

Aplicação da Modelagem Difusa Baseada em Dados de Uma EMA Para Previsão de Chuvas

Janaide Nogueira de Sousa Ximenes¹, Rhyan Ximenes de Brito²

¹Universidade Estadual do Ceará (UECE)

Av. Dr. Silas Munguba, 1700, Itaperi, CEP 60.714-903 - Fortaleza - CE, Brasil

²Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Av. Tabelaio Luiz Nogueira Lima, SN, CEP 62.320-000 – Tianguá – CE, Brasil

{nogueirajanaide, rxbrito}@gmail.com

Abstract. *The application of fuzzy modeling for rainfall prediction is of great importance to agriculture and other productive sectors. This study aimed to develop a predictive tool for rainfall estimation using fuzzy logic, based on data from an Automatic Weather Station located in the state of Ceará, provided by the National Institute of Meteorology. The methodology consisted of applying fuzzy logic to analyze meteorological variables collected by the station, aiming to predict rainfall events. It was observed that fuzzy logic can assist meteorology professionals by providing support for rainfall forecasting, contributing to decision-making in areas affected by weather conditions.*

Resumo. *A aplicação da modelagem difusa para a previsão de chuvas é de grande importância para a agricultura e outros setores produtivos. Este estudo teve como objetivo desenvolver uma ferramenta preditiva de precipitação pluviométrica, utilizando a lógica fuzzy, baseada em dados de uma Estação Meteorológica Automática localizada no estado do Ceará, fornecidos pelo Instituto Nacional de Meteorologia. A metodologia consistiu na aplicação da lógica difusa para analisar variáveis meteorológicas coletadas pela estação, visando prever eventos de chuva. Observou-se que lógica fuzzy pode auxiliar profissionais da meteorologia, oferecendo suporte na previsão de chuvas contribuindo para a tomada de decisões em áreas impactadas pelas condições climáticas.*

1. Introdução

A previsão de precipitações é essencial para a agricultura, gerenciamento de recursos hídricos e diversos setores produtivos que dependem diretamente das condições climáticas. A precisão nas estimativas de eventos de chuva permitem que produtores e gestores planejem suas atividades de forma mais segura e eficiente, minimizando riscos e perdas causadas por fenômenos naturais. Neste contexto, a aplicação de técnicas de Inteligência Artificial (IA), especialmente a lógica *fuzzy*, surge como uma abordagem promissora para lidar com a variabilidade e incertezas inerentes aos dados meteorológicos.

Este trabalho teve como foco o desenvolvimento de uma ferramenta preditiva de precipitação pluviométrica utilizando modelagem difusa, baseada em dados meteorológicos coletados por uma Estação Meteorológica Automática (EMA) localizada no interior do estado do Ceará e disponibilizados pelo Instituto Nacional de Meteorologia (INMET).

A metodologia proposta emprega a lógica difusa para interpretar variáveis meteorológicas, visando prever de forma mais confiável possíveis eventos de precipitação. Espera-se que esta abordagem contribua significativamente para a previsão de chuvas, apoiando decisões no setor meteorológico e promovendo benefícios práticos para áreas dependentes do clima.

A estrutura deste trabalho está organizada da seguinte maneira: a Seção 2 apresenta os trabalhos relacionados, com uma revisão da literatura sobre a aplicação de técnicas de Inteligência Artificial na previsão de chuva; a Seção 3 aborda a fundamentação teórica, contemplando os principais conceitos e bases técnicas pertinentes ao tema; a Seção 4 descreve os materiais e métodos utilizados no desenvolvimento da pesquisa; a Seção 5 expõe e discute os resultados obtidos; e, por fim, a Seção 6 apresenta as considerações finais, bem como propostas para estudos futuros.

2. Trabalhos Relacionados

Esta seção traz uma revisão de estudos previamente realizados com a utilização da Inteligência Artificial no contexto da possibilidade de chuva, destacando abordagens relevantes com técnicas como Redes Neurais Artificiais (RNA) e Classificadores Estatísticos (CE). Além disso, permite contextualizar a pesquisa dentro do estado da arte, evidenciando a contribuição do estudo em relação a trabalhos anteriores.

