

Influência das Variações Climáticas no Mercado de Manga em Petrolina-PE: Modelagem com LSTM e ARIMA

Influence of Climate Variations on the Mango Market in Petrolina-PE: Modeling with LSTM and ARIMA

Rita de Cássia de Vasconcelos Pedrosa¹ 

Guilherme Lopes de Campos² 

Denise Honorato Lopes da Silva¹ 

Hallysson Farias Gomes³ 

Claudio Tadeu Cristino¹ 

¹Universidade Federal Rural de Pernambuco, Departamento de Biometria e Estatística Aplicada, PPGBEA, Recife, Pernambuco, Brasil.

²Universidade Federal Fluminense, Departamento de Engenharia Química, Niterói, Rio de Janeiro, Brasil

³Universidade Federal Rural de Pernambuco, Departamento de Física, Recife, Pernambuco, Brasil

Resumo

Objetivo: Investigar os impactos das temperaturas extremas e da variabilidade climática na produção de manga na região de Petrolina-PE, utilizando técnicas de modelagem estatística (ARIMA) e inteligência artificial (Reinforcement Learning e LSTM) para prever cenários futuros e apoiar a formulação de estratégias adaptativas na agricultura.

Método/abordagem: A pesquisa utiliza séries temporais de produção de manga e aplica modelos de previsão: ARIMA, Rede Neural Recorrente (LSTM) e Reinforcement Learning. A abordagem combina análise estatística e aprendizado de máquina para identificar padrões climáticos e projetar os efeitos das mudanças climáticas sobre a produção agrícola

Contribuições teóricas/práticas/sociais: As contribuições do estudo abrangem diferentes dimensões. No campo teórico, a pesquisa avança a discussão ao integrar técnicas estatísticas tradicionais com métodos de inteligência artificial aplicados à previsão agrícola em cenários de variabilidade climática. Em termos práticos, disponibiliza aos produtores ferramentas que auxiliam na melhoria da tomada de decisão, contemplando o planejamento da colheita, a gestão da irrigação e a seleção de cultivares mais adaptados às condições adversas. Já no aspecto social, o trabalho contribui para a sustentabilidade da cadeia produtiva da manga em Petrolina, fortalecendo o desenvolvimento econômico local e mitigando os riscos associados às mudanças climáticas.

Originalidade/relevância: O estudo é original por integrar técnicas tradicionais (ARIMA) com métodos avançados de inteligência artificial (Reinforcement Learning e LSTM) para analisar os efeitos das mudanças climáticas na produção de manga em uma região semiárida estratégica para o Brasil. A relevância está na contribuição direta para a segurança alimentar, geração de renda e formulação de políticas agrícolas adaptativas.

Palavras-chave: Produção de manga; Mudanças Climáticas; Reinforcement Learning; ARIMA.

Abstract

Purpose: To investigate the impacts of extreme temperatures and climate variability on mango production in Petrolina-PE, employing statistical modeling (ARIMA) and artificial intelligence techniques (Reinforcement Learning and LSTM) to forecast future scenarios and support adaptive agricultural strategies.

Design/methodology/approach: The study analyzes mango production time series using ARIMA, Long Short-Term Memory (LSTM) recurrent neural networks, and Reinforcement Learning models. This hybrid approach integrates statistical and machine

learning techniques to identify climatic patterns and project their effects on agricultural production.

Research, Practical & Social implications: The contributions of this study encompass different dimensions. From a theoretical perspective, it advances the discussion by integrating traditional statistical techniques with artificial intelligence methods applied to agricultural forecasting under climate variability. In practical terms, it provides producers with tools that support improved decision-making, including harvest planning, irrigation management, and the selection of cultivars better adapted to adverse conditions. From a social standpoint, the research contributes to the sustainability of the mango production chain in Petrolina, strengthening local economic development and mitigating the risks associated with climate change.

Originality/value: The originality lies in integrating ARIMA with advanced AI models (Reinforcement Learning and LSTM) to analyze the effects of climate change on mango production in a semi-arid region. The relevance is linked to food security, income generation, and the formulation of adaptive agricultural policies.

Keywords: Mango Production; Climate Change; Reinforcement Learning; ARIMA.

Introdução

A região de Petrolina, PE, no Vale do São Francisco, representa um dos principais polos de produção de manga do Brasil, contribuindo significativamente para o mercado nacional e internacional (J. R. Lima, 2023). No entanto, a produtividade dessa cultura tem sido impactada por mudanças climáticas, como variações de temperatura e eventos extremos, que afetam tanto a qualidade quanto a quantidade da produção. Este trabalho apresenta uma análise abrangente do mercado de manga em Petrolina, avalia os impactos climáticos na produção, e propõe o uso de técnicas avançadas de inteligência artificial, como Reinforcement Learning e

Long Short-Term Memory (LSTM), juntamente com o modelo ARIMA, para prever variações climáticas e otimizar a produção agrícola.

Conforme (Harmon et al., 2020) o Reinforcement Learning (RL) é uma técnica de aprendizado de máquina que se baseia em agentes que tomam decisões para maximizar uma recompensa cumulativa. Para a agricultura, o RL pode ser usado para desenvolver estratégias adaptativas para gerenciar a produção de manga diante de condições climáticas variáveis, com base em feedback contínuo, o que é valioso para enfrentar incertezas climáticas e otimizar o manejo agrícola.

O Long Short-Term Memory (LSTM), é um tipo de rede neural recorrente que é especialmente eficaz em modelar dados temporais e prever séries temporais complexas. De acordo com (Graves, 2012; Hochreiter & Schmidhuber, 1997), o LSTM é capaz de capturar padrões de longo prazo em dados temporais, o que é crucial para prever tendências climáticas e suas consequências na produção de manga mais precisas, permitindo uma melhor preparação e resposta às mudanças climáticas.

O modelo estatístico utilizado para análise e previsão de séries temporais é o ARIMA, (Box et al., 2015; Box & Jenkins, 1970; Yadav & Ghosh, 2019), ele é utilizado para analisar a série temporal de produção de manga e prever as tendências futuras com base em dados históricos. Os resultados mostram que a combinação dessas técnicas permite uma previsão mais precisa das condições climáticas e suas consequências, facilitando a implementação de estratégias mais eficazes para minimizar as perdas e maximizar a produtividade.

Fundamentação Teórica

A fundamentação teórica desse artigo está baseada em cinco tópicos principais: Mudanças climáticas; Mercado

de Manga em Petrolina-PE; Impactos Climáticos na produção de Manga; Reinforcement Learning - Long short term memory e ARIMA.

