

Sistema Inteligente Residencial com IA e IoT para Apoio à Tomada de Decisão Baseada em Alertas Meteorológicos Contextuais

Gabriel da Silva Oliveira Coelho¹, Evelin Helena Cardoso Gomes¹

¹Faculdade de Computação – Universidade Federal do Pará (UFPA)

Abstract. *This study proposes an intelligent residential system based on the Internet of Things (IoT) and Artificial Intelligence, aimed at anticipating local precipitation events. Unlike regional weather forecasts and models focused solely on global accuracy metrics, the proposed approach prioritizes the decision-making utility of alerts in residential environments. The system integrates low-cost environmental sensors, temporal processing using recurrent neural networks, and event-oriented analysis, comparing a Baseline model (MR), a Very Short-Term Prediction model (MCP), and an Event-Based model (MBE). Results indicate that, although the MR exhibits superior overall statistical performance, the MBE achieved greater anticipation capability and higher sensitivity to atmospheric patterns preceding rainfall, correctly alerting 3 out of 5 observed precipitation events, while the MR and MCP generated only 1 and no useful alerts, respectively. These findings suggest that temporal and contextual approaches are more suitable for residential alert applications than models focused exclusively on numerical precision.*

Keywords: Weather forecasting; Alert systems; Internet of Things; Artificial Intelligence; Time series.

Resumo. *Este trabalho propõe um sistema residencial inteligente baseado em Internet das Coisas (IoT) e Inteligência Artificial voltado à antecipação de eventos de precipitação em escala local. Diferentemente de previsões meteorológicas regionais e de modelos orientados exclusivamente a métricas globais de acurácia, a abordagem proposta prioriza a utilidade decisória do alerta em ambientes residenciais. O sistema integra sensores ambientais de baixo custo, processamento temporal por meio de redes neurais recorrentes e análise orientada a eventos, comparando um modelo de referência (MR), um modelo de previsão de curtíssimo prazo (MCP) e um modelo baseado em eventos (MBE). Os resultados indicam que, embora MBE apresente um desempenho estatístico global inferior, ele demonstrou maior capacidade de antecipação e maior sensibilidade a padrões atmosféricos antecedentes à ocorrência de chuva, alertando corretamente 3 dos 5 eventos de precipitação, enquanto MR e MCP geraram, 1 e nenhum alertas uteis, respectivamente, o que indica que abordagens temporais e contextuais se mostram mais adequadas para aplicações residenciais de alerta do que modelos focados exclusivamente em precisão numérica.*

Palavras-chave: Previsão meteorológica; Sistemas de alerta; Internet das Coisas; Inteligência Artificial; Séries temporais.

1. Introdução

A previsão meteorológica tem evoluído significativamente com o uso de modelos numéricos e técnicas de Inteligência Artificial (IA), especialmente no contexto de instituições nacionais e estudos climáticos de larga escala (MUCAVELE; MANHIÇA, 2025; MARQUES; DEREZYNSKI, 2021). Contudo, em ambientes residenciais, essas previsões apresentam limitações práticas, pois são baseadas majoritariamente em dados de estações oficiais que representam médias regionais e não capturam adequadamente a volatilidade do microclima local. Como resultado, previsões genéricas frequentemente não oferecem o suporte necessário para decisões cotidianas imediatas, como fechar janelas ou proteger bens domésticos, problema já apontado em estudos sobre a usabilidade da informação meteorológica (SIVLE; KOLSTØ, 2016).

Além disso, grande parte das abordagens baseadas em IA concentra-se na maximização de métricas globais de desempenho, tratando a ocorrência de chuva como um problema de classificação determinística ou regressão numérica. Trabalhos que utilizam redes neurais aplicadas a séries temporais meteorológicas demonstram bons resultados estatísticos, mas permanecem fortemente orientados à previsão pontual, sem foco explícito na utilidade decisória do alerta (SOARES, 2022). Essa perspectiva desconsidera a natureza temporal e processual dos fenômenos atmosféricos, bem como o fato de que, em contextos residenciais, a antecipação de tendências é frequentemente mais relevante do que a precisão numérica absoluta.

Diante desse cenário, observa-se a necessidade de desenvolver sistemas voltados ao apoio à tomada de decisão humana em ambientes residenciais, integrando dados de IoT local, análise contextual e modelagem orientada a eventos. Embora existam iniciativas que relacionem a previsão do tempo à gestão de riscos e às falhas na comunicação com a sociedade, como demonstrado em estudos sobre telejornalismo meteorológico e sistemas de alerta centrados nas pessoas (HOFACKER, 2023; MARCHEZINI et al., 2017), poucos trabalhos exploram sensores residenciais de baixo custo como fonte primária de informação ou priorizam mecanismos de alerta direto orientados ao comportamento temporal das variáveis ambientais.

Este trabalho propõe um sistema residencial inteligente baseado em IoT e IA, concebido como um mecanismo de alerta contextual e não como um previsor meteorológico determinístico, ou seja, um sistema que não busca apenas prever um número exato, mas que analisa o comportamento do clima no local da residência para gerar avisos que façam sentido para as decisões do morador. Isto é, o sistema integra coleta local de dados ambientais, processamento inteligente por meio de redes neurais recorrentes e visualização em tempo quase real, com foco na antecipação de eventos de chuva e no suporte à decisão humana, alinhando-se a abordagens que defendem o uso da informação como instrumento de apoio ao processo decisório, e não apenas como previsão numérica (OLIVEIRA, 2025).

O objetivo geral deste trabalho é desenvolver e avaliar uma arquitetura de IoT residencial capaz de identificar padrões atmosféricos que precedem eventos de precipitação, considerando o microclima local e a evolução temporal das variáveis ambientais. Como objetivos específicos, destacam-se: o desenvolvimento do protótipo de *hardware*; a integração de dados locais e históricos; a avaliação de diferentes estratégias de modelagem; e a análise do desempenho dos modelos sob a perspectiva de alerta, com ênfase na previsibilidade de curto prazo e na dinâmica temporal dos fenômenos atmosféricos locais.