De [de Almeida Sá 2019] propôs um sistema *fuzzy* para estimar a possibilidade de chuva no dia seguinte, ou seja, processo logístico, utilizando dados oficiais de uma estação climática autônoma localizada no município de Sorocaba-SP. No trabalho foi formalizada a base teórica para a criação de um dispositivo autônomo, *offline*, de previsão de chuva local.

[de Lima and Guedes 2015] propuseram uma abordagem com redes neurais multicamadas para prever precipitações em Manaus - AM, usando dados de 1970 a 2014. Foram testadas 2.500 redes neurais com até 50 neurônios por camada, identificando a arquitetura 4-9-7-1 como a mais eficiente, alcançando cerca de 70% de acerto.

[Luiz and Schroder 2020], o estudo avaliou a eficácia dos métodos *Multilayer Perceptron* (MLP) e *Gradient Boosting Machine* (GBM) com uso da técnica de amostragem *bootstrap*, considerando dados de dois pluviômetros próximos à estação fluviométrica. A performance foi medida pelo coeficiente de determinação (R^2) e desvio absoluto, com R^2 de 93% para o MLP e 99% para o GBM.

[Oliveira et al. 2021] avaliaram o classificador *Random Forest*, Regressão Polinomial e *Support Vector Regression Machines* na previsão de chuva-vazão para apoiar a gestão hídrica no Nordeste. Usando dados diários de uma estação pluviométrica, os melhores modelos alcançaram R^2 entre 49,8% e 53,2%.

O artigo traz como diferencial a utilização da lógica difusa aplicada a uma base de dados meteorológicos coletada em uma cidade da região da Serra da Ibiapaba, no interior do estado do Ceará. O objetivo é prever precipitações com base em variáveis linguísticas, como umidade relativa máxima, ponto de orvalho, pressão atmosférica mínima, temperatura máxima, entre outras.

Diferentemente de outros trabalhos presentes na literatura, que fazem uso de técnicas mais complexas, como Redes Neurais Artificiais e Classificadores Estatísticos

(CE) a exemplo do algoritmo *Random Forest*, esta proposta se destaca pela adoção exclusiva da lógica *fuzzy*. A metodologia emprega dados provenientes de uma Estação Meteorológica Automática (EMA) localizada na Serra da Ibiapaba, uma região de expressiva relevância para a atividade agrícola. Essa abordagem, além de ser mais simples e interpretável, oferece maior transparência nos processos de inferência, facilitando a análise por especialistas e contribuindo diretamente para a tomada de decisões estratégicas no contexto local.

3. Fundamentação Teórica

Esta seção apresenta uma revisão técnica e teórica dos temas utilizados como base para a elaboração deste trabalho. A Subseção 3.1 introduz conceitos relacionados a precipitações pluviométricas e a subseção 3.2 destaca conceitos relacionados a lógica difusa.

3.1. Precipitações Pluviométricas

De acordo com [Ferrari 2012], há uma grande preocupação no meio científico nos últimos anos com relação às mudanças climáticas, assim como suas consequências para o meio ambiente, tal preocupação deve-se ao fato dos impactos que as mesmas geram sobre os diversos setores seja ambiental, social ou mesmo econômico.

Nessa perspectiva [de Mesquita et al. 2022] ressalta a importância das chuvas para os setores produtivos como fonte de alimentos e renda para diversos produtores. Assim é importante salientar que existem diversos tipos de chuvas a saber.

- **Chuvas Orográficas:** tem uma maior duração, assim como um volume menor de precipitação, originando-se quando uma quota de ar provida de certa quantidade de umidade locomove-se simultaneamente ao solo até alcançar uma barreira, como a encosta de uma escarpa ou de uma montanha [Cândido and Nunes 2008];
- **Chuvas Convectivas:** originam-se no verão, pelo fato dessa estação do ano gerar calor e excesso de umidade [Mello and Viola 2013];
- **Chuvas Frontais:** são originárias de frentes frias, ocorrem durante todo o ano, ocasionando chuvas de grande duração com intensidade que varia de baixa a média [Cândido and Nunes 2008].

