

Abordagem de árvore de regressão para análise de dados de distribuição pluviométrica na cidade de São Carlos – SP

Lucas de Barros Teixeira¹

¹LabDES – Laboratório de Banco de Dados e Engenharia de Software
Universidade Federal de São Carlos (UFSCar) 13.565-905– São Carlos – SP – Brasil
lucas.barros@estudante.ufscar.br

Abstract. *The advent of artificial intelligence nowadays has enabled association with natural disaster prediction models focusing on intense rainfall in the prevention of natural and extreme phenomena. This work proposes an approach to analyzing rainfall data in the city of São Carlos – SP. The regression tree approach presented aims to contribute to an assertive determination of future rainfall data. To this end, an estimate of volumetric precipitation data was carried out in the period from 2016 to 2023, which was close to the real published values, with values of RMSE of 1.274, MSE of 1.624 and MAE of 0.305. With a view to future development, it is expected to apply the method in different contexts.*

Resumo. *O advento da inteligência artificial nos dias atuais tem possibilitado associação com modelos de previsão de desastres naturais com foco em chuvas intensas na prevenção de fenômenos naturais e extremos. Este trabalho propõe uma abordagem de análise de dados pluviométricos da cidade de São Carlos – SP. A abordagem de árvore de regressão apresentada visa contribuir com uma determinação assertiva acerca de dados pluviométricos futuros. Para tanto, foi realizada uma estimativa de dados volumétricos de precipitação no intervalo de 2016 a 2023, a qual se aproximou dos valores reais divulgados, com valores de RMSE de 1,274, de MSE de 1,624 e MAE de 0,305. Com vistas ao desenvolvimento futuro, espera-se aplicar o método em diferentes contextos.*

1. Introdução e Objetivos

O uso da inteligência artificial para prever os volumes de chuva tem sido um tópico de crescente interesse nos últimos anos. Com as mudanças climáticas causando eventos pluviais impactantes mais frequentes e graves, previsões precisas de chuva estão se tornando cada vez mais importantes. Ao usar algoritmos de aprendizado de máquina para analisar dados históricos de clima, pesquisadores e órgãos públicos podem identificar padrões e fazer previsões futuras de chuva.

Para começar a cidade de São Carlos está localizada no centro geográfico do estado de São Paulo, com uma área total de 1.136 km², com uma população de 254.822 habitantes segundo IBGE Cidades (2022), e com os limites de coordenadas geográficas de 47°30' e 48°30' Longitude Oeste e 21°30' e 22°30' Latitude Sul (Prefeitura de São Carlos, 2020). Como consequência, os impactos das chuvas na cidade de São Carlos têm sido uma preocupação constante para a população e as autoridades locais. Dessa forma, o efeito das chuvas intensas frequentemente causam alagamentos, deslizamentos de terra e outras formas de danos à infraestrutura da cidade. Por essa razão, as áreas mais afetadas são aquelas localizadas em encostas e próximas aos córregos que cortam a cidade.

Os efeitos dessas chuvas segundo a reportagem do G1.GLOBO (2023) vão além dos danos materiais. Desse modo, as enchentes e deslizamentos também podem ter graves consequências para a saúde pública, incluindo surtos de doenças transmitidas pela água e pela falta de saneamento básico adequado. Portanto, população local tem pedido por soluções eficazes para minimizar esses efeitos negativos e garantir a segurança de todos os moradores da cidade.

Em resumo, os impactos das chuvas na cidade de São Carlos são uma questão séria que exige atenção e ações imediatas por parte das autoridades e da comunidade. Conforme a matéria divulgada pelo G1.GLOBO (2022), os dois córregos principais da cidade transbordaram e zona rural também teve consequências graves, causando transtornos por toda cidade. Assim, a implementação de medidas preventivas e de preparação para emergências é fundamental para garantir a segurança e o bem-estar da população.

Dentre os vários tipos de pesquisa preventiva climática, a previsão de chuvas tende a ser de extrema importância, pois o ambiente é severamente afetado por ele. Existem desastres naturais incontornáveis que criticamente prejudicam a vida humana, o meio ambiente, o material da receita, as operações e atividades sociais. Além disso, torna-se difícil reviver de volta a desastres com os recursos existentes restritos. Se as previsões forem feitas com precisão, ajudará a detectar a possibilidade de chuvas ou tempestades futuras, fomentando assim o gerenciamento de desastres. A previsão é destacada como a principal preocupação mais técnica e científica confrontada pelas pesquisas.