Mudanças Climáticas

O aquecimento global é um fenômeno climático complexo, caracterizado pelo aumento das temperaturas médias na superfície terrestre, sendo influenciado por fatores que incluem tanto processos naturais quanto atividades humanas. (IPCC, 2023; Penman et al., 2006)

Entre os fatores naturais que influenciam esse fenômeno, destacam-se as variações na atividade solar, a ocorrência de erupções vulcânicas e as flutuações naturais na circulação dos oceanos e da atmosfera. Esses processos podem resultar em mudanças temporárias no clima, como períodos de aquecimento ou resfriamento, que são parte integrante do ciclo climático da Terra (Hussain et al., 2020; Malhi et al., 2021).

Por outro lado, as atividades humanas são as principais responsáveis pela intensificação das mudanças climáticas, tornando-as mais rápidas e severas. A queima de combustíveis fósseis para produção de energia, transporte e processos industriais libera grandes quantidades de gases de efeito estufa (GEE),

aumentando a concentração desses gases na atmosfera e intensificando o aquecimento global (Reay et al., 2007a; Shukla et al., 2023).

Além disso, o desmatamento e as mudanças no uso da terra têm um papel crucial, pois reduzem a capacidade dos ecossistemas naturais de absorver dióxido de carbono da atmosfera. Compreender e abordar esses fatores é essencial para enfrentar as mudanças climáticas e proteger o meio ambiente para as gerações futuras. (Hussain et al., 2020; Malhi et al., 2021; Shukla et al., 2023; Zhang et al., 2018)

O quarto relatório de avaliação do Painel Intergovernamental sobre Mudanças Climáticas (IPCC a, 2014; Mackay, 2008; Reay et al., 2007b; WMO, 2021) revelou que a maior parte do aquecimento registrado nos últimos 50 anos está relacionada ao aumento nas concentrações de gases de efeito estufa de origem antropogênica. Em um intervalo de 100 anos, a temperatura global terrestre aumentou em média 0,85°C, a dos oceanos 0,55°C e a temperatura média global subiu cerca de 0,7°C.

O Painel Intergovernamental sobre Mudança Climática (IPCC), criado em parceria com o Programa das Nações Unidas para o Meio Ambiente e a Organização Meteorológica Mundial, define a “mudança climática” como qualquer

alteração significativa no clima, seja provocada por processos naturais ou por ações humanas. De acordo com a Convenção-Quadro das Nações Unidas sobre Mudanças Climáticas, essa alteração é qualquer mudança no clima resultante, direta ou indiretamente, das atividades humanas (Glenn et al., 1992; Nations, 1992).

Especialistas no sexto Relatório de Avaliação do IPCC (IPCC, 2023) afirmam que as mudanças climáticas decorrentes das atividades humanas têm causado impactos profundos e abrangentes no meio ambiente, afetando bilhões de vidas ao redor do mundo, apesar dos esforços de mitigação dos riscos. As consequências são mais severas para os países, comunidades e ecossistemas menos preparados para enfrentar esses desafios.

Nesse contexto, as mudanças climáticas estão profundamente conectadas à ação humana, que modifica a composição da atmosfera global e intensifica as variações climáticas naturais. As atividades humanas, como a queima de combustíveis fósseis e o desmatamento, liberam gases de efeito estufa, amplificando o efeito estufa natural. Esse aumento na concentração de gases na atmosfera leva ao aquecimento global e a mudanças nos padrões climáticos, como o crescimento da frequência

e intensidade de eventos climáticos extremos (Chevuturi et al., 2022; IPCC, 2023; Malhi et al., 2021).

Mercado de Manga em Petrolina-PE

A região Nordeste, com Petrolina, PE, e Juazeiro, BA, é a principal produtora de manga no Brasil, beneficiada pelo clima quente e solo fértil. Em 2022, o país cultivou 78 mil hectares de manga, com 76% na região Nordeste e 23% na Sudeste. O Vale do São Francisco respondeu por 63% da colheita nacional, totalizando cerca de 1,55 milhões de toneladas e R\$2,07 bilhões em valor de produção. O Brasil é o quarto maior produtor mundial e o terceiro maior exportador, com 200 mil toneladas exportadas em 2022. Apesar do aumento na produção, as exportações representam apenas 13% do total produzido (IBGE, 2021; R. Lima, 2023; Tebet, 2022).

A manga é a segunda fruta tropical mais consumida no mundo, ficando atrás apenas da banana. Além de ser consumida in natura ou seca, ela desempenha um papel significativo na indústria alimentícia, sendo amplamente processada para a produção de polpas, geleias, bebidas e cosméticos. A ampla utilização da manga em diversos produtos industriais e culinários destaca

sua importância econômica e nutricional (EMBRAPA, 2023).

Os preços da manga são mais altos no primeiro semestre, especialmente em maio, devido a quebras de colheita causadas por temperaturas extremas e variabilidade climática. Essas condições adversas podem reduzir a oferta e aumentar os preços. Em contraste, os preços tendem a ser mais baixos em novembro, quando a oferta geralmente se estabiliza. Análises indicam que a temperatura desempenha um papel crucial na produtividade, com temperaturas elevadas durante o ciclo de crescimento da manga podendo levar a perdas na produção e influenciar a variação de preços ao longo do ano, especialmente em Juazeiro, um dos maiores centros de comercialização do Nordeste (Dennys & De, 2015; R. Lima, 2023; Tebet, 2022).

De acordo com (M. de F. Vidal, 2022), o Polo Petrolina/Juazeiro é uma região estratégica para a produção de frutas no Brasil, representando 47% da produção nacional de manga e 23% da produção de uva. Localizado no Submédio São Francisco, este polo é fundamental para o desenvolvimento econômico local e regional, promovendo o crescimento do setor agroindustrial e gerando empregos. As frutas tropicais e subtropicais, como a manga, possuem

um elevado potencial de consumo global, consolidando ainda mais a importância dessa região no mercado nacional e internacional.

O Brasil é um dos principais atores no mercado internacional de frutas, ocupando a terceira posição entre os maiores produtores globais, atrás apenas da China e da Índia. Em 2022, o país respondeu por 45,9% da produção mundial de frutas tropicais e subtropicais. A importância do Polo Petrolina/Juazeiro transcende a produção local, pois sua atuação tanto no mercado interno quanto externo reforça a posição do Brasil no comércio global de frutas (Andrade, 2020; Embrapa, 2023; M. D. F. Vidal, 2024).