Sendo assim, parte-se da hipótese de que abordagens baseadas em variações temporais e em modelagem orientada a eventos são potencialmente mais adequadas para aplicações residenciais de apoio à decisão do que modelos tradicionais focados exclusivamente em métricas globais de acurácia. Para investigar essa premissa, o trabalho adota uma progressão metodológica que se inicia com o desenvolvimento de um protótipo IoT para coleta de dados meteorológicos locais, seguindo com o treinamento e a comparação de diferentes estratégias de Inteligência Artificial finalizando na avaliação prática de sua capacidade de antecipação de eventos de chuva e emissão de alertas válidos. A análise prioriza a sensibilidade dos modelos a padrões atmosféricos relevantes e seu impacto na utilidade da informação para o usuário, deslocando o foco da precisão numérica isolada para o suporte efetivo à tomada de decisão.

2. Referencial Teórico

2.1. Internet das Coisas e Monitoramento Ambiental Inteligente

Os avanços tecnológicos recentes posicionaram a conectividade digital como um dos principais motores de transformação na sociedade contemporânea. Segundo Magrani (2018), as tecnologias digitais afetam profundamente as estruturas econômicas e sociais, alterando relações de trabalho e comunicação ao promover a integração entre o mundo físico e o digital. Nesse contexto, o conceito de Internet das Coisas (IoT) emerge não apenas como uma rede de objetos conectados, mas como um ecossistema capaz de otimizar processos e promover sustentabilidade e qualidade de vida.

Conforme definem Godoi e Araújo (2019), a IoT refere-se à interconexão de dispositivos físicos que comunicam e compartilham dados pela internet, permitindo o monitoramento remoto e o controle automático de sistemas. Essa capacidade de coleta de dados em tempo real é fundamental para a gestão inteligente de recursos, possibilitando que dispositivos antecipem necessidades e respondam de forma proativa a situações emergentes, sem a necessidade de intervenção humana constante.

No entanto, o desenvolvimento de soluções eficazes em IoT exige a convergência de conhecimentos multidisciplinares, unindo engenharia eletrônica, protocolos de comunicação e ciência de dados (MAGRANI, 2018). Na aplicação específica de monitoramento ambiental, essa convergência se materializa, por exemplo, por meio do uso de microcontroladores de baixo custo e alto desempenho, como o ESP32. Estudos como o de (SILVA, 2021) validam a arquitetura baseada em ESP32 para a construção de estações meteorológicas autônomas, demonstrando que o *hardware* acessível é capaz de realizar a coleta de variáveis climáticas com confiabilidade suficiente para fins acadêmicos e de alerta local.

Avançando nessa perspectiva, (TRAN et al., 2023) destacam que a aplicação de IoT em ambientes meteorológicos permite a captura de dados de microclima e variações locais de temperatura e umidade que grandes estações oficiais não conseguem registrar devido à distância geográfica. Assim, a IoT residencial deixa de ser apenas uma ferramenta de coleta passiva para se tornar um sistema ativo de suporte à decisão, fornecendo a granularidade de dados necessária para alimentar modelos preditivos locais.

2.2. Inteligência Artificial e Modelagem de Séries Temporais Meteorológicas

A Inteligência Artificial (IA), inicialmente explorada nas décadas de 1950 e 1960, tem passado por um profundo processo de evolução ao longo dos anos, consolidando-se como uma ferramenta indispensável para a automação de tarefas que exigem raciocínio avançado. Segundo Russell e Norvig (2020), a IA é fundamental no desenvolvimento de agentes inteligentes que não apenas processam dados, mas aprendem com eles e se adaptam continuamente às mudanças do ambiente, ampliando sua capacidade de lidar com situações de incerteza.

Nesse sentido, (FETZER, 2007) afirma que a aplicabilidade da IA transcende a simples automação de processos repetitivos, permitindo uma gestão mais eficiente e fundamentada de atividades complexas. No contexto meteorológico, essa capacidade é crítica, uma vez que os fenômenos atmosféricos são caracterizados por um comportamento caótico e não-linear (SAVI, 2006). (RAMOS, 2025) argumenta que métodos estatísticos tradicionais, como o ARIMA, muitas vezes falham em capturar oscilações abruptas ou anomalias climáticas, enquanto algoritmos de Aprendizado de Máquina (*Machine Learning*) demonstram superioridade ao identificar padrões ocultos em grandes volumes de dados históricos.

Dentre as arquiteturas de Aprendizado de Máquina, as Redes Neurais Recorrentes (RNN) se destacam pela habilidade de processar sequências de dados, onde a ordem temporal é relevante. Uma RNN processa informações baseada no tempo, armazenando dados de etapas anteriores. No entanto, conforme apontam Tanvir e Naiema (2025), essas redes apresentam limitações críticas ao lidar com dependências de longo prazo, sofrendo com o problema do 'gradiente desaparecendo' (*vanishing gradient*), isto é, durante o processo de aprendizado, a informação usada para ajustar o modelo enfraquece progressivamente à medida que retrocede no tempo, fazendo com que a rede "esqueça" ou não consiga aprender com os dados mais antigos da sequência. No contexto meteorológico, isso pode impedir com que o modelo correlacione os eventos climáticos passados distantes com a precipitação atual.

Para superar essa deficiência estrutural, a rede *Long Short-Term Memory* (LSTM) foi projetada com uma arquitetura interna mais complexa. Segundo Tanvir e Naiema (2025), a LSTM substitui o nó simples da RNN por um bloco de memória composto por células de memória e três tipos de portões (esquecimento, entrada e saída). Essa estrutura permite que o sistema regule o fluxo de informação, decidindo quais dados meteorológicos (como temperatura e pressão de horas anteriores) devem ser retidos ou descartados, modelando com eficácia a associação temporal necessária para a previsão de chuvas.