Como pode ser destacado o processo de predição de chuvas pode trazer inúmeros benefícios, entre eles conforme [Engelbrecht et al. 2021], a possibilidade de antecipar os alertas e melhoramento de sua eficiência resultando em melhoria de prevenção e mitigação dos desastres naturais que ocorrem pelos extremos da chuva.

3.2. Lógica Difusa

De acordo com [Marro et al. 2010] a lógica *fuzzy* foi introduzida em 1930, utilizando-se inicialmente de termos linguísticos, para indicar valores em números *fuzzy*, assim, inicialmente foi proposto a utilização de intervalos de $[0,1]$, isso indicaria a possibilidade de uma declaração ser verdadeira ou falsa mostrando assim um indicativo de pertinência. Em 1965, Lofti Zadeh com a publicação do artigo *Fuzzy Sets* [Zadeh 1965] que ficou conhecido como a origem da lógica *fuzzy*, redescobriu a ideia de fuzzyficação.

Para [Kumru and Kumru 2013] é uma forma lógica de raciocínio derivada da teoria dos conjuntos difusos para lidar com raciocínio aproximado. O sistema *fuzzy* cuida

da relação entre entradas e saídas, associando vários parâmetros de processo e de controle, resultando em um processo mais aperfeiçoado, com desempenho estável e robusto. Sua maneira singela de implementação pode reduzir a complexidade de um projeto [Gomide et al. 1995].

Para [Simões and Shaw 2007], um sistema *fuzzy* é composto dos seguintes blocos funcionais:

- **Fuzzificação:** nesta etapa, os dados de entrada são transformados em variáveis linguísticas e as funções de pertinência são determinadas, podendo ser apresentadas como valores numéricos tabulados.
- **Base de conhecimento:** consiste em um conjunto de regras que define a estratégia de controle e metas, armazenando definições sobre discretizações e normalizações dos universos de discurso.
- **Funções de Pertinência:** utilizadas em sistemas *fuzzy* para definir o grau de pertencimento de um valor a um conjunto *fuzzy*.
- **Regras de Inferência:** utilizando inferência *fuzzy* para simular tomadas de decisões humanas gerando ações conseqüentes a partir de um conjunto de condições de entrada antecedentes.
- **Defuzzificação:** etapa em que os valores *fuzzy* são convertidos em números reais, tendo um conjunto de saída matematicamente definido, sendo o valor da variável linguística de saída inferida interpretada num valor discreto.

Na lógica *fuzzy*, não há limites abruptos para definir o pertencimento a um conjunto, como nos conjuntos alto, médio e baixo. Em vez disso, os graus de pertinência variam suavemente no intervalo $[0,1]$, representando de forma mais realista o conhecimento humano [Marro et al. 2010].

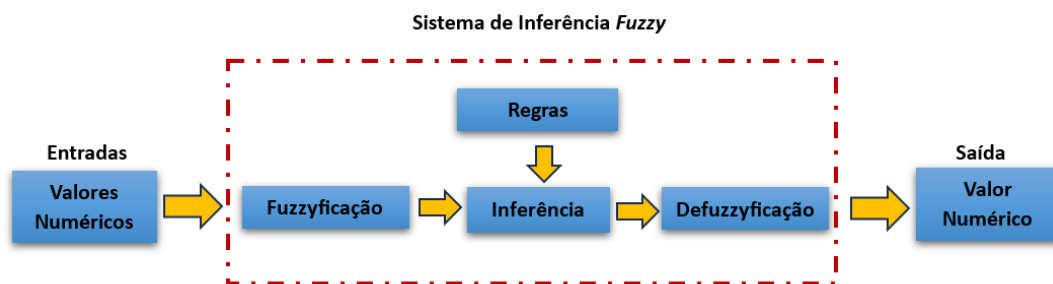


Figura 1. Blocos Funcionais de um Sistema *Fuzzy*

A Figura 1 evidencia a sequência de blocos que permite a interpretação pelo sistema de dados incertos de forma inteligente fornecendo respostas mais flexíveis e aproximadas da lógica humana, modelando assim o modo aproximado do raciocínio humano.