A cadeia produtiva da manga em Petrolina, Pernambuco, para exportação envolve várias etapas, desde o cultivo da fruta até a sua chegada aos mercados internacionais. A região como o principal polo de produção é o Vale do Submédio São Francisco, com área plantada de 36,3 mil hectares em 2022, a produtividade média da manga foi de 27 toneladas/hectares e o volume de manga produzida foi de 976,1 mil toneladas no mesmo período e região. Nacionalmente, o valor de produção de manga no Brasil para 2022 foi de R\$ 1,23 bilhões de reais em 2022, sendo que mais da metade deste total é do Vale do

São Francisco (EMBRAPA, 2023; J. R. F. de Lima, 2023).

O preço de mercado da manga desempenha um papel crucial na rentabilidade dos produtores, uma vez que é fundamental para recuperar o investimento feito na safra. Conhecer esses preços é essencial para tomar decisões estratégicas, como o momento adequado para plantar, colher e vender, permitindo aos produtores negociarem acordos mais favoráveis com os agentes econômicos envolvidos (CEPEA, 2024).

A atividade rural está intrinsecamente conectada aos custos de produção e ao preço de venda dos produtos agrícolas. A rentabilidade é fortemente impactada pela interação entre esses custos e o preço de venda, e compreender essa dinâmica é crucial para reduzir perdas na produção e evitar problemas financeiros na cadeia produtiva. A análise de fatores como condições climáticas, pragas e mercado permite a implementação de estratégias eficazes, promovendo o sucesso das operações rurais (Souza, A. C. F., & de Lima, 2023; Subrinho et al., 2021).

Impactos Climáticos na produção de Manga

As mudanças climáticas referem-se às alterações nos padrões de temperatura e clima ao longo dos anos, resultantes tanto de processos naturais quanto das atividades humanas. No século XXI, as atividades humanas têm sido o principal motor dessas mudanças, causando danos significativos à biodiversidade global. Esses impactos incluem a perda de habitats naturais, a degradação dos recursos naturais, o aumento da frequência e intensidade dos desastres ambientais e sérios problemas econômicos e sociais em todo o mundo (Bastien-Olvera et al., 2022; Bathiany et al., 2018; Howard & Sylvan, 2021).

De acordo com o relatório da (WMO, 2021)(WMO, 2021), o estado do clima global está se deteriorando progressivamente devido às concentrações sem precedentes de gases de efeito estufa, ao aumento das temperaturas da Terra e à intensificação dos eventos climáticos extremos dos eventos climáticos extremos, bem como impactos socioeconômicos relacionados.

Um evento é classificado como extremo quando a variável climática ultrapassa um limite próximo às extremidades superior ou inferior do intervalo normal durante um período predefinido. Entre os eventos climáticos extremos estão inundações, enchentes, geadas, alagamentos e deslizamentos de terra, além de secas severas, incêndios e escassez hídrica. Também se destacam pragas agrícolas, desertificação do solo

e a redução da eficiência na produção de commodities agrícolas (Nobre & Marengo, 2017).

Os desastres causados por eventos extremos estão se agravando com o tempo e se tornando mais interconectados, especialmente nos últimos 10 anos. Na agricultura, esses eventos resultam em perda de colheitas, degradação do solo, escassez de água e aumento de pragas e doenças. Além disso, danificam infraestruturas essenciais e forçam mudanças nos tipos de culturas cultivadas. Esses impactos resultam em perdas financeiras significativas para os produtores e comprometem a segurança alimentar, afetando tanto a produção quanto os consumidores (Bashir et al., 2020; Bastien-Olvera et al., 2022; Guyennon et al., 2021; Raza et al., 2020; Zhong et al., 2021).

Em termos de vulnerabilidade e capacidade reduzida dos países em desenvolvimento de se proteger dos impactos da mudança climática, destaca-se a agricultura. Ao considerar alterações nas temperaturas, este setor se torna mais suscetível ao agravamento da situação, uma vez que na maioria dos casos é a única forma de sobrevivência ou constitui base para a economia nacional (Gondim et al., 2017).

A vulnerabilidade dos países afeta sua dependência de um vetor específico da economia, nesse caso, da agricultura, que se torna altamente dependente das condições climáticas. Subsequentemente, isso pode resultar em perda de colheitas, degradação da

qualidade do solo, escassez de água, disseminação de pragas e doenças e, finalmente, ameaçar a segurança alimentar e o sustento econômico e a estabilidade social na maioria das comunidades dependentes da agricultura (Gondim et al., 2017; M. A. De Lima, 2007).

As mudanças climáticas podem alterar os padrões de precipitação e temperatura e aumentar a frequência de eventos climáticos extremos, como o El Niño no semiárido. Essas mudanças afetam a evapotranspiração das plantas, ajustando as necessidades hídricas das culturas e a quantidade de água necessária para irrigação proveniente das bacias. O aumento das temperaturas eleva a demanda de água na atmosfera, o que pode causar estresse hídrico adicional nas plantas devido à diminuição da umidade do solo, resultando em uma possível redução na produtividade das lavouras (FAO, 2024; Gondim et al., 2022; Skendžić et al., 2021).

O aumento das temperaturas pode levar a uma série de impactos negativos, como a redução na produtividade das lavouras, a alteração dos padrões de floração e frutificação, e o agravamento de problemas relacionados à irrigação e ao manejo das doenças. Cultivares de diferentes tipos de manga respondem de maneira variada ao aumento da temperatura do ar. Devido às suas características fenológicas, como a duração do ciclo e as datas de

indução floral, essas respostas podem variar, especialmente para evitar temperaturas elevadas durante os períodos críticos, como florescimento e frutificação (De Oliveira et al., 2022).

Os fatores climáticos que mais afetam a incidência e a severidade das doenças na manga incluem temperatura, precipitação pluviométrica, umidade relativa, duração do molhamento foliar e ventos fortes. Regiões com clima quente e estresse hídrico tendem a ser menos favoráveis para o desenvolvimento de doenças da mangueira (Dennys & De, 2015; EMBRAPA, 2019; R. Lima, 2023; Shu & Sheen, 1987).

O estudo de (Shu & Sheen, 1987) que os ramos das mangueiras não florescem quando a temperatura diurna é de 31°C e a temperatura noturna é de 25°C. Assim, o aumento da temperatura pode impactar negativamente a produção. O clima é um fator crucial na produção de mangas, e os cenários de aquecimento global indicam que o Semiárido brasileiro será uma das regiões mais afetadas pelo aumento das temperaturas, o que pode levar a mudanças na geografia da produção agrícola, tanto para a manga quanto para outras espécies.