Portanto, a aplicação de redes neurais LSTM em dados provenientes de sensores IoT não visa apenas replicar a precisão numérica de modelos globais, mas sim capturar a dinâmica temporal do microclima. Essa abordagem permite que o sistema identifique a "assinatura" de padrões atmosféricos locais que precedem eventos de interesse, transformando dados brutos em inteligência preditiva capaz de suportar decisões em tempo hábil.

2.3. Comunicação de Risco e Apoio à Tomada de Decisão

A eficácia de um sistema de monitoramento ambiental não reside apenas na precisão técnica de seus sensores ou algoritmos, mas principalmente na sua capacidade de comunicar

o risco de forma compreensível e acionável para o usuário final. (MARCHEZINI et al., 2017) criticam a abordagem tradicional de sistemas de alerta “*top-down*” (baseados em hierarquias de decisão), argumentando que estes frequentemente falham em atingir as comunidades locais com a tempestividade necessária. Segundo os autores, sistemas eficazes devem ser “centrados nas pessoas”, integrando o conhecimento local e permitindo que a população não seja apenas receptora passiva, mas participante ativa do monitoramento.

No cenário da comunicação de massa, (HOFACKER, 2023) aponta que a previsão do tempo veiculada nos telejornais brasileiros muitas vezes prioriza o entretenimento ou a informação genérica em detrimento da comunicação efetiva do risco. Essa abordagem cria uma lacuna entre a informação disponível (dados macroclimáticos) e a necessidade do cidadão comum, que precisa tomar decisões imediatas em seu cotidiano, como proteger bens domésticos ou garantir a segurança da residência.

Essa necessidade de tradução de dados técnicos para uma linguagem de decisão é corroborada por (SIVLE; KOLSTØ, 2016). Em seus estudos sobre o uso de informações meteorológicas por leigos, os autores identificaram que o excesso de complexidade técnica pode dificultar a tomada de decisão cotidiana. Para o usuário final, saber a pressão atmosférica exata em hectopascals é menos relevante do que receber um indicativo claro de que as condições estão se deteriorando rapidamente. Portanto, a usabilidade da informação depende de sua contextualização: transformar o dado bruto em um alerta de “mudança de estado”.

Nesse sentido, a proposta deste trabalho alinha-se ao conceito de produção de conhecimento para a decisão, discutido por (OLIVEIRA, 2025). A inteligência, nesse contexto, não é apenas o algoritmo computacional, mas o produto final que reduz a incerteza do decisor. Ao integrar a coleta local (IoT) com o processamento preditivo (IA), o sistema proposto busca propor um sistema de comunicação identificada na literatura, fornecendo alertas locais que servem como suporte direto à tomada de decisão humana frente à volatilidade climática.

3. Metodologia

A presente pesquisa caracteriza-se como uma abordagem quantitativa e experimental (MARCONI; LAKATOS, 2004). O trabalho foi desenvolvido em três etapas principais, integradas de forma contínua: inicialmente, o desenvolvimento do protótipo de hardware para coleta de dados; em seguida, o pré-processamento e a organização dos *datasets* históricos e locais; e, por fim, a construção de uma arquitetura de Inteligência Artificial baseada em aprendizado profundo (*Deep Learning*) para a identificação de padrões sequenciais.

3.1. Arquitetura do sistema IoT

O sistema de *hardware* desenvolvido (Figura 1) é baseado no microcontrolador ESP32-S3, amplamente empregado em projetos de Internet das Coisas (IoT), o qual integra conectividade sem fio Wi-Fi e Bluetooth, dispensando o uso de módulos externos.

Além disso, o diagrama de montagem simplificado pode ser visto na Figura 2, contendo diversos sensores, bem como sua disposição, conectividade e valores de referência utilizados.




Figura 1. Sistema de Hardware para captação de dados

Fonte: Elaborado pelo autor.




Figura 2. Diagrama do Hardware para captação de dados

Fonte: Elaborado pelo autor.

Para a coleta das variáveis ambientais, foram utilizados sensores adicionais conectados ao microcontrolador. Esses sensores foram selecionados de modo a fornecer informações essenciais ao processo de predição, conforme resumido na Tabela 1.

Já em relação à alimentação, o sistema é energizado por um conjunto de seis pilhas alcalinas, totalizando aproximadamente 9 V. Para adequar essa tensão aos níveis operacionais do microcontrolador e minimizar perdas energéticas, foi utilizado um conversor de tensão do tipo *step-down* (*buck*), modelo MP1584, configurado para fornecer 3,33 V estáveis. Essa abordagem tem como objetivo evitar as perdas associadas à regulação linear interna do ESP32 presentes nos pinos VIN e USB, além de garantir maior eficiência energética ao longo do funcionamento do sistema (Tabela 2).


Componente	Identificação	Função no sistema
	BME280	Medição de temperatura, umidade do ar e pressão atmosférica
	APDS-9930	Medição da luminosidade do ambiente
	YL-83 + LM393	Deteção da presença de chuva por contato com água

Tabela 1. Lista de Sensores

Fonte: Elaborado pelo autor

Componente	Identificação	Função no sistema
	MP1584 (Buck)	Redução e estabilização da tensão de entrada para 3,33 V
	Conjunto de pilhas	Fornecimento de energia ao sistema

Tabela 2. Componentes de alimentação

Fonte: Elaborado pelo autor

No sistema, os sensores BME280 e APDS-9930 estão conectados ao barramento I2C (*Inter-Integrated Circuit*) do microcontrolador, enquanto o sensor YL-83 é ligado a uma porta GPIO (*General Purpose Input/Output*) pertencente ao domínio RTC (*Real-Time Clock*), possibilitando sua leitura pelo coprocessador ULP (*Ultra Low Power Coprocessor*) durante períodos de baixo consumo. Ademais, a estabilização da tensão fornecida pelo conversor *buck* foi realizada com o uso de capacitores de filtragem na entrada e na saída do circuito, conforme ilustrado no diagrama de montagem apresentado na Figura 2.