O trabalho atual de pesquisa propõe a abordagem e uso da regressão de árvore de decisão para prever chuvas e tempestades com base em vários dados climáticos. Nesse método, a árvore de decisão é construída a partir dos dados de treinamento, dividindo o conjunto de dados com base em determinados critérios nos nós internos da árvore, até chegar às folhas que contêm as previsões, conforme Shehadeh et al. (2021).

Esta pesquisa procura preencher a lacuna encontrando soluções tecnológicas sem grandes investimentos financeiros em infraestrutura e tecnologia, de maneira criativa, incluindo os atores envolvidos no processo da prevenção a resposta a emergências. Para tanto, será utilizada a base de dados do INMET (2023) da cidade de São Carlos-SP. A seguir, a seção 2 descreve a fundamentação teórica, seção 3 menciona a abordagem proposta, as seções 4 e 5 descrevem, respectivamente, os resultados e discussões, finalizando assim com a seção 6 com a conclusão do artigo.

2. Fundamentação Teórica

Usman et al. (2023), apresentaram um comparativo entre algoritmos de aprendizado de máquina. A pesquisa propõe-se a discutir o desempenho entre os algoritmos de regressão linear múltipla, regressão de floresta aleatória e redes neurais, utilizando dados de precipitação da cidade Semarang, Indonésia. Com relação ao uso de métricas para avaliação dos modelos, utilizaram Erro Absoluto Médio (MAE) e Erro Médio Quadrático (RMSE). Finalizando, o modelo de rede neural apresentou melhor desempenho para o cálculo de volume diário de chuva.

Em seu trabalho, Yovan Felix et al. (2019) dispõe do algoritmo K-means de aprendizado de máquina. Como resultado, a abordagem foi descrita seguindo um fluxo

de etapas sequenciais como: coleção de conjunto de dados, pré-processamento, filtragem, seleção de recursos, e por último o cluster K-means. Para finalizar, é apresentado uma comparação entre os algoritmos K-means, Fuzzy Logic e Neuro-fuzzy Genetic. Em resumo, considerando as métricas de acurácia e tempo de processamento, K-means obteve melhores resultados.

Posteriormente, Dananjali et al. (2020) equipara 3 técnicas de mineração de dados com objetivo de prever chuvas semanais utilizando dados do distrito de Badulla, Sri Lanka. Conseqüentemente, os modelos utilizados foram: regressão linear, árvore modelo M5P e otimização mínima sequencial (SMO). No artigo apresentaram, várias métricas como forma de avaliar os algoritmos, como: MAE, RMSE, Erro Médio Quadrático Relativo (RRSE), Erro Absoluto Quadrático (RAE) e Direção de Precisão (DA). Para finalizar, a árvore modelo M5P registrou resultados melhores e obteve uma correlação maior entre os valores de precipitação real e o previsto.

Do mesmo modo, Li et al. (2023) aborda um estudo de caso envolvendo os dados de duas cidades da China, Zhengzhou e Jiangxi respectivamente. Em relação ao uso do modelo WaterLogging da RainStorm, os resultados mostram que o método é capaz de avaliar efetivamente a capacidade da rede suportar desastres. Por outro lado, o modelo treinado pode ser aplicado em apenas uma área, tornando difícil avaliar a resiliência das redes de distribuição urbana em outras regiões. Logo, é preciso considerar o impacto da tempestade com diferentes durações de chuva na rede de distribuição. Além disso, é necessário estudar um método aprimorado do algoritmo de simulação de Monte Carlo para melhorar a eficiência do cálculo.

3. Apresentação da abordagem

3.1. Visão geral

Com respeito ao uso da inteligência artificial (IA) e a descoberta do conhecimento, são áreas essenciais para a extração de informações valiosas a partir de grandes conjuntos de dados. Resumidamente, a IA envolve a identificação de padrões, correlações e tendências nos dados, enquanto a descoberta do conhecimento refere-se à aplicação desses padrões para a tomada de decisões e a criação de soluções inovadoras.

Ambas as áreas são fundamentais para a análise de dados em diversas áreas, incluindo negócios, ciência, saúde e tecnologia. Para resumir, o processo de descoberta do conhecimento e padrões, envolve várias etapas, como a seleção e preparação dos dados, a aplicação de algoritmos, a avaliação e interpretação dos resultados, e a implementação de soluções baseadas nesses resultados.