Portanto, conforme os autores supracitados, o aumento da temperatura pode impactar negativamente a

produção, o clima é um fator crucial na produção de mangas, e os cenários de aquecimento global indicam que o Semiárido brasileiro, incluindo a região de Petrolina, será uma das regiões mais afetadas pelo aumento das temperaturas. Esta região, é um importante produtor de manga no Estado, enfrenta desafios crescentes devido ao aquecimento global e ao estresse hídrico associado (Araújo et al., 2018).

Reinforcement Learning

Conforme (Harmon et al., 2020), Reinforcement Learning (RL) é uma área da inteligência artificial onde um agente aprende a tomar decisões através de interação com um ambiente, no qual o objetivo é aprender políticas que maximizem a recompensa acumulada ao longo do tempo. Diferentemente do aprendizado supervisionado, no qual os pares de entrada e saída são fornecidos ao modelo para treinamento, o RL trabalha com feedbacks esparsos ou retardados, onde a ação tomada pelo agente pode influenciar estados futuros e, conseqüentemente, as recompensas recebidas ao longo de uma sequência temporal (Sutton & Barto, 2018).

O RL é estruturado em torno de componentes chave como política (policy), função de valor (value function),

função de recompensa (reward function), e o ambiente (environment). A política define a estratégia que o agente segue para selecionar ações em diferentes estados, enquanto a função de valor estima a recompensa esperada de um estado ou de uma ação em um estado. A interação entre o agente e o ambiente gera uma sequência de estados, ações e recompensas que são utilizados para ajustar a política do agente ao longo do tempo.

Long Short Term Memory (LSTM)

As redes Long Short Term Memory (LSTM) são um tipo especial de redes neurais recorrentes (RNNs), desenvolvidas para superar as limitações das RNNs tradicionais, que sofrem com o problema do gradiente desaparecendo ou explodindo ao lidar com dependências de longo prazo em dados sequenciais (Hochreiter & Schmidhuber, 1997). As LSTMs introduzem a ideia de células de memória que mantêm informações ao longo do tempo, o que permite que essas redes capturem padrões temporais e contextos de longo prazo de maneira mais eficaz (Graves, 2012).

A memória de longo prazo (LSTM) é uma poderosa disposição de

rede neural artificial projetada para enfrentar o desafio de aprender e armazenar informações em longos períodos, particularmente em sequências com dependências de longo prazo.

Integração de RL com LSTM

A combinação de Reinforcement Learning (RL) com redes neurais Long Short-Term Memory (LSTM) tem se mostrado particularmente eficaz em situações em que a previsão e a tomada de decisão ao longo do tempo são essenciais. Juntas, essas técnicas oferecem uma análise mais precisa e uma previsão mais robusta dos resultados, permitindo decisões mais bem fundamentadas e melhorando a eficiência e sustentabilidade das operações agrícolas.

Um exemplo prático dessa combinação é o controle de sistemas dinâmicos, onde um agente de RL precisa tomar decisões que dependem não apenas do estado atual do sistema, mas também de dados históricos. Nesse cenário, as LSTMs são empregadas para capturar a estrutura temporal dos dados, proporcionando ao agente RL uma visão detalhada do histórico de estados. Isso é crucial para tomar decisões informadas e eficazes (Graves, 2012; Hochreiter & Schmidhuber, 1997).

Métodos Estatísticos na Análise Climática e Agrícola: Previsão de séries temporais (ARIMA)

O Modelo (AutoRegressive Integrated Moving Average) ARIMA como é conhecido, é um método de modelagem estatística que tem se mostrado extremamente útil em diversas áreas, incluindo a agricultura. Baseado no método Box-Jenkins, o ARIMA são ferramentas estatísticas amplamente utilizadas para analisar e prever séries temporais. (Box & Jenkins, 1970)

Esses modelos operam partem do pressuposto de que os dados são estacionários, ou seja, que não apresentam tendências ou sazonalidades ao longo do tempo. Eles identificam padrões e relacionamentos entre as observações por meio da análise de autocorrelação e utilizam essas informações para realizar previsões futuras com base em dados passados, permitindo modelar e prever séries temporais de forma eficaz ao captar a estrutura de dependência temporal e os padrões e tendência nos dados, o que o torna uma ferramenta valiosa para planejamento e tomada de decisões em contextos variáveis, como a agricultura por exemplo. (Box et al., 2015; Yadav & Ghosh, 2019)

O modelo ARIMA é composto por três principais componentes: AR (AutoRegressivo), que captura a dependência dos valores atuais dos valores passados; I (Integrated), que se refere ao processo de diferenciação aplicado para tornar a série estacionária; e MA (Médias Móveis), que modela a dependência entre o valor atual e os erros passados. Esses componentes trabalham juntos para modelar séries temporais sem padrões sazonais, permitindo previsões precisas e uma análise robusta dos dados temporais. (Campos & Cordeiro, 2006)

Na agricultura, o ARIMA pode ser utilizado para analisar e prever dados relacionados à produção de culturas e às condições climáticas. Para o

contexto da produção de manga, o ARIMA pode ser aplicado para prever como as variações na temperatura podem impactar o rendimento das safras.

Estudos como os de (Praveen & Sharma, 2020) demonstram como o ARIMA pode ser utilizado para avaliar a variabilidade climática e seu impacto na agricultura, permitindo aos produtores antecipar mudanças e adaptar suas práticas para minimizar prejuízos. Além disso, a técnica supracitada pode ajudar a planejar decisões de forma mais racional, ajustando-se às variações econômicas e climáticas.

Para uma compreensão mais clara, o modelo ARIMA pode ser dividido em três fases principais, conforme ilustrado na Figura 1.




Figura 1: Processos da Fases do modelo ARIMA.

Fonte: Adaptado de (Campos & Cordeiro, 2006).

Na Fase 1, é necessário preparar e analisar os dados para adequá-los ao modelo ARIMA, o que inclui estabilizar

a variância e aplicar diferenciação para alcançar a estacionariedade. Na Fase 2, os parâmetros do modelo são definidos:

p (ordem da parte autoregressiva ou número de defasagens), d (número de diferenciações necessárias para garantir a estacionariedade) e q (número de defasagens dos erros de previsão na média móvel). Por fim, na Fase 3, aplicam-se os dados e os parâmetros definidos na equação ARIMA para gerar previsões futuras (Puchalsky et al., 2018; Shumway & Stoffer, 2011).