Em termos de autonomia, cálculos baseados no ciclo de operação (1 minuto ativo para médias locais a cada 10 minutos) projetam uma duração teórica superior a uma semana devido à capacidade de 2000 mAh e consumo diário médio de 180mAh. No entanto, testes preliminares em campo revelaram que a resistência interna das pilhas alcalinas tende a provocar instabilidades após o quarto dia de uso contínuo, provavelmente devido aos picos de corrente da utilização do Wi-Fi. Dessa forma, para o novo período de testes, foi realizado a troca preventiva da fonte de energia ao terceiro dia logo após o ultimo envio observado pela manhã, a fim de não comprometer de modo muito acentuado a série temporal e garantindo que não existissem perdas na sequência dos dados. Além disso, o custo dos componentes do protótipo está destacado na Tabela 3.




Figura 3. Diagrama de Funcionamento do Sistema de Hardware

Fonte: Elaborado pelo autor.

Componente	Valor (R\$)
ESP32	45,23
BME280	17,12
APDS9930	13,44
YL83 + LM393	15,31
Protoboard	11,33
Cabos e capacitores	1,23
Total	103,66

Tabela 3. Custos dos Componentes do Sistema IoT

Fonte: Elaborado pelo autor

3.2. Coleta e Aquisição de Dados

Os dados utilizados neste trabalho foram obtidos a partir de duas fontes distintas. A primeira corresponde aos dados meteorológicos oficiais disponibilizados pelo Instituto Nacional de Meteorologia (INMET) (METEOROLOGIA, 2025), abrangendo o período de 2015 a 2025, com resolução temporal horária (a cada 1 hora). Esse conjunto inclui variáveis meteorológicas básicas, como temperatura, umidade relativa do ar e pressão atmosférica, sendo utilizados como base histórica para o treinamento do modelo de IA.

A segunda fonte de dados consiste do sistema próprio de aquisição baseado em

microcontrolador ESP32 ilustrado na Figura 1, responsável pela coleta de informações ambientais em tempo quase real. As leituras são realizadas a cada 10 minutos por sensores instalados em ambiente residencial, refletindo condições microclimáticas locais distintas daquelas registradas pelas estações oficiais.

A coleta local foi realizada na cidade de Castanhal-PA, durante um período de uma semana (05/11/2025 até 12/11/2025). Os dados obtidos pelo ESP32 são transmitidos via protocolo HTTP para uma Interface de Programação de Aplicações (API, *Application Programming Interface*) desenvolvida em Python com o *framework* FastAPI e armazenados no sistema de gerenciamento de banco de dados SQLite, para posterior pré-processamento, análise e utilização no modelo de inteligência artificial (Figura 4). As leituras e previsões do sistema foram posteriormente organizadas em uma interface *web* desenvolvida com o *framework* Streamlit (Figura 5).





Figura 4. Dashboard histórico Predição

Fonte: Elaborado pelo autor.

Cabe destacar que as duas fontes de dados apresentam diferenças naturais relacionadas à localização geográfica, altitude, cobertura vegetal e qualidade dos sensores. Essas diferenças foram consideradas nas etapas subsequentes de processamento e modelagem, a fim de reduzir impactos decorrentes da comparação direta entre medições absolutas.



Historico de predições

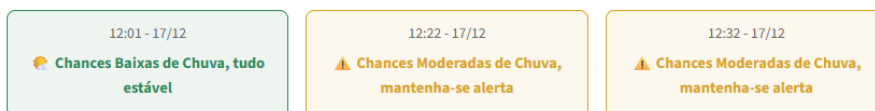


Figura 5. Dashboard histórico Predição

Fonte: Elaborado pelo autor.

3.3. Processamento dos dados e estratégia de modelagem

Antes do treinamento do modelo, os dados passaram por uma etapa de organização e preparação, com o objetivo de reduzir inconsistências e tornar o aprendizado mais coerente com o comportamento real das variáveis meteorológicas.

Como os dados do INMET possuem resolução horária, isto é, a cada 1 hora, e os dados coletados pelo sensor local são obtidos a cada 10 minutos, optou-se por manter os dados históricos em sua forma original e adaptar os dados locais a essa escala. Para isso, foi utilizada uma janela deslizante no formato FIFO (*First-In-First-Out*), considerando as seis leituras mais recentes do sensor (equivalentes a uma hora de dados), a partir das quais foi calculada a média dos valores. Com essa abordagem, buscou-se a comparação entre as duas fontes sem a criação artificial de informações intermediárias.

Para reduzir a influência de diferenças entre os valores medidos pelas duas fontes, o modelo passou a trabalhar com deltas, isto é, com a variação das variáveis meteoro-

lógicas entre uma leitura e a seguinte, em vez de utilizar apenas os valores absolutos na tomada de decisão do modelo. Sendo assim, o foco da análise foi deslocado para o comportamento das mudanças ao longo do tempo, e não somente para níveis isolados de temperatura, umidade ou pressão.

A modelagem foi realizada com redes neurais recorrentes do tipo LSTM, escolhidas por sua capacidade de lidar com dependências temporais em séries históricas (TANVIR; NAIEMA, 2025). O modelo estima a chance de chuva em uma escala que vai de 0 a 1 (ou 0% a 100%). No entanto, para que o sistema decida o momento exato de enviar um alerta ao usuário, é necessário definir um ponto de corte, chamado de limiar.

Para encontrar o valor ideal desse corte, o sistema realizou uma simulação com os dados do passado. O computador testou 20 "régua" diferentes, começando com uma sensibilidade muito alta (0,1) e indo até uma sensibilidade muito rigorosa (0,9). Para cada um desses 20 valores, o algoritmo verificou como o modelo se sairia: se o corte fosse baixo demais, o sistema daria muitos alarmes falsos e se fosse alto demais, ele esqueceria de avisar chuvas reais.

Ao final desse teste, o sistema selecionou para cada modelo o ponto de corte que apresentou o melhor equilíbrio (F1-Score), garantindo que o alerta seja disparado apenas quando há uma assinatura atmosférica clara de chuva (Tabela 4). Esse ajuste permite que o sistema funcione como um mecanismo de suporte à decisão, evitando o incômodo de notificações desnecessárias sem perder a capacidade de aviso.

