and de Oliveira, A. C. (2025). Classificação de Precipitações - INMET - Tianguá - 2021 - IFCE. Conjunto de dados de precipitações coletados do INMET referente ao município de Tianguá (CE) durante o período de 15/03/2018 a 11/05/2021. Disponível em <https://doi.org/10.5281/zenodo.14914786>.