4. Materiais e Métodos

Para o desenvolvimento deste trabalho, foi utilizado um *dataset* disponibilizado pelo Instituto Nacional de Meteorologia (INMET), acessível em <https://tempo.inmet.gov.br/TabelaEstacoes/>. Os testes foram realizados com dados processados por meio da lógica nebulosa, utilizando amostras selecionadas aleatoriamente, correspondentes ao período compreendido entre 01/01/2024 às 00h00 e 06/07/2024 às 19h00, ou seja,

último ano de operação da Estação Meteorológica Automática (EMA) antes da pane. Nesse intervalo, foram coletados 4.421 registros no total. Dessa forma, foi possível avaliar os acertos e erros da ferramenta proposta. A Figura 2 apresenta o modelo representativo do sistema desenvolvido, evidenciando as etapas de entrada, inferência e saída.

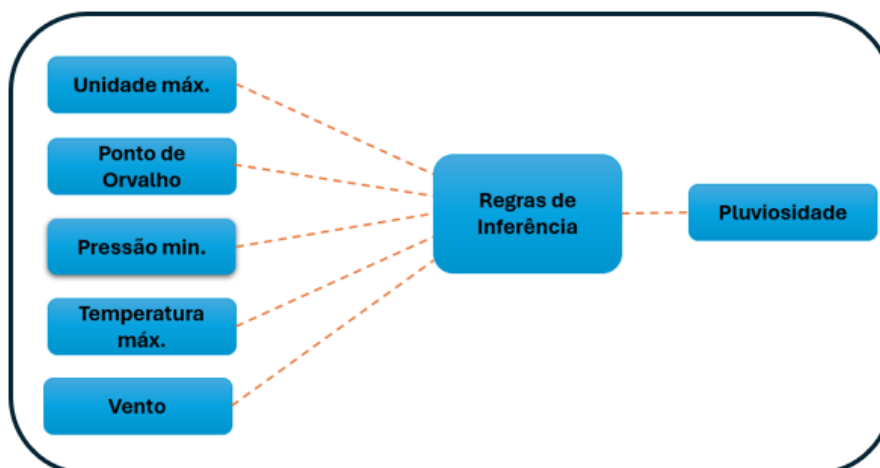


Figura 2. Estrutura Representativa do Sistema *Fuzzy* Desenvolvido

Para a implementação e testes do sistema foi utilizada a linguagem *Python* e amostras coletadas pela EMA. Para a realização dos testes foi empregado o modelo de inferência *fuzzy* MAMDANI propostos por Ebrahim Mamdani em 1975 [Mamdani 1976]. Assim pode-se verificar o correto funcionamento do sistema, onde por meio das regras de inferência pode-se verificar a determinação de operadores para o processamento do antecedente da regra e da função de implicação que iria determinar o seu consequente [Andrade and Jaques 2008].

Salienta-se que todas as variáveis linguísticas utilizadas foram classificadas dentro das seguintes fases (conjuntos *fuzzy*): baixa, média e alta. As variáveis estão classificadas em uma escala entre 0 e 1, onde 0 representa a menor atribuição e 1, a maior, ou seja, quanto mais próximo de 0, maior é o grau de pertinência para falso, e quanto mais próximo de 1, maior é o grau de pertinência para verdadeiro.

No estudo foram consideradas as seguintes escalas para baixa: a faixa de valores numéricos entre 0.1 a 0,39; para média entre 0,40 a 0,69 e para alta entre 0,70 a 1,0. As variáveis linguísticas de entrada utilizadas foram: umidade máxima, ponto de orvalho, pressão mínima, temperatura máxima, velocidade do vento.