Modelo	Limiar Selecionado
Referência (MR)	0,8347
Curtíssimo Prazo (MCP)	0,8673
Baseado em Eventos (MBE)	0,8501

Tabela 4. Limiares de Decisão Selecionados por Modelo
Fonte: Elaborado pelo autor

Além disso, o presente trabalho avaliou três abordagens de predição baseadas em Redes Neurais Recorrentes (RNN) do tipo *Long Short-Term Memory* (LSTM) implementadas com a biblioteca PyTorch (Tabela 5). Os modelos foram chamados de: Modelo de Referência (MR), Modelo de Previsão de Curtíssimo Prazo (MCP) e Modelo Baseado em Eventos (MBE). Todos utilizam o otimizador Adam com taxa de aprendizado de 0,001 e uma função de perda *Binary Cross Entropy with Logits* (BCE), com peso da classe de chuva ajustado conforme a proporção entre registros com e sem precipitação no conjunto de treinamento.

Além disso, com o objetivo de comparar estratégias de previsão e analisar a evolução da detecção e alerta de eventos de chuva, todos os modelos foram treinados com dados históricos do INMET, variando a abordagem de separação entre os conjuntos de treinamento e teste. Já na etapa de inferência, todos os modelos utilizaram o mesmo conjunto de dados, coletado localmente via ESP32 durante o período de uma semana.

O modelo MR foi adotado como modelo de referência do estudo por se tratar de uma abordagem preditiva simples e amplamente utilizada na literatura por ser eficiente na previsão de chuvas (TANVIR; NAIEMA, 2025). Sendo assim, MR Trata-se de um

Característica	Modelo de Referência (MR)	Modelo Curtíssimo Prazo (MCP)	Modelo Baseado em Eventos (MBE)
Objetivo	Estabelecer uma linha base de desempenho com dados brutos.	Prever a ocorrência de chuva em horizonte de curtíssimo prazo (10 min).	Detectar padrões pré-evento associados à ocorrência de chuva.
Arquitetura	LSTM (64 neurônios, 2 camadas) + camada densa		
Janela de Entrada	12 leituras (2 h, 10 min)	12 leituras (2 h, 10 min)	3 leituras horárias (3 horas)
Horizonte	6 leituras (1 h à frente)	1 leitura (10 min à frente)	1 leitura (1 h à frente)
Variáveis	Temp., Umid., Pressão, Hora (Seno/Cos)	Deltas (Temp, Umid, Pressão), Ponto de orvalho, Hora	Deltas (Temp, Umid, Pressão), Hora, Mês
Estratégia	Divisão Temporal 80/20	Ajuste dinâmico de pesos de classe	Amostragem balanceada e separação por anos

Tabela 5. Especificações Técnicas e Hiperparâmetros dos Modelos

Fonte: Elaborado pelo autor

classificador probabilístico baseado em regressão logística, no qual a probabilidade de ocorrência de chuva é estimada a partir de uma combinação ponderada das variáveis meteorológicas de entrada (temperatura do ar, umidade relativa e pressão atmosférica). Além disso, devido a natureza das séries temporais, adotou-se uma segmentação cronológica, na qual os registros mais antigos foram utilizados para treinamento do modelo e os mais recentes para avaliação, com objetivo de evitar vazamento de informação futura.

Além das variáveis meteorológicas principais, o modelo MR utiliza transformações circulares do tempo utilizando funções seno e cosseno aplicadas à hora do dia e ao mês do ano. O objetivo dessa abordagem é permitir que o modelo capture padrões diurnos e sazonais de forma contínua e que eventos próximos temporalmente, como ocorrências de chuva às 23h e 0h, sejam tratados como temporalmente próximos, evitando potenciais distorções que surgiriam se a hora fosse representada de forma linear.

Já o modelo MCP foi desenvolvido com o objetivo de capturar alterações imediatas nas condições meteorológicas e antecipar a ocorrência de chuva em curto prazo (10 minutos). Para isso, além das variáveis meteorológicas utilizadas no MR e das transformações cíclicas de hora e mês via funções seno e cosseno, o MCP incorpora as variações (*deltas*) dessas grandezas, ou seja, as diferenças entre as leituras consecutivas. Nesse contexto, essa abordagem tem como objetivo permitir que o modelo analise não apenas os valores absolutos, mas também a direção e a intensidade das mudanças recentes para uma visão mais dinâmica do comportamento do clima e buscando padrões mais sutis que antecedem a chuva, como elevação rápida da umidade ou queda abrupta da pressão.

Além disso, outra variável incorporada ao modelo foi o ponto de orvalho, que indica a temperatura na qual o ar atinge saturação e a umidade começa a se condensar, formando gotas de água. Essa medida é importante porque permite ao modelo identificar condições propícias à formação de chuva, mesmo quando a temperatura e a umidade

absolutos isoladamente não sugerem precipitação. Por exemplo, se em uma tarde a temperatura está em 25 °C e a umidade relativa em 70%, o ponto de orvalho indica se o ar já está próximo de condensação e mudanças pequenas nessa relação podem sinalizar a iminência de chuva, algo que os valores absolutos isolados provavelmente não captariam com a mesma precisão.

Por fim, o modelo MBE foi configurado visando detectar padrões que antecedem a ocorrência de chuva e orientada aos eventos de precipitação. Diferentemente dos modelos anteriores, que processavam sequências contínuas de dados, o MBE adota um paradigma de treinamento diferente, separando explicitamente as ocorrências de chuva das longas sequências de tempo seco ou limpo presentes na base de dados, na tentativa de evitar com que o modelo seja influenciado por dezenas de milhares de registros sem precipitação devido ao forte desbalanceamento das classes, concentrando o aprendizado nas situações realmente relevantes para alerta de chuva.

Para isso, o MBE utiliza as mesmas variáveis do MCP, mas as organiza em sequências que precedem eventos de chuva, onde cada janela de treino contém informações que refletem o comportamento do clima 3 horas antes de uma precipitação para que o modelo não seja inundado por longos períodos de clima limpo.