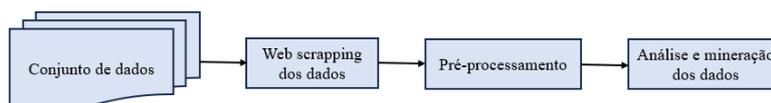


Figura 1 - Visão Geral do Processo

Em relação a linguagem de programação utilizada no estudo, decidiu-se usar o Python, por ser tratar de uma linguagem de alto nível, interpretada por script, de tipagem forte e dinâmica, segundo python Software Foundation (2023). Em segundo lugar,

optamos pela plataforma Google Colab para a implementação e visualização dos dados e análise. A figura 1, demonstra a visão do geral do processo.

3.2 Coleção de conjuntos de dados

Com referência ao conjunto de dados, serão utilizados os dados do INMET (2023), como fonte primária dos dados. Em seguida, será descrito o período temporal selecionado para análise, de 2016 até 05/2023.

3.3 Web *scrapping* dos dados

Para começar, o *web scrapping* é o processo de extração de dados de sites. Entretanto, envolve o uso de ferramentas automatizadas para coletar informações de páginas da web e, em seguida, salvá-las em um formato estruturado. Essa técnica é comumente usada por empresas e pesquisadores para coletar dados sobre as condições do clima e realizar análise de tendências. Para concluir, a raspagem da web também pode ser usada para análise e visualização de dados, o que pode ajudar os pesquisadores e órgãos públicos a tomar decisões mais assertivas (Thapelo et al., 2021).

3.4 Pré-processamento dos dados

No que se diz a respeito, ao pré-processamento dos dados é uma etapa fundamental na análise preditiva de dados climáticos. Nessa etapa, os dados brutos coletados, são submetidos a diversas técnicas de limpeza, transformação e normalização para garantir que sejam adequados para a análise. É importante lembrar que os dados climáticos são extremamente complexos e apresentam diversas fontes de ruído, como falhas nos sensores, erros de medição e fenômenos climáticos extremos. Portanto, o pré-processamento dos dados é essencial para garantir que a análise seja precisa e confiável (Juneja & Das, 2019).

Além disso, o pré-processamento dos dados também pode envolver a seleção de recursos relevantes, a identificação de padrões e a redução da dimensionalidade dos dados. Essas técnicas podem ajudar a melhorar a eficiência do modelo preditivo e a reduzir o tempo de processamento necessário para gerar resultados precisos.

Inicialmente, foram implementadas variáveis sazonais conforme observada na Figura 2, e a decomposição da série temporal. A utilização de técnicas de análise de séries temporais tem se tornado cada vez mais popular no campo de previsões de dados

```
# variáveis sazonais
df['hora'] = df.index.hour
df['mes'] = df.index.month
df['trimestre'] = df.index.quarter

from statsmodels.tsa.seasonal import seasonal_decompose
# salvar os componentes, decomposição da série temporal
result = seasonal_decompose(df.precipitacao_total_h, period=8760)
```

climáticos. Esses métodos envolvem a análise de pontos de dados sequenciais ao longo de um período, com o objetivo de identificar padrões e tendências nos dados.

Figura 2 - Séries temporais

Em seguida, visualizou-se a volumetria de precipitação da média mensal por anos (em mm). Por meio da Figura 3, constatamos que a precipitação média se encontra concentrada nos três últimos meses e nos três primeiros meses de cada ano.