Para cada uma das variáveis linguísticas para predição de chuvas, foram definidos conjuntos *fuzzy*, que representam as categorias como “baixa”, “média” e “alta” para essas variáveis. A seguir estão sugestões de como os conjuntos *fuzzy* foram construídos para as variáveis listadas.

As regras *fuzzy* utilizadas no modelo apresentado no Algoritmo 1 foram geradas automaticamente por meio de um algoritmo desenvolvido especificamente para esse fim. Esse algoritmo realizou a combinação sistemática de todas as categorias possíveis das variáveis de entrada, classificadas nos conjuntos *fuzzy* “baixa”, “média” e “alta”. Considerando cinco variáveis de entrada, o algoritmo gerou $m^n = 3^5 = 243$ regras, onde

m representa o número de conjuntos *fuzzy* por variável e n a quantidade de variáveis linguísticas de entrada.

O sistema modelado também utilizou funções de pertinência triangulares para representar os conjuntos *fuzzy*, o que simplifica os cálculos e permite uma transição gradual entre os níveis das variáveis linguísticas. As 243 regras de inferência foram elaboradas de forma a cobrir todas as combinações possíveis entre as variáveis, garantindo a completude do modelo. O Algoritmo 1 exemplifica como essas regras *fuzzy* podem ser implementadas na perspectiva da inferência lógica em sistemas difusos.

Embora as regras reflitam relações coerentes com os fenômenos meteorológicos, como alta umidade e baixa pressão indicando maior probabilidade de chuva, elas foram geradas automaticamente com base em princípios da lógica fuzzy e nos dados históricos disponíveis, sem a formulação direta ou validação por especialistas da área.

Algoritmo 1 - Regras Fuzzy para Probabilidade de Chuva

Algorithm 1: Regras Fuzzy para Probabilidade de Chuva

- 1: **Entrada:** Umidade Máxima, Ponto de Orvalho, Pressão Mínima, Temperatura Máxima, Velocidade do Vento
 - 2: **Saída:** Probabilidade de Chuva
 - 3: **if** Umidade Máxima = Alta **e** Ponto de Orvalho = Alto **e** Pressão Mínima = Baixa **then**
 - 4: Probabilidade de Chuva = Alta
 - 5: **else if** Ponto de Orvalho = Alto **e** (Umidade Máxima = Média **ou** Alta) **e** Pressão Mínima = Baixa **then**
 - 6: Probabilidade de Chuva = Média
 - 7: **else if** Pressão Mínima = Baixa **e** Ponto de Orvalho = Médio **e** Umidade Máxima = Média **then**
 - 8: Probabilidade de Chuva = Média
 - 9: **else if** Temperatura Máxima = Alta **e** (Umidade Máxima = Média **ou** Alta) **then**
 - 10: Formação de Nuvens = Média
 - 11: **else if** Velocidade do Vento = Fraca **e** Pressão Mínima = Baixa **then**
 - 12: Probabilidade de Chuva = Alta
 - 13: **end if**
-

A seguir tem-se definições e demais esclarecimento sobre cada variável linguística utilizada para a modelagem do sistema *Fuzzy* proposto [Ynoue et al. 2017, Nery 2013, Mendonça and Danni-Oliveira 2017].

1. **Umidade Máxima:** indica o nível de saturação do ar com vapor d'água, onde os níveis altos indicam maior potencial de precipitação.
 - **Conjuntos Fuzzy:**
 - Baixa: 0% – 50%
 - Média: 30% – 80%
 - Alta: 60% – 100%
 - **Regras:** quanto maior a umidade máxima, especialmente em combinação com ponto de orvalho alto e pressão baixa, maior a probabilidade de chuva.
2. **Ponto de Orvalho:** é a temperatura na qual o vapor d'água se condensa, onde valores altos indicam ar mais úmido.