Vale ressaltar, que o treinamento não seguiu a distribuição 80/20 padrões utilizado nos outros modelos, mas os intervalos foram definidos diretamente, isto é, os dados de 2015 até 2023 foram processados por meio dos eventos de chuvas e usados para treinamento, enquanto os dados de 2024 e 2025 foram utilizados em sua totalidade (sem separar por eventos) para testes. Ademais, o MBE tem como objetivo funcionar como um sistema de alerta mais sensível pois tem seu treinamento direcionado exatamente aos modelos que precisa alertar.

Os treinamentos foram realizados em um computador com processador AMD Ryzen 5 5600X, 32 GB de memória RAM e placa de vídeo NVIDIA RTX 3050 com 8 GB de memória dedicada. O sistema operacional utilizado foi Windows 11 Pro, com Python 3.11 e PyTorch 2.1.0.

4. Resultados e Discussões

4.1. Resultados Numéricos e Discussão

A avaliação do desempenho dos modelos foi feita em duas etapas: a primeira sendo uma análise estatística baseada nas métricas clássicas de classificação utilizando o conjunto de testes, e a outra uma análise qualitativa e empírica das séries temporais focada no comportamento dos modelos diante de eventos reais captados pelo sistema IoT. Para essa análise, foram consideradas as métricas discutidas por Tharwat (2018) como Acurácia (acerto geral), a Precisão (detectar corretamente a previsão de chuva), o Recall (capacidade de mapear todos os eventos de chuva), o F1-Score (equilíbrio entre precisão e recall), área sob a curva ROC (ROC-AUC), além do Coeficiente de Correlação de Matthews (MCC).

As métricas Acurácia, Precisão, Recall e F1-Score são as mais comuns e variam no intervalo $[0, 1]$. (THARWAT, 2018). Normalmente, quanto mais próximos os valores forem de 1, melhor a capacidade de classificação geral do modelo. De forma prática, valores em torno de 0,5 indicam desempenho mediano, valores entre 0,7 e 0,8 indicam bom desempenho e valores próximos de 0,9 ou superiores indicam desempenho excelente.

No entanto, segundo Chicco e Jurman (2020), essas métricas podem não ser confiáveis e representar uma visão muito otimista dos resultados perante grande desbalanceamento da classe majoritária.

O MCC varia no intervalo $[-1, 1]$, em que $+1$ representa classificação perfeita, 0 desempenho equivalente ao acaso e -1 desacordo total entre predição e classe real (CHICCO; JURMAN, 2020). Diferentemente da ROC-AUC, que avalia a capacidade do modelo de separar instâncias positivas e negativas independentemente de um ponto de corte específico, o MCC é calculado a partir de uma única matriz de confusão, associada a um limiar previamente definido (*threshold*) (THARWAT, 2018; CHICCO; JURMAN, 2020). Isso significa que o MCC mede diretamente a qualidade da decisão binária final do modelo, considerando simultaneamente verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos. Por incorporar todos esses elementos em seu cálculo, o MCC fornece uma medida mais equilibrada do desempenho, sendo particularmente adequado em cenários com desbalanceamento de classes (CHICCO; JURMAN, 2020), nos quais métricas como acurácia podem apresentar valores erroneamente elevados.

Já a curva ROC (*Receiver Operating Characteristic*) é o sumário dos diferentes desempenhos da matriz de confusão para vários limiares de decisão (THARWAT, 2018). Nesse sentido, são testados diversos limiares dentro da faixa $[0, 1]$ e, para cada um deles, calculam-se a Taxa de Verdadeiros Positivos (TPR) e a Taxa de Falsos Positivos (FPR). A partir dessa curva calcula-se a AUC (*Area Under the Curve*), que corresponde à área sob a ROC e sintetiza, em um único valor, a capacidade geral do modelo de separar instâncias positivas e negativas (THARWAT, 2018). Nesse sentido, valores próximos a $0,5$ indicam desempenho equivalente a aleatoriedade, enquanto valores próximos de 1 indicam maior poder de separação entre as classes.

A Tabela 6 demonstra os resultados quantitativos obtidos por cada um dos modelos durante a fase de treinamento. Observa-se que MCP apresentou, estatisticamente, os melhores indicadores globais, com precisão de $0,70$, ROC-AUC de $0,94$ e F1-Score de $0,68$. Já o modelo MR apresentou desempenho ligeiramente inferior, com precisão de $0,64$, ROC-AUC de $0,91$ e F1-Score de $0,62$. Nesse contexto, esses valores indicam que ambos os modelos foram capazes de identificar corretamente a maioria dos eventos e conseguem diferenciar as classes na maior parte do tempo durante o período de treinamento e testes.

No entanto, esses valores devem ser interpretados com cuidado, visto que a superioridade numérica do MCP seguido pelo MR podem ser parcialmente explicadas pelo viés introduzido pela interpolação linear aplicada aos dados de treinamento. Esse procedimento tende a suavizar ruídos naturais da série temporal e a introduzir valores sintéticos determinísticos, facilitando a convergência da rede neural em cenários controlados, especialmente no caso desses dois modelos, que foram treinados a partir de dados horários do INMET interpolados da distribuição horária para janelas de 10 minutos, resultado em um número mais maior de eventos na etapa de treinamento e testes.

Em contrapartida, o modelo baseado em eventos (MBE) apresentou métricas globais inferiores, com precisão de $0,48$ e F1-Score de $0,49$, embora tenha mantido um ROC-AUC de $0,89$. Esse resultado indica que, apesar de o modelo conseguir distinguir probabilisticamente as classes com desempenho próximo aos demais, sua decisão binária final

Métrica	Referência	Curtíssimo Prazo	Baseado em Eventos
Acurácia	90,89%	93,70%	91,96%
Precision (Chuva)	0,6427	0,7007	0,4871
Recall (Chuva)	0,6095	0,6710	0,5025
F1-Score (Chuva)	0,6256	0,6855	0,4947
MCC	0,5740	0,6507	0,4510
ROC-AUC	0,9130	0,9470	0,8980

Tabela 6. Comparativo de Métricas de Desempenho

Fonte: Elaborado pelo autor

apresenta maior oscilação quando avaliada sob um limiar fixo de classificação.