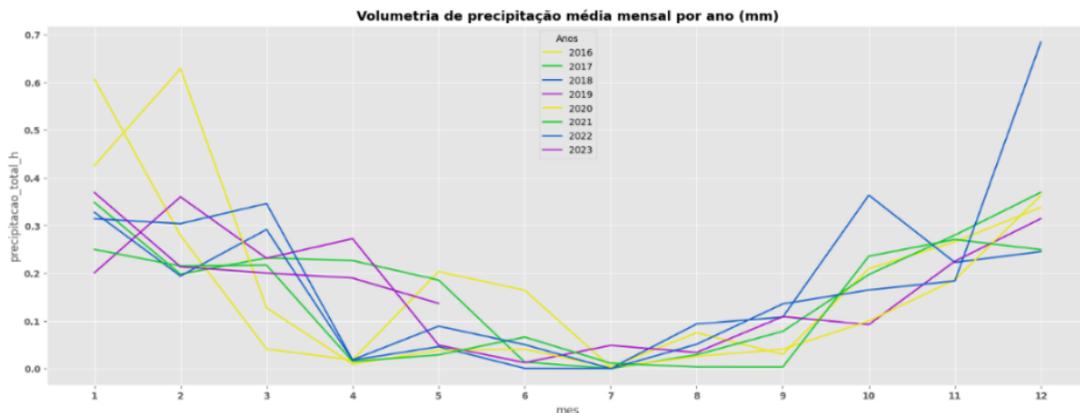


Figura 3 - Volumetria de precipitação da média mensal

Após isso, verificamos e avaliamos a demonstração da volumetria de precipitação total mensal (em mm), a Figura 4 demonstra que os anos de 2020 e 2023 apresentaram uma volumetria acentuada em comparação aos outros anos do período selecionado.

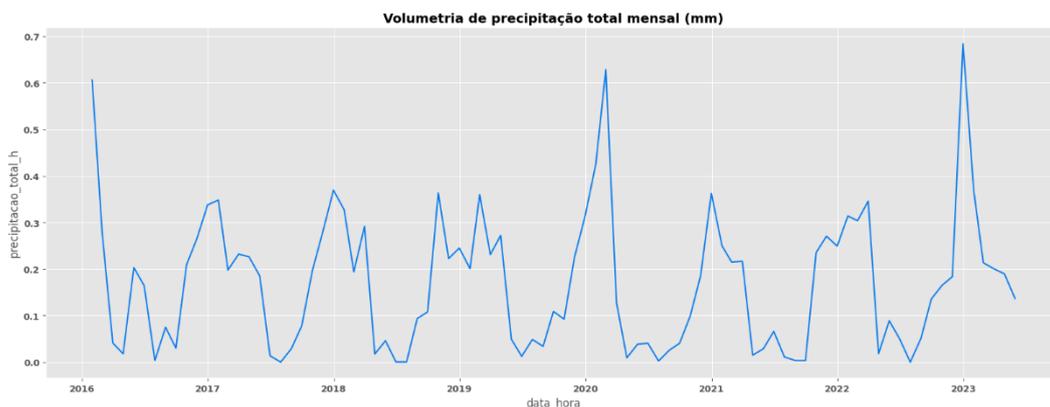


Figura 4 - Volumetria de precipitação total mensal

Não menos importante, na Figura 5 evidenciou-se o mapa de calor entre as variáveis do conjunto de dados. O coeficiente de correlação de Pearson indica a associação entre duas variáveis, conforme Karatayev et al. (2022). Na análise realizada, encontra-se uma correlação entre a precipitação e variáveis de temperatura de orvalho e dados extraídos do vento. Por último, variáveis de umidade e temperatura apresentam uma alta correlação entre si.

3.4 Métricas utilizadas no Modelo

Conforme Singh Kushwah et al. (2022), as métricas mais comumente utilizadas para avaliação de modelos de árvore de decisão são:

- MSE: é uma medida do erro médio quadrático entre as previsões do modelo e os valores reais do conjunto de dados. Ele calcula a diferença entre cada valor previsto e seu valor correspondente real, eleva essa diferença ao quadrado e tira a média desses quadrados;
- MAE: é uma medida do erro médio absoluto entre as previsões do modelo e os valores reais do conjunto de dados. Ele calcula a diferença absoluta entre cada

valor previsto e seu valor correspondente real, e em seguida, tira a média dessas diferenças;

- RMSE: é calculado tomando a raiz quadrada do MSE. O MSE é a média das diferenças ao quadrado entre as previsões e os valores reais, enquanto o RMSE é a raiz quadrada dessa média.