- **Conjuntos Fuzzy:**
 - Baixo: 0°C – 10°C
 - Médio: 5°C – 20°C
 - Alto: 15°C – 25°C
 - **Regras:** ponto de orvalho alto em conjunto com umidade elevada e baixa pressão contribui para maior chance de chuva.
3. **Pressão Mínima:** indicador de sistemas meteorológicos, em que pressões mais baixas são geralmente associadas a chuvas.
- **Conjuntos Fuzzy:**
 - Baixa: 950 hPa – 990 hPa
 - Média: 980 hPa – 1020 hPa
 - Alta: 1010 hPa – 1030 hPa
 - **Regras:** pressão baixa combinada com umidade e ponto de orvalho altos levam a maior probabilidade de precipitação.
4. **Temperatura Máxima:** influencia a evaporação e a formação de nuvens.
- **Conjuntos Fuzzy:**
 - Baixa: 10°C – 20°C
 - Média: 18°C – 32°C
 - Alta: 30°C – 40°C
 - **Regras:** temperaturas altas favorecem a convecção e formação de nuvens carregadas, especialmente em dias quentes e úmidos.
5. **Velocidade do Vento:** pode contribuir para o transporte de umidade ou indicar instabilidade atmosférica.
- **Conjuntos Fuzzy:**
 - fraco/baixo: 0 km/h – 15 km/h
 - Moderado/médio: 10 km/h – 40 km/h
 - Forte/alta: 35 km/h – 50 km/h
 - **Regras:** ventos fracos com baixa pressão favorecem chuvas; ventos fortes com alta pressão tendem a dispersar nuvens.

É significativo ressaltar que a variável linguística de saída (pluviosidade) do sistema modelado tem um papel importante, onde o resultado é dado em forma de percentual.

5. Resultados e Discussões

Nesta seção serão discutidos os resultados encontrados a partir da modelagem do sistema, a partir das entradas através as seguintes variáveis linguísticas: $umidade_{máx}$, $ponto_{orvalho}$, $pressão_{min}$, $temperatura_{máx}$, $velocidade_{do\ vento}$.

A Tabela 1 evidencia os resultados realizados com uma amostra de dados extraída do *dataset*. Assim, observa-se um percentual de 84,95% de chance de chuva, o que é confirmado pela base de dados que mostrou um forte indicativo de precipitação pluviométrica. Os valores de entrada para as variáveis linguísticas indicam alta umidade, alto ponto de orvalho, baixa pressão e vento fraco, dados compatíveis com a amostra utilizada.

Nessa Tabela 2 possui valores de entrada que indicam umidade moderada, ponto de orvalho baixo, pressão alta, temperatura alta e vento forte, atingindo 59,80% de chance de chuva, com uma expectativa de média pluviosidade esperada.

Tabela 1. Valores Testados de Acordo com o Dataset (Teste 1)

Variável Linguística	Intervalo de Valores	Unidade	Valores Teste	Chance de Chuva
Umidade Máxima	0 – 100	%	95	84,95%
Ponto de Orvalho	0 – 25	°C	24	
Pressão Mínima	950 – 1030	hPa	955	
Temperatura Máxima	10 – 40	°C	28	
Velocidade do Vento	0 – 50	km/h	5	

Tabela 2. Valores Testados de Acordo com o Dataset (Teste 2)

Variável Linguística	Intervalo de Valores	Unidade	Valores Teste	Chance de Chuva
Umidade Máxima	0 – 100	%	65	59,80%
Ponto de Orvalho	0 – 25	°C	18	
Pressão Mínima	950 – 1030	hPa	1000	
Temperatura Máxima	10 – 40	°C	30	
Velocidade do Vento	0 – 50	km/h	20	

A Tabela 3 evidencia umidade baixa, ponto de orvalho muito baixo, pressão muito alta, temperatura muito alta e vento muito forte, demonstrando 15,56% de chance de chuva refletindo assim uma baixa pluviosidade esperada.