Além disso, o MCC, por considerar simultaneamente todos os elementos da matriz de confusão, mostra-se especialmente adequado para bases de dados desbalanceadas (CHICCO; JURMAN, 2020), como é o caso da previsão de precipitação. Ao apresentar valores mais baixos para o MBE (0,45) em comparação aos demais modelos, o MCC reforça a leitura de que o MBE foi treinado sob um paradigma diferente, sem interpolação e com redução deliberada do volume de dados, priorizando sequências associadas a eventos anteriores aos de chuva.

Cabe ressaltar que, embora essas métricas sejam amplamente utilizadas para avaliação de classificadores, elas avaliam predominantemente a capacidade de acerto pontual do modelo e não capturam adequadamente aspectos temporais relevantes à proposta do trabalho, como antecipação do alerta ou estabilidade da predição ao longo do tempo. Dessa forma, a análise estatística, por si só, não foi suficiente para avaliar a aplicabilidade prática dos modelos em um sistema de alerta meteorológico, tornando necessária a análise do comportamento dinâmico apresentado a seguir.

Embora as métricas globais presentes na Tabela 6 forneçam uma visão geral do desempenho durante o treinamento e validação, elas podem ser insuficientes para diagnosticar o comportamento dos modelos em cenários de desbalanceamento severo, como é o caso de eventos de precipitação. Em meteorologia, os períodos de tempo estável (sem chuva) superam muito os eventos de chuva, o que tende a inflacionar a métrica de Acurácia (CHICCO; JURMAN, 2020) como pode ser visto na Tabela 6.

Sendo assim, para compreender a real capacidade preditiva dos algoritmos e justificar as variações observadas entre as métricas, faz-se necessária a análise dos resultados em uma Matriz de Confusão. A seguir, serão apresentadas os valores absolutos de acertos e erros, bem como as proporções internas para cada arquitetura, a fim de distinguir a capacidade do modelo de identificar corretamente a chuva (Verdadeiros Positivos), registrar alarmes falsos (Falsos Positivos) e omitir eventos (Falsos Negativos) (Tabelas 7, 8 e 9).

	Predito: Não Chuva	Predito: Chuva	Support
Real: Não Chuva	93.835	4.914	98.749
Real: Chuva	4.696	7.949	12.645

Tabela 7. Matriz de Confusão - Modelo de Referência (MR)

Fonte: Elaborado pelo autor

	Predito: Não Chuva	Predito: Chuva	Support
Real: Não Chuva	83.594	2.825	86.419
Real: Chuva	3.244	6.615	9.859

Tabela 8. Matriz de Confusão – Curtíssimo Prazo (MCP)

Fonte: Elaborado pelo autor

	Predito: Não Chuva	Predito: Chuva	Support
Real: Não Chuva	13.482	635	14.117
Real: Chuva	597	603	1.200

Tabela 9. Matriz de Confusão – Baseado em Eventos (MBE)

Fonte: Elaborado pelo autor

A análise dos dados brutos das matrizes de confusão (Tabelas 7, 8 e 9) demonstra a razão pela qual a acurácia se mantém elevada enquanto a precisão e o recall apresentam valores menores. Observa-se uma predominância massiva de Verdadeiros Negativos (TN), isto é, momentos de tempo seco corretamente identificados. No modelo MBE, por exemplo, o equilíbrio entre Verdadeiros Positivos (603) e Falsos Negativos (597) revela um desempenho próximo ao acaso na detecção de chuva, embora a acurácia seja inflada pela correta classificação das 13.482 instâncias de tempo seco. Esse cenário ratifica as críticas de Chicco e Jurman (2020), evidenciando que a acurácia, ao ser dominada pela classe majoritária, mascara a real dificuldade dos modelos em identificar o evento de interesse (precipitação).

Com o objetivo de transformar a antecipação visual observada nas séries temporais em medidas quantitativas comparáveis, foi elaborada a Tabela 10, focada especificamente no desempenho dos modelos sob a perspectiva de alerta. Diferentemente da Tabela 6, que sintetiza métricas clássicas de classificação pontual, a Tabela 10 introduz indicadores orientados aos eventos registrados no *dataset* de inferência (dados dos sensores), buscando verificar a real eficácia dos modelos em gerar os alertas próximo ao início de cada precipitação e quantos alertas negativos foram gerados dentro do espaço de 3 horas anteriores e posteriores do evento de precipitações observados.

Modelo	Alertas Úteis	Falsos Alertas
MR	1/5	4
MCP	0/5	8
MBE	3/5	3

Tabela 10. Análise de Alertas e Probabilidades por Modelo

Fonte: Elaborado pelo autor

Vale ressaltar que apenas a primeira entrada da sequência foi considerada para a geração de alertas úteis, evitando a contagem redundante de leituras consecutivas como eventos independentes. Em relação à análise de inferência, definiu-se um critério de sucesso baseado em uma probabilidade acima de 70% em um horizonte de até 60 minutos antes do evento de chuva.

Inversamente, os falsos alertas foram contabilizados quando a probabilidade superava os 70% em janelas fora do intervalo de uma hora antes ou depois de um evento real.

Caso o valor caísse abaixo desse limiar e voltasse a subir fora desse período, um novo falso alerta era registrado. Dessa forma, para visualizar a aplicabilidade prática além dos números estatísticos, analisou-se a resposta dinâmica dos modelos em cinco cenários meteorológicos distintos registrados pelo protótipo.




Figura 6. Comparativo de resposta preditiva em evento de precipitação

Fonte: Elaborado pelo autor.

O cenário presente na Figura 6 representa um evento de precipitação intensa ocorrido no dia 05/11 e é possível notar uma diferença significativa no tempo de resposta entre os modelos. O MR (linha cinza) apresentou comportamento conservador, elevando gradualmente sua probabilidade até o início da precipitação, ainda com valores inferiores a 60%. O MCP (linha laranja) demonstrou alta instabilidade, com oscilações abruptas entre picos e quedas de probabilidade minutos antes da chuva, possivelmente influenciado pela relativa estabilidade da umidade no período pré-evento.