A aplicação do ARIMA na previsão de dados de temperatura e produção de manga permite uma compreensão mais profunda dos fatores que afetam a produção, possibilitando estratégias mais eficazes para enfrentar os desafios climáticos e otimizar os rendimentos (Pardhi et al., 2018).

Metodologia

Para modelar a série temporal referente à produção de manga no estado de Pernambuco, inicialmente extraiu-se a base de dados da produção anual, disponível pela Instituto Brasileiro de Geografia e Estatística-IBGE (2023) para agricultura, em que relata os valores, quantitativo e características da produção anual de manga. Os dados disponíveis continham o montante de produção anual de manga com periodicidade anual, iniciando em 2009 e final em 2022.

A partir da base de dados exportou-a para o software MATLAB™ *release 2024b* para modelar as séries temporais tendo como base duas metodologias: ARIMA e Redes Neurais Recorrentes (Box et al., 2015).

A metodologia para aplicação do modelo ARIMA, segue-se então para a estimação dos três parâmetros: p- ordem autorregressiva da, d- número de diferenciações necessárias e q o número de defasagens dos erros. A série temporal de produção da manga, possui duas características distintas quando comparadas com a dinâmica do sistema: tendência ascendente desde 2009 até 2018, com pico máximo de produção em 2019 e queda subsequente para estabilização em 2022. Assim, observa-se a necessidade da diferenciação da série para remoção da tendência crescente nos primeiros anos. A ordem autorregressiva da série foi observada a partir da variação da produção anual, sendo caracterizada igual a um. Maiores valores da ordem regressiva mostraram comportamento

indesejado de *Overfitting*, em que o modelo matemático se ajusta demasiadamente havendo percas de singularidades da série temporal.

A Rede neural recorrente foi aplicada pelo algoritmo de treinamento *Levenberg – Marquardt* com métrica de

performance a média do erro quadrado, a base de dados foi particionada: 82% para treinamento e 18% para teste e validação. A escolha da proporção baseou-se pelo quantitativo de leituras disponíveis a partir do número de épocas igual a 9 em 200 camadas de treinamento com atraso no tempo de 2 segundos (Harmon et al., 2020; Yadav & Ghosh, 2019).

Descrição e Análise de Dados

A partir da aplicação do método ARIMA (1,1,0) e Rede Neural Recorrente, os seguintes comportamentos estatísticos foram observados:

A figura 1 explicita duas subfiguras com os resultados do modelo ARIMA (1,1,0). Na primeira subfigura contém o comparativo entre a produção de manga, representado em linha sólida em azul juntamente com o modelo, em linha pontilhada vermelha. Pode-se observar que o modelo descreveu fortemente o comportamento da série, nos anos iniciais bem como o pico de produtividade em 2019. Avalia-se também que a partir de 2017 o modelo apresentou uma diferença maior entre o observado bem como o montante do pico, alternando entre o subdimensionamento

dentre 2016 a 2017 e superdimensionamento em 2019. A figura 2 corrobora com as informações elencadas, havendo resíduos em menor nível de magnitude no começo da série com inflexão positiva seguida de negativa entre 2017 e 2019 representando então as produções máxima de manga no período observado. A figura 3 representa os resultados do modelo da rede neural recorrente tendo como base também a produção de manga no estado de Pernambuco. É possível observar que a característica geral da série temporal foi expressa pelo modelo, no entanto, em nível de escala menor que a observada, havendo propensão ao subdimensionamento dos valores de produção de manga.

Numericamente o modelo resultou em maior proporção de resíduos, disponível na Figura 4, durante a elevação ao ponto máximo em 2019, em que os gradientes de treinamento foram em pequena escala não representados pelo modelo de rede neural. A tabela 1 sintetiza as informações e métrica dos modelos aplicados. Frente ao ARIMA (1,1,0) explicita a constante do modelo juntamente com o primeiro coeficiente e a variância, com as colunas de valores, o erro da métrica, estatística t-Student e o p-valor. No caso da Rede Neural Recor-

rente (RNN), foram obtidos dois valores para o coeficiente de determinação (R^2), que foram

0,982 e 0,9303. Esses valores indicam a proporção da variabilidade dos dados que o modelo conseguiu explicar. Um coeficiente de determinação próximo de 1, como 0,982, sugere que o modelo RNN teve um desempenho excelente, explicando quase toda a variação observada nos dados. Já o valor de 0,9303, embora um pouco menor, ainda demonstra que o modelo mantém uma boa capacidade preditiva e é adequado para a tarefa proposta. Esses resultados reforçam a qualidade e a confiabilidade do modelo RNN para o problema apresentado.

Com base nos dados dos resultados supracitados, as previsões geradas pelos modelos ARIMA e Redes Neurais

têm várias aplicações práticas para os produtores agrícolas de Petrolina-PE, permitindo-lhes tomar decisões mais informadas e estratégicas. Primeiramente, com dados precisos sobre a produção e os padrões climáticos esperados, os agricultores podem planejar melhor suas colheitas, determinando o momento ideal para a colheita das mangas, o que maximiza a qualidade e o valor de mercado dos frutos. Além disso, a gestão da irrigação se torna mais eficiente, pois os produtores podem ajustar os sistemas de irrigação de acordo com as previsões de precipitação e temperatura, evitando tanto a falta quanto o excesso de água, que pode prejudicar as plantas.




Figura 2: Modelo ARIMA e resíduos

Fonte: Autores (2024)




Figura 3: Predição de produção de manga – Rede Neural Recorrente

Fonte: Autores (2024)




Figura 4: Resíduos produção de manga – Rede Neural Recorrente

Fonte: Autores (2024)

Modelo ARIMA (1,1,0)					Rede Neural Recorrente			
Parâmetro	Valor	Erro	Estatística t	pvalor	Etapa	Observações	MSE	R ²
Constant	2.611936	1,53E+07	0.1705	0.8646	Treinamento	10	7,70E+08	0,982
AR{1}	0.9015	0.0515	174.979	1,49E-64	Validação	2	1,30E+10	1
Variance	8,56E+11	0.0793	1,08E+13	0	Teste	14	2,80E+09	0,9303

Tabela 1: Métricas dos modelos ARIMA (1,1,0) e Rede Neural Recorrente

Fonte: Autores (2024)

Os dados também podem influenciar a escolha de variedades de mangas que são mais adequadas para as condições climáticas projetadas, ajudando na seleção de cultivares que se destacam em resistência a doenças e estresses hídricos. Com informações sobre as expectativas de preço no mercado, os produtores podem definir estratégias de comercialização e precificação mais eficazes, garantindo melhores margens de lucro.