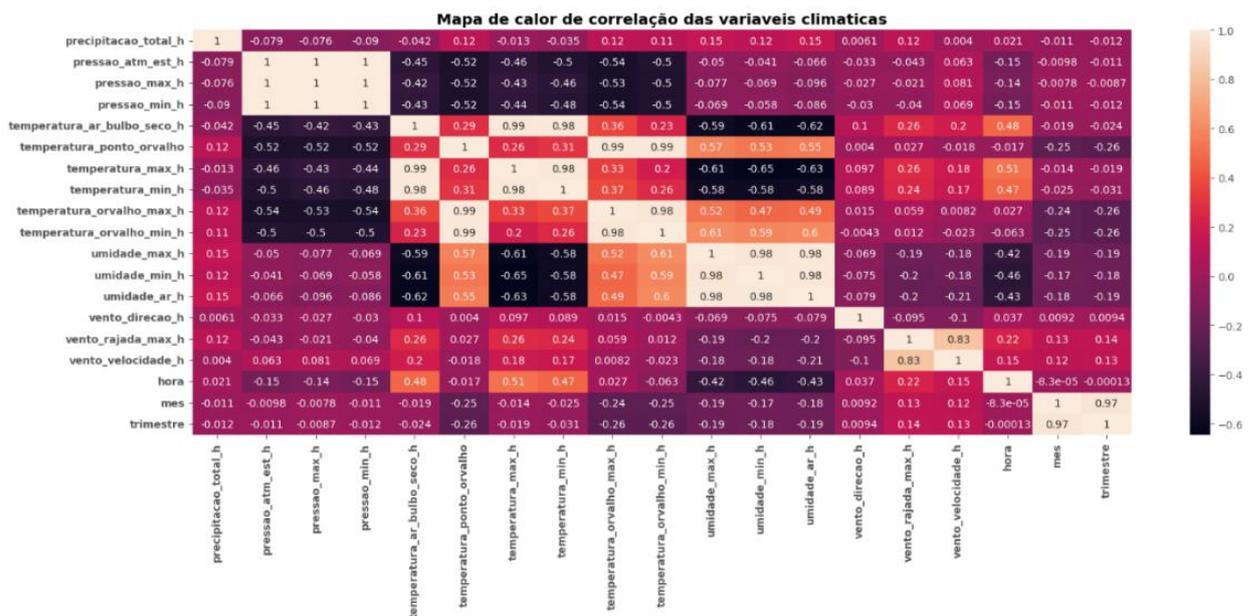


Figura 5 - Correlação de Pearson das variáveis

3.5 Aprendizado de máquina: Árvore de Decisão

Conforme Charbuty e Abdulzeez (2021), o uso do modelo de árvore de decisão é uma técnica amplamente utilizada para previsão de chuvas em diferentes regiões do mundo. A sua aplicação tem se mostrado eficaz para identificar as variáveis mais relevantes e seus respectivos impactos nas condições climáticas. Essa abordagem requer o entendimento das informações meteorológicas disponíveis, bem como a escolha adequada das variáveis que serão utilizadas na construção do modelo. Além disso, é importante ressaltar que a precisão da previsão pode ser aprimorada através da utilização de técnicas complementares, como a análise de dados históricos e o uso de algoritmos de aprendizado de máquina. Devido a eficiência, desempenho e a capacidade de lidar com uma variedade de problemas em aprendizado de máquina, o *XGBoost (Extreme Gradient Boosting)* foi utilizado para a previsão dos dados. Para ser ilustrar, a Figura 5 demonstra o código criado.

```

# import das libs
import xgboost as xgb
from xgboost import DMatrix
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_absolute_error, mean_squared_error

# separação dos dados
data1 = df.dropna()
x_dt1,y_dt1 = data1.drop(['precipitacao_total_h'],axis=1),data1.precipitacao_total_h
x_train1,x_test1,y_train1,y_test1 = train_test_split(x_dt1,y_dt1,test_size=0.2,shuffle=False)

# matriz dos dados
dtrain = DMatrix(x_train1,y_train1)
dtest = DMatrix(x_test1)

# modelo
%%time
params = {'tree_method': 'hist','eval_metric':'rmsle'}

model = xgb.train(params,
                  num_boost_round = 999,
                  dtrain=dtrain)

yhat1 = model.predict(dtest,ntree_limit = model.best_ntree_limit)
mae = mean_absolute_error(y_test1,yhat1)
mse = mean_squared_error(y_test1,yhat1)

```

Figura 5 – código do XGBoost

4. Resultados

Com relação aos resultados obtidos, pode se observar a relação calculada na Tabela 1.