Tabela 3. Valores Testados de Acordo com o Dataset (Teste 3)

Variável Linguística	Intervalo de Valores	Unidade	Valores Teste	Chance de Chuva
Umidade Máxima	0 – 100	%	25	15,56%
Ponto de Orvalho	0 – 25	°C	5	
Pressão Mínima	950 – 1030	hPa	1025	
Temperatura Máxima	10 – 40	°C	37	
Velocidade do Vento	0 – 50	km/h	45	

Tabela 4. Métricas de Avaliação dos Testes

Teste	MAE	MSE	RMSE	Resultado Esperado	Resultado Previsto
Teste 1	5,05	25,48	5,05	90,00	84,95
Teste 2	5,00	25,00	5,00	55,00	50,00
Teste 3	4,44	19,75	4,44	20,00	15,56

A Tabela 4 traz dados relacionados as métricas de avaliação utilizadas no estudo, o modelo apresentou valores de erro relativamente baixos nos três testes, com MAE entre 4,44 e 5,05, o que indica uma boa precisão média das previsões. Os valores de RMSE acompanharam os de MAE, sugerindo pequena variância nos erros, isto é, os erros não estão muito dispersos. Já o MSE, por ser uma média dos erros ao quadrado, reforça que não há erros extremos nos resultados.

Dessa forma percebe-se que o modelo *fuzzy* apresentou bons níveis de acurácia nos três testes, com pequenos erros absolutos e quadráticos. Apesar de todas as previsões

serem subestimadas, a consistência dos erros com $RMSE \approx MAE$ sugere que o modelo é estável e confiável, tendo um destaque para o Teste 3 com maior precisão, mesmo com um valor de referência mais baixo.

Observa-se nos testes realizados que o modelo apresentou um viés com subestimação em média de 5 pontos percentuais abaixo do esperado, podendo estar relacionado aos limites das funções de pertinência e à geração automática das regras, sem ajustes baseados em conhecimento especializado. A revisão desses parâmetros, bem como a adoção de funções de pertinência mais precisas e regras ponderadas, poderia melhorar a aderência do modelo aos dados reais. Além disso, a adoção de modelos híbridos é uma alternativa viável para reduzir esse viés.

6. Considerações Finais e Trabalhos Futuros

O modelo de previsão apresentou bons resultados, com erros moderados. Em geral, os erros estão dentro de uma faixa razoável, mas o modelo pode ser aprimorado para lidar melhor com variações extremas nas variáveis meteorológicas e melhorar a precisão em cenários mais complexos.

No Teste 1, o valor esperado foi 90% conforme o *dataset* e o valor previsto foi 84,95%, com um erro de 5,05%, o que é aceitável. No Teste 2, o valor esperado foi 55% e o previsto foi 50%, com um erro de 5%, mantendo a precisão. No Teste 3, o valor esperado foi 20% e o previsto foi 15,56%, com o menor erro de 4,44%, sugerindo maior precisão quando as variáveis estão mais controladas.

As amostras utilizadas do *dataset* ofereceram medições precisas e a discrepância entre os valores pode ser atribuída a fatores como a complexidade dos fenômenos meteorológicos, imprecisões nas medições da Estação Meteorológica Automática (EMA) e limitações do modelo em capturar padrões complexos e não-lineares.

Para trabalhos futuros, sugere-se aprimorar do modelo proposto por meio da incorporação de outras variáveis linguísticas e de abordagens híbridas, como os sistemas neuro-*fuzzy*, que combinam a capacidade adaptativa das redes neurais com a interpretabilidade dos sistemas *fuzzy*. Assim como a incorporação de outras métrica de avaliação como revocação, *Area Under the Curve* (AUC), coeficiente de determinação (R^2), coeficiente de correlação de *Pearson*, visando aumentar a acurácia, reduzir o viés observado e ampliar a capacidade de generalização do modelo.