Por fim, as previsões também têm um papel crucial no planejamento financeiro, já que os produtores podem projetar suas receitas futuras com mais precisão, possibilitando uma melhor. Em suma, a aplicação desses modelos permite uma abordagem mais proativa e adaptativa no manejo agrícola, contribuindo para a resiliência e a sustentabilidade econômica da produção de manga.

Considerações Finais

O estudo demonstrou que as mudanças climáticas, particularmente o aumento das temperaturas, têm um impacto significativo na produção de manga, especialmente na região de Petrolina, um dos principais polos de cultivo dessa fruta no Brasil. Com base nos

dados analisados e nas projeções climáticas, há uma correlação direta entre o aumento das temperaturas e a queda na produtividade das safras de manga, evidenciando que as temperaturas elevadas prejudicam processos críticos como a floração e a frutificação das plantas.

Os resultados do modelo ARIMA (1,1,0) demonstram que a produção de manga é sensível às variações de temperatura, confirmando a hipótese de que as condições climáticas extremas, como o aumento da temperatura média está associado a uma redução significativa na produtividade. A análise dos resíduos do modelo revelou que, durante os anos de maior produção, como 2019, houve uma tendência de superdimensionamento, indicando que as condições climáticas adversas poderiam estar influenciando negativamente as estimativas de produtividade.

Além disso, a aplicação das Redes Neurais Recorrentes também mostrou limitações na captura precisa dos picos de produção. O modelo apresentou um subdimensionamento nas estimativas durante os períodos críticos, especialmente em 2019, sugerindo que as técnicas de aprendizado de máquina precisam incorporar mais informações

sobre as variações climáticas para melhorar a precisão das previsões.

A tendência de aumento da temperatura global projeta desafios significativos para a produção de manga, principalmente em regiões semiáridas como Petrolina-PE, que já enfrentam condições de estresse térmico e hídrico. O aumento das temperaturas pode alterar os padrões de floração e frutificação da manga, diminuindo a eficiência dos processos fisiológicos das plantas e resultando em menor rendimento das safras. Com as temperaturas diurnas próximas a 31°C e noturnas em torno de 25°C, como observado no estudo de Shu & Sheen (1987), há uma diminuição substancial na capacidade das mangueiras de florescerem adequadamente, o que impacta diretamente a produtividade.

A vulnerabilidade da produção de manga às mudanças climáticas resalta a importância de monitorar e ajustar continuamente as práticas agrícolas em resposta ao aumento das temperaturas. Uma abordagem integrada, utilizando técnicas estatísticas e de aprendizado de máquina, pode não apenas melhorar as previsões de produtividade, mas também auxiliar na tomada de decisões estratégicas que minimizem os impactos negativos das mudanças climáticas na agricultura da região. Isso é

fundamental para manter a viabilidade econômica e a segurança alimentar da região de Petrolina-PE, que é um importante pilar para o desenvolvimento socioeconômico local.

Projeções Futuras e Recomendações

Com base nas projeções climáticas de aumento contínuo das temperaturas globais, é provável que a região de Petrolina, um dos principais polos produtores de manga do Brasil, sofra com uma queda significativa na produção nos próximos anos, caso não sejam implementadas medidas de adaptação. Recomenda-se que estratégias de manejo sejam desenvolvidas para mitigar os efeitos do aumento das temperaturas, como a introdução de práticas agrícolas que aumentem a resiliência das plantas ao estresse térmico e hídrico, o uso de técnicas de irrigação mais eficientes, e a seleção de cultivares mais adaptadas às condições de calor extremo.

O uso integrado de tecnologias preditivas, como o modelo ARIMA e as Redes Neurais Recorrentes, em combinação com outras abordagens de aprendizado de máquina, como Reinforcement Learning (RL) e Long Short-Term Memory (LSTM), pode oferecer uma

abordagem mais robusta para prever e responder às mudanças climáticas na produção de manga. A aplicação desses métodos pode ajudar a planejar intervenções mais eficazes, melhorar a eficiência das operações agrícolas e assegurar uma produção sustentável, mesmo diante das variações climáticas futuras.

Referências

- Andrade, P. F. de S. (2020). *Fruticultura, análise da conjuntura: prognóstico 2020*.
- Araújo, W. B. C., Campos, R. T., & Campos, K. C. (2018). Análise da Cadeia Produtiva da Manga em Petrolina. *Revista Política Agrícola*, 4, 122–133.
- Bashir, M. F., Ma, B., Bilal, Komal, B., Bashir, M., Tan, D., & Bashir, M. (2020). Correlation between climate indicators and COVID-19 pandemic in New York, USA. *January*.
<https://doi.org/https://doi.org/10.1016/j.scitotenv.2020.138835>
- Bastien-Olvera, B. A., Granella, F., & Moore, F. C. (2022). Persistent effect of temperature on GDP identified from lower frequency temperature variability. *Environmental Research Letters*, 17(8), 084038.
<https://doi.org/10.1088/1748-9326/ac82c2>
- Bathiany, S., Dakos, V., Scheffer, M., & Lenton, T. M. (2018). Climate models predict increasing temperature variability in poor countries. *Science Advances*, 4(5).
<https://doi.org/10.1126/sciadv.aar5809>
- Box, G. E. P., & Jenkins, G. M. (1970). *Time Series Analysis: Forecasting and Control*. 112.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control*. *Journal of Marketing Research*.
<https://doi.org/10.2307/3150485>
- Campos, P. A. C., & Cordeiro, A. A. L. de. (2006). Aplicação do modelo ARIMA para previsão do preço do frango inteiro resfriado no grande atacado do estado de São Paulo. Em *XIII Congresso Brasileiro de Custos*.
- CEPEA. (2024). *Cepea (Centro de Estudos Avançados em Economia Aplicada), da Esalq/USP*.
- Chevuturi, A., Klingaman, N. P., Turner, A. G., Guo, L., & Vidale, P. L. (2022). Projected Changes in the East Asian Hydrological Cycle for Different Levels of Future Global Warming. *Atmosphere*, 13(3), 1–25.
<https://doi.org/10.3390/atmos13030405>
- De Oliveira, J. R., Moreira, N. M., De Carvalho, A. C., Dos Santos, A. B. C., & Da Silva, I. L. do S. S. (2022). Efeito da densidade de inóculo, temperatura, período de molhamento sobre o desenvolvimento de lesões e controle alternativo de antracnose e podridão peduncular

de manga Tommy Atkins. *Brazilian Journal of Animal and Environmental Research*, 5(4), 4410–4428. <https://doi.org/10.34188/bjaerv5n4-084>

Dennys, G., & De, M. S. B. (2015). *Impacto do Aumento de Temperatura na Produção da Mangueira* Impact of Temperature Rise on Mango Production. <https://ainfo.cnptia.embrapa.br/dig>

EMBRAPA. (2023). *Produção brasileira de manga em 2022*. 4–7.