Tabela 1 – Valores

Métrica	Valores encontrados
MSE	1,624
MAE	0,305
RMSE	1,274

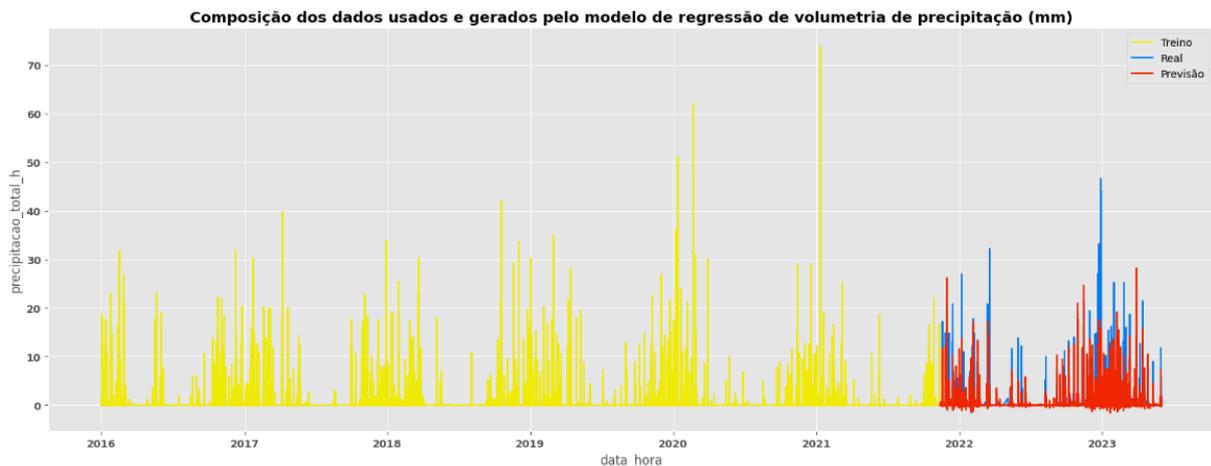


Figura 6 – Modelo de regressão de volumetria

Com referência ao modelo de regressão de volumetria, Figura 6, 80% dos dados foram utilizados para treino do modelo, os 20% restantes usados para testes. Logo, visualizamos a diferença entre a Previsão encontrada e o dado real. Finalmente, na Figura 7 demonstra-se um teste de regressão de volumetria comparando a Previsão estimada e dados reais do conjunto de dados.

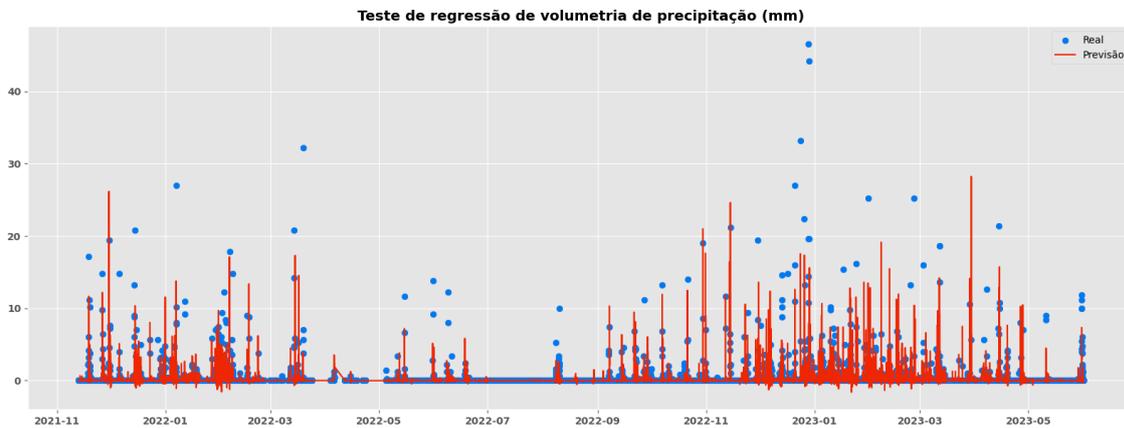


Figura 7 – Teste de regressão de volumetria

5. Discussão

Em primeiro lugar, o modelo apresentou um MSE de 1,624, que indica a média dos erros quadrados das previsões em relação aos valores reais. Logo, quanto menor o valor do MSE, melhor é o desempenho do modelo, sugerindo que as previsões estão mais próximas dos valores reais. Nesse caso, o valor do MSE indica que o modelo tem uma quantidade moderada de erro quadrado médio.