Referências

- Andrade, M. and Jaques, M. A. P. (2008). Estudo comparativo de controladores de mamdani e sugeno para controle de tráfego em interseções isoladas. *Transportes*, 16(2).
- Cândido, D. H. and Nunes, L. H. (2008). Influência da orografia na precipitação da área entre o vale do rio tietê e a serra da mantiqueira. *GEOUSP Espaço e Tempo (Online)*, 12(1):08–27.
- de Almeida Sá, Y. V. (2019). Estudo prático para um sistema de previsão autônoma de chuva de curto período (um dia) baseado em lógica fuzzy.
- de Lima, P. M. and Guedes, E. B. (2015). Uma abordagem baseada em redes neurais para a predição de chuva em manaus, amazonas. In *Latin America Congress on Computational Intelligence (LA-CCI)*.

- de Mesquita, I. M., Carneiro, F. T., Alves, S. F., Albuquerque, L. T., and Aragão, F. A. P. (2022). Análise de algoritmos de aprendizagem de máquina para previsão de precipitações para utilização na agricultura familiar. In *Escola Regional de Computação do Ceará, Maranhão e Piauí (ERCEMAPI)*, pages 179–187. SBC.
- Engelbrecht, A., Jatobá, A., da Silva, A. J. D., Gomes, J. O., Dolif, G., Nobre, C. A., and de Carvalho, P. V. R. (2021). A análise do trabalho dos meteorologistas na previsão de chuvas intensas no rio de janeiro. *Revista Ação Ergonômica*, 6(2):11–17.
- Ferrari, A. L. (2012). *Variabilidade e tendência da temperatura e pluviosidade nos municípios de Pirassununga, Rio Claro, São Carlos e São Simão (SP): estudo sobre mudança climática de curto prazo em escala local*. Tese de doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. Acesso em: 2025-03-30.
- Gomide, F., Gudwin, R. R., and Tanscheit, R. (1995). Conceitos fundamentais da teoria de conjuntos fuzzy, lógica fuzzy e aplicações. In *Proc. 6 th IFSA Congress-Tutorials*, volume 59, pages 1–38.
- Kumru, M. and Kumru, P. Y. (2013). Fuzzy fmea application to improve purchasing process in a public hospital. *Applied soft computing*, 13(1):721–733.
- Luiz, T. B. P. and Schroder, T. (2020). Modelos chuva-vazão: Uso de técnicas de aprendizagem de máquinas para calibração de modelos em uma pequena bacia hidrográfica. *Geoambiente On-line*, (37):304–321.
- Mamdani, E. H. (1976). Advances in the linguistic synthesis of fuzzy controllers. *International Journal of Man-Machine Studies*, 8(6):669–678.
- Marro, A. A., Souza, A. d. C., Cavalcante, E. d. S., Bezerra, G. S., and Nunes, R. O. (2010). Lógica fuzzy: conceitos e aplicações. *Natal: Universidade Federal do Rio Grande do Norte (UFRN)*, 2.
- Mello, C. R. d. and Viola, M. R. (2013). Mapeamento de chuvas intensas no estado de minas gerais. *Revista Brasileira de Ciência do Solo*, 37:37–44.
- Mendonça, F. and Danni-Oliveira, I. M. (2017). *Climatologia: noções básicas e climas do Brasil*. Oficina de textos.
- Nery, J. T. (2013). *Glossário de termos técnicos em Meteorologia e Climatologia*. Paco Editorial.
- Oliveira, A., Oliveira, A., and Brito, R. (2021). Séries temporais e técnicas de regressão: Uma análise comparativa a partir de dados de precipitações pluviométricas coletados por estação meteorológica automática. In *Anais do XIV Encontro Unificado de Computação do Piauí e XI Simpósio de Sistemas de Informação*, pages 97–104, Porto Alegre, RS, Brasil. SBC.
- Simões, M. G. and Shaw, I. S. (2007). *Controle e modelagem fuzzy*. Editora Blucher.
- Ynoue, R. Y., Reboita, M. S., Ambrizzi, T., and da Silva, G. A. (2017). *Meteorologia: noções básicas*. Oficina de Textos.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and control*, 8(3):338–353.