EMBRAPA. (2019). *Cultivo da Mangueira Apresentação Socioeconomia* (3a ed.). Empresa Brasileira de Pesquisa Agropecuária (Embrapa). <https://doi.org/Disponível> em: <https://www.infoteca.cnptia.embrapa.br/bitstream/doc/884451/1/CultivodaMangueira.pdf>. Acesso: agosto de 2024

EMBRAPA. (2023). BRASIL EM 50 ALIMENTOS. Em *Empresa Brasileira de Pesquisa Agropecuária* (pp. 1–17). <https://doi.org/Acesso>: Agosto de 2024

FAO. (2024). OECD-FAO Agricultural Outlook 2024-2033. Em *OECD-FAO Agricultural Outlook 2024-2033*. <https://doi.org/10.4060/cd0991en>

Glenn, E. P., Hodges, C. N., Lieth, H., Pielke, R., & Pitelka, L. (1992). Climate. *Environment*, 34(3), 5–40. <https://doi.org/10.1080/00139157.1992.9931432>

Gondim, R. S., Maia, A. de H. N., Figueirêdo, M. C. B. de, Bezerra, M. A., & Carvalho, C. A. C. de. (2017). *Mudanças climáticas e Agricultura* (Vol. Parte 2-). <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1076096>. Acesso: Julho de 2024

Gondim, R. S., Maia, A. de H. N., Figueirêdo, M. C. B. de, & Evangelista, S. R. M. (2022). Mudanças Climáticas, Agricultura Irrigada e Integração De Modelos. *Journal of the Japan Welding Society*, 91(5), 328–341. <https://doi.org/10.2207/jjws.91.328>

Graves, A. (2012). *Supervised Sequence Labelling with Recurrent Neural Networks* (Vol. 385).

Guyennon, N., Salerno, F., Rossi, D., Rainaldi, M., Calizza, E., & Romano, E. (2021). Climate change and water abstraction impacts on the long-term variability of water levels in Lake Bracciano (Central Italy): A Random Forest approach. *Journal of Hydrology: Regional Studies*, 37(April), 1–13. <https://doi.org/10.1016/j.ejrh.2021.100880>

Harmon, M. E., & Harmon, S. S. (2020). Reinforcement Learning: A Tutorial. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, 9(July 2000), 1–89. <https://www.researchgate.net/publication/2464216>. Acesso: Agosto de 2024

Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

Howard, P., & Sylvan, D. (2021). *Gauging Economic Consensus on Climate Change*. I. for P. Integrity.

Hussain, M., Butt, A. R., Uzma, F., Ahmed, R., Irshad, S., Rehman, A., & Yousaf, B. (2020). A comprehensive review of climate change impacts, adaptation, and mitigation on environmental and natural calamities in Pakistan. *Environmental Monitoring and Assessment*, 192(1). <https://doi.org/10.1007/s10661-019-7956-4>

IBGE. (2021). *Sistema de Contas Nacionais. PIB dos Municípios*. Instituto Brasileiro de Geografia e Estatística.

IPCC. (2014). *Climate Change 2014 Synthesis Report Summary Chapter for Policymakers*. *Ipcc*, 31.

IPCC. (2023). Health, Wellbeing and the Changing Structure of Communities. *Climate Change 2022 – Impacts, Adaptation and Vulnerability*, 1041–1170. <https://doi.org/10.1017/9781009325844.009>

Lima, J. R. (2023). *MERCADO DE MANGAS E A IMPORTÂNCIA*. Observatório Da Manga- Embrapa.

Lima, J. R. F. de. (2023). *Desenvolvimento Regional do Submédio Vale do São Francisco*. SOBER-NE.

Lima, M. A. de. (2007). *Impactos, Vulnerabilidade e Adaptação às Mudanças Climáticas no Brasil Impactos na Agricultura*. Embrapa.

Lima, R. (2023). *Desafios e Tendências dos Mercados de Uva e Manga*.

Mackay, A. (2008). Climate Change 2007: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change. *Journal of Environmental Quality*, 37(6), 2407–2407. <https://doi.org/10.2134/jeq2008.0015br>

Malhi, G. S., Kaur, M., & Kaushik, P. (2021). Impact of climate change on agriculture and its mitigation strategies: A review. *Sustainability (Switzerland)*, 13(3), 1–21. <https://doi.org/10.3390/su13031318>

Nations, U. (1992). *United Nations Framework Convention*. 62220.

Nobre, C. A., & Marengo, J. A. (2017). *Mudanças climáticas em rede: um olhar interdisciplinar* (1a ed.). Canal 6 Ed.

Pardhi, R., Singh, R., & Kumar Paul, R. (2018). Price Forecasting of Mango in Varanasi Market of Uttar Pradesh. *Current Agriculture Research Journal*, 6(2), 218–224. <https://doi.org/10.12944/carj.6.2.12>

Penman, J., Gytarsky, M., Hiraishi, T., Irving, W., & Krug, T. (2006). 2006 IPCC - Guidelines for National Greenhouse Gas Inventories. <http://www.ipcc-nggip.iges.or.jp/public/2006gl/index.html>

Praveen, B., & Sharma, P. (2020). Climate variability and its impacts on agriculture production and future prediction using autoregressive integrated moving average method (ARIMA). *Journal of Public Affairs*, 20(2), 1-12. <https://doi.org/10.1002/pa.2016>

Puchalsky, W., Ribeiro, G. T., da Veiga, C. P., Freire, R. Z., & Santos Coelho, L. dos. (2018). Agribusiness time series forecasting using Wavelet neural networks and metaheuristic optimization: An analysis of the soybean sack price and perishable products demand. *International Journal of Production Economics*, 203(June), 174-189. <https://doi.org/10.1016/j.ijpe.2018.06.010>

Raza, T., Liwag, C. R. E. U., Andres, A. V. L., Castro, J. T., Cuña, A. C., Vinarao, V. G., Raza, T. K. S., Marasigan, K. M. E., Espinosa, R. I. M., Rentoy, F. C., Perez, B. D., & Ahmed, N. (2020). Extreme weather disasters challenges for sustainable development: Innovating a science and policy framework for disaster-resilient and sustainable Quezon City, Philippines. *Progress in Disaster Science*, 5, 100066.