Posteriormente, o MAE encontrado de 0,305, que representa a média dos erros absolutos das previsões em relação aos valores reais. Portanto, um valor mais baixo do MAE indica que o modelo tem previsões mais precisas, com erros menores em magnitude. No caso apresentado, o valor do MAE sugere que o modelo tem um desempenho satisfatório, com erros absolutos médios relativamente baixos.

Por último, o RMSE calculado foi de 1,274. O RMSE é uma métrica semelhante ao MSE, porém é mais sensível a valores discrepantes, pois envolve a raiz quadrada dos erros quadrados. Mais detalhadamente, quanto menor o valor do RMSE, melhor é o desempenho do modelo. Neste caso, o valor do RMSE indica que o modelo tem um nível moderado de erro médio em relação aos valores reais.

Para finalizar, com base nas métricas MSE, MAE e RMSE, pode-se concluir que o modelo de regressão de árvore XGBoost apresenta um desempenho razoável na previsão da volumetria de precipitação. No entanto, é importante considerar o contexto específico da aplicação e avaliar as métricas em relação às necessidades e requisitos do problema em questão.

6. Conclusão

A utilização da IA na pesquisa preventiva climática e na previsão de volumes de chuva tem sido uma das áreas de pesquisa mais promissoras dos últimos anos. Com o avanço da tecnologia, tem sido possível desenvolver modelos de previsão climática cada vez mais precisos, que permitem aos pesquisadores identificar padrões climáticos e prever eventos extremos com maior antecedência. Além disso, a IA tem sido empregada na análise de grandes conjuntos de dados, o que possibilita uma compreensão mais profunda dos fenômenos e uma melhor previsão das mudanças climáticas futuras.

Em relação a fundamentação teórica, foram citados trabalhos relacionados ao uso da IA com foco em previsão de volumetria pluviométricas. De modo geral, as lacunas encontradas, os resultados finais e métricas apuradas permitem o estudo e desenvolvimento de novas técnicas. No que diz respeito a abordagem apresentada no artigo, foi desenvolvido e implementado um processo envolvendo etapas como: coleta, pré-processamento e análise dos dados pluviométricos. Em resumo, a abordagem

proposta apresentou resultados melhores referente as métricas mais utilizadas para avaliação de modelos. Além de ser de fácil manuseio e com uso de poucos recursos, tanto financeiros como tecnológicos.

A regressão de árvore, representada pelo XGBoost, demonstrou ser uma forma útil na previsão da volumetria de precipitação. Com sua capacidade de modelar relacionamentos complexos e não lineares entre os dados, essa técnica é capaz de capturar padrões e tendências relevantes, contribuindo para uma previsão mais precisa. Ao considerar fatores como a topografia, o uso do solo e as características climáticas específicas da região de interesse, o modelo de regressão de árvore pode oferecer insights valiosos para a identificação de áreas de maior risco e a definição de medidas de prevenção e mitigação de desastres naturais.

O modelo apresentou um MSE de 1,624, indicando a média dos erros das previsões em relação aos valores reais. Quanto menor o valor do MSE, melhor o desempenho do modelo, sugerindo previsões mais precisas. O MAE encontrado foi de 0,305, um valor mais baixo dessa métrica aponta que o modelo tem previsões mais precisas, com erros menores em magnitude. Logo, o RMSE calculado foi de 1,274, indicando um nível moderado de erro médio em relação aos valores reais. Em resumo, o modelo de regressão XGBoost tem um desempenho razoável na previsão da volumetria de precipitação, mas é importante avaliar as métricas de acordo com as necessidades do problema.

Em relação as pesquisas futuras, prevê-se o estudo de algoritmos de aprendizado de máquina, especialmente para a predição quanto ao volume de chuva, com foco no aumento de correlação e melhora nos resultados de métricas utilizadas. Dessa forma, o aprimoramento de um modelo de predição pontual, pode ser viável em aplicações mais extensivas abrangendo um volume maior de dados e análise de informações em função das especificidades de outros cenários e cidades.

Referências

- Charbuty, B., & Abdulazeez, A. (2021). Classification Based on Decision Tree Algorithm for Machine Learning. *Journal of Applied Science and Technology Trends*, 2(01), 20–28. <https://doi.org/10.38094/jastt20165>
- Dananjali, T., Wijesinghe, S., & Ekanayake, J. (2020). Forecasting weekly rainfall using data mining technologies. *2020 From Innovation to Impact, FITI 2020*. <https://doi.org/10.1109/FITI52050.2020.9424877>
- G1.GLOBO. (2022). *São Carlos tem manhã de alagamentos e interdições após chuva de 96 milímetros Locais mais afetados foram Parque Ecológico, Rotatória do Cristo e Kartódromo. Defesa Civil também registrou quedas de árvores. Não há desabrigados.* G1.GLOBO. <https://g1.globo.com/sp/sao-carlos-regiao/noticia/2022/12/28/sao-carlos-tem-manha-de-alagamentos-e-interdicoes-apos-chuva-de-96-milímetros.ghtml>
- G1.GLOBO. (2023). *Chuva forte em São Carlos causa alagamento, derruba árvores e interdita rotatória do Cristo.* G1.GLOBO. <https://g1.globo.com/sp/sao-carlos-regiao/noticia/2023/02/16/chuva-forte-em-sao-carlos-causa-alagamentos-derruba-arvore-e-interdita-rotatoria-do-cristo.ghtml>

- IBGE Cidades. (2022). *Portal IBGE - Instituto Brasileiro de Geografia e Estatística*. IBGE. <https://cidades.ibge.gov.br/brasil/sp/sao-carlos/panorama>
- INMET. (2023, August 26). *Portal INMET - Instituto Nacional de Meteorologia*. Portal INMET. <https://portal.inmet.gov.br/dadoshistoricos>
- Juneja, A., & Das, N. N. (2019, February). Big Data Quality Framework: Pre-Processing Data in Weather Monitoring Application. *2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*, 559–563. <https://doi.org/10.1109/COMITCon.2019.8862267>
- Karatayev, M., Clarke, M., Salnikov, V., Bekseitova, R., & Nizamova, M. (2022). Monitoring climate change, drought conditions and wheat production in Eurasia: the case study of Kazakhstan. *Heliyon*, 8(1), e08660. <https://doi.org/10.1016/j.heliyon.2021.e08660>
- Li, K., Ma, J., Gao, J., Xu, C., Li, W., Mao, Y., & Jiang, S. (2023). Resilience Assessment of Urban Distribution Network Under Heavy Rain: A Knowledge-Informed Data-Driven Approach (April 2023). *IEEE Access*. <https://doi.org/10.1109/ACCESS.2023.3288341>
- Prefeitura de São Carlos. (2020). *DADOS DA CIDADE - Prefeitura de São Carlos*. DADOS DA CIDADES. <http://www.saocarlos.sp.gov.br/index.php/conheca-sao-carlos/115442-dados-da-cidade-geografico-e-demografico.html>
- python Software Foundation. (2023). *python SOFTWARE FOUNDATION*. PYTHON.ORG. <https://www.python.org/psf-landing/>
- Shehadeh, A., Alshboul, O., Al Mamlook, R. E., & Hamedat, O. (2021). Machine learning models for predicting the residual value of heavy construction equipment: An evaluation of modified decision tree, LightGBM, and XGBoost regression. *Automation in Construction*, 129, 103827. <https://doi.org/https://doi.org/10.1016/j.autcon.2021.103827>
- Singh Kushwah, J., Kumar, A., Patel, S., Soni, R., Gawande, A., & Gupta, S. (2022). Comparative study of regressor and classifier with decision tree using modern tools. *Materials Today: Proceedings*, 56, 3571–3576. <https://doi.org/10.1016/j.matpr.2021.11.635>
- Thapelo, T. S., Namoshe, M., Matsebe, O., Motshegwa, T., & Bopape, M.-J. M. (2021). SASSCAL WebSAPI: A Web Scraping Application Programming Interface to Support Access to SASSCAL's Weather Data. *Data Science Journal*, 20. <https://doi.org/10.5334/dsj-2021-024>
- Usman, C. D., Widodo, A. P., Adi, K., & Gernowo, R. (2023). Rainfall prediction model in Semarang City using machine learning. *Indonesian Journal of Electrical Engineering and Computer Science*, 30(2), 1224. <https://doi.org/10.11591/ijeecs.v30.i2.pp1224-1231>
- Yovan Felix, A., Vinay, G. S. S., & Akhik, G. (2019). K-Means Cluster Using Rainfall and Storm Prediction in Machine Learning Technique. *Journal of Computational and Theoretical Nanoscience*, 16(8), 3265–3269. <https://doi.org/10.1166/jctn.2019.8174>