<https://doi.org/10.1016/j.pdisas.2020.100066>

Reay, D., Sabine, C., Smith, P., & Hymus, G. (2007a). Intergovernmental Panel on Climate Change. Fourth Assessment Report. Geneva, Switzerland: Intergovernmental Panel on Climate Change. Cambridge; UK: Cambridge University Press; 2007. Available from: www.ipcc.ch. Em *Intergovernmental Panel on Climate Change*. <https://doi.org/10.1038/446727a>

Reay, D., Sabine, C., Smith, P., & Hymus, G. (2007b). Spring-time for sinks. *Nature*, 446(7137), 727-728. <https://doi.org/10.1038/446727a>

Shu, Z. H., & Sheen, T. F. (1987). Floral induction in axillary buds of mango (*Mangifera indica* L.) as affected by temperature. *Scientia Horticulturae*, 31(1-2), 81-87. [https://doi.org/10.1016/0304-4238\(87\)90109-9](https://doi.org/10.1016/0304-4238(87)90109-9)

Shukla, P., Skea, J., Slade, A., Al Khourdajie, A., van Diemen, R., McCollum, D., Pathak, M., Some, S., Vyas, P., Fradera, R., Belkacemi, M., Hasija, A., Lisboa, G., Luz, S., & Malley, J. (2023). Summary for Policymakers in Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the IPCC. Em *Climate Change 2022 - Mitigation of Climate Change*.

<https://www.cambridge.org/core/books/climate-change-2022-mitigation-of-climate-change/summary-for-policymakers/ABC31CEA863CB6AD8FEB6911A872B321>

Shumway, R. H., & Stoffer, D. H. (2011). Chapter 3: ARIMA Models. *Time Series Analysis and Its Applications*, 1970, 84–164. <https://doi.org/10.1007/978-3-319-52452-8>

Skendžić, S., Zovko, M., Živković, I. P., Lešić, V., & Lemić, D. (2021). The impact of climate change on agricultural insect pests. Em *Insects* (Vol. 12, Issue 5). <https://doi.org/10.3390/insects12050440>

Souza, A. C. F., & de Lima, J. R. F. (2023). Behavior of Palmer mango prices to the producer of Vale do Submédio São Francisco. *Revista de Economia e Sociologia Rural*, 61(1), 1–20. <https://doi.org/10.1590/1806-9479.2021.250161>

Subrinho, A. G. de S., Araújo, J. L. P., de Lima, J. R. F., & Neto, A. S. (2021). Economic and financial determination of mango cultivation under different Irrigation Management, in the Curaçá Project, in Juazeiro - BA. *International Journal of Advanced Engineering Research and Science*, 8(10), 023–034. <https://doi.org/10.22161/ijaers.810.3>

Sutton, R. S., & Barto, A. G. (2018). Reinforcement Learning: An Introduction. *Neurocomputing*, 35(1–4),

205–206. [https://doi.org/10.1016/s0925-2312\(00\)00324-6](https://doi.org/10.1016/s0925-2312(00)00324-6)

Tebet, S. N. (2022). Produção Agrícola Municipal Culturas temporárias e permanentes. Em IBGE (Ed.), *INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE* (Vol. 49).

Vidal, M. D. F. (2024). *Fruticultura*. Escriatório Técnico de Estudos Econômicos Do Nordeste - ETENE.

Vidal, M. de F. (2022). Agropecuária - Fruticultura. *Caderno Setorial Etene*, 7(228), 1–16. https://www.bnb.gov.br/s482-dspace/bitstream/123456789/1326/3/2022_CDS_228.pdf

WMO. (2021). *State of the Global Climate 2020* (Issue 1264). https://library.wmo.int/index.php?lvl=notice_display&id=21880#.YHg0AB-MzZR0

Yadav, A., & Ghosh, S. (2019). Forecasting monthly farm tractor demand for India using MSARIMA and ARMAX models. *Indian Journal of Agricultural Research*, 53(3), 315–320. <https://doi.org/10.18805/IJAR.A-5185>

Zhang, H., Fan, J., Cao, W., Harris, W., Li, Y., Chi, W., & Wang, S. (2018). Response of wind erosion dynamics to climate change and human activity in Inner Mongolia, China during 1990 to 2015. *Science of the Total Environment*, 639, 1038–1050.

<https://doi.org/10.1016/j.scitotenv.2018.05.082>

<https://doi.org/10.1016/j.accre.2021.07.002>

Zhong, S., Cheng, Q., Huang, C. R., & Wang, Z. (2021). Establishment and validation of health vulnerability and adaptation indices under extreme weather events on the basis of the 2016 flood in Anhui province, China. *Advances in Climate Change Research*, 12(5), 649–659.

Rita de Cássia de Vasconcelos Pedrosa (rita.cvpedrosa@gmail.com)* trabalhou na concepção e estruturação da pesquisa, coleta e organização de dados, aplicação dos modelos ARIMA, LSTM e Reinforcement Learning, análise estatística, redação e revisão final do artigo.

Guilherme Lopes de Campos (guilherme_lc@id.uff.br) colaborou na coleta e tratamento dos dados, aplicação prática dos modelos de séries temporais, análise e discussão dos resultados.

Denise Honorato Lopes da Silva (denise.honorato@hotmail.com) participou da revisão da literatura e coleta de dados.

Hallysson Farias Gomes (hallyssonfariasgomes@gmail.com) atuou no apoio à análise de dados.

Cláudio Tadeu Cristino (claudio.cristino@ufrpe.br) contribuiu com a orientação geral da pesquisa, revisão e acompanhamento das etapas desenvolvidas.

Data de Submissão: 01/07/2025 Data de Aprovação: 10/08/2025.

Editor-Chefe: Diogo Henrique Helal.

Editor Adjunto: Bruno Melo Moura.

Direitos autorais das pessoas autoras, 2025. Licenciado sob Licença Creative Commons Atribuição-NãoComercial 4.0 Internacional (CC BY-NC 4.0). Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do material em qualquer meio ou formato, apenas para fins não comerciais, desde que seja dada a devida atribuição ao criador. Texto da Licença: <https://creativecommons.org/licenses/by-nc/4.0/>