Já o modelo MBE conseguiu identificar precocemente a tendência das condições atmosféricas, cruzando o limiar de alerta de 70% cerca de 40 minutos antes do início da precipitação, atendendo ao critério de análise discutido anteriormente, impulsionado principalmente pela queda consistente da pressão atmosférica e pela saturação da umidade conforme pode ser visto nos Painéis B e C. Contudo, apresentou dificuldade em identificar o término do evento, possivelmente devido à continuidade da tendência de queda da pressão.




Figura 7. Comparativo de resposta preditiva em evento de precipitação

Fonte: Elaborado pelo autor.

Já no evento de chuva leve e rápida ocorrido no dia 07/11 (Figura 7), é possível notar que nenhum dos modelos realmente conseguiu prever com exatidão o evento de chuva. O fator que potencialmente mais contribuiu para o ocorrido, foi devido à rapidez do evento, mesmo com os valores exibindo alta tendência à chuva convectiva. O modelo que mais compreendeu o cenário de aumento da temperatura e redução da umidade e queda de pressão foi o MR, no qual permaneceu em crescente, por mais que não tenha atingido corretamente o limiar a tempo da precipitação. O MCP por sua vez, teve picos e vales, o que demonstra a natureza caótica da tentativa de prever valores que não necessariamente seguem linearidade conforme o treinamento do mesmo, enquanto o MBE permaneceu próximo a 60% durante todo o período, mas também não atingiu o valor mínimo de alerta efetivo.

O cenário de chuva ocorrido no dia 09/11 (Figura 8), representa também um evento de chuva leve, mas com queda bem acentuada dos valores de pressão atmosférica. É possível analisar por meio do gráfico que todos os modelos tiveram um pico de decisão aproximadamente 40 minutos antes do evento de chuva, possivelmente motivados por uma leve variação positiva da umidade. No entanto, apenas MR e MBE conseguiram atingir o limiar e gerar um alerta efetivo, no entanto apenas MBE manteve sua decisão até o início da precipitação.

O evento destacado nesse dia, se assemelha bastante ao acontecido na Figura 7, No entanto, mesmo com os valores sejam equivalentes em comportamento, os modelos agiram diferentes em ambos os cenários. Tal característica reforça a premissa de que tentar prever chuvas apenas com os valores meteorológicos utilizados podem não ser a forma mais eficaz, talvez outra grandeza como a velocidade do vento por exemplo, possam ter variado nos dois cenários.




Figura 8. Comparativo de resposta preditiva em evento de precipitação

Fonte: Elaborado pelo autor.

Já o cenário presente na Figura 9, avaliou o comportamento dos modelos diante de uma chuva de muito leve, onde os sinais meteorológicos são bem mais sutis, especialmente os de pressão atmosférica. Nesse evento, o MCP falhou totalmente em antecipar a precipitação, mantendo probabilidades inferiores a 15%, possivelmente influenciado pela estabilidade temporária da pressão atmosférica no período adjacente ao evento (Painel C). O MBE manteve níveis de alerta superiores a 60% com cerca de uma hora de antecedência, enquanto o MR permaneceu com sua crescente conservadora tendo um pico após o evento, intensificado potencialmente pela queda súbita da pressão atmosférica.

No entanto, nenhum dos modelos atingiu o limiar mínimo, porém MBE e MR identificaram parcialmente a tendência, subindo ou descendo suas probabilidades conforme os dados de entrada iam sendo registrados. É possível notar que o modelo MR possui menos variação, e se demonstra mais estável em relação às decisões, sem muitas subidas e quedas rápidas.




Figura 9. Resposta dos modelos em evento de chuva leve e instabilidade

Fonte: Elaborado pelo autor.

Por fim, analisou-se um cenário de "falso positivo", isto é, a iminência, mas sem a precipitação, ocorrido em 11/11 (Figura 10) e observado empiricamente. Neste dia, houve uma queda de pressão de aproximadamente 3 hPa (Painel C) associada a um rápido aquecimento e ressecamento do ar (Painel B), configurando um quadro típico de pré-tempestade (Figura 11). Embora a chuva não tenha realmente acontecido, o modelo MR e MBE demonstraram entender que havia iminência de precipitação, mas somente o segundo manteve probabilidade em nível de alerta (acima de 70%) momentos antes do início do período analisado.

Vale também notar que MCP teve um pico de decisão junto com MBE no início período observado, MR também permaneceu em subida durante todo o período. Com isso, pode-se inferir que todos os três modelos, entenderam que algo estava na iniminencia de acontecer naquele momento, no entanto MCP teve uma queda brusca, e apenas os outros dois permaneceram com o comportamento, MR de subida constante, e MBE mantendo seu valor aproximadamente em 72% durante todo o período.

Estatisticamente, tanto o modelo MR e MCP acertaram ao não alcançarem o limiar de 70% nesse evento falso-positivo, mas esse comportamento conservador (MR), e errático (MCP) simbolizaram um potencial risco de erro no cenário. Ao emitir um alerta às condições iminentes, MBE alertou corretamente sobre os riscos e deu valor razoável para eventual preparo humano em caso de que uma chuva realmente acontecesse (como retirar roupas do varal) ou fechar as janelas de uma residência.




Figura 10. Comportamento dos modelos em cenário de iminência sem chuva

Fonte: Elaborado pelo autor.

Nesse contexto, é possível compreender parcialmente as baixas métricas estatísticas de MBE, visto que ele cumpre o papel de alertar sobre a iminência de eventos meteorologicamente coerentes, mesmo quando são falsos-positivos, ao priorizar a identificação de tendências, uma vez que um falso-negativo pode acarretar consequências mais graves; nesse sentido, a Figura 11 confirma a premissa central deste trabalho, isto é, a utilidade do alerta pode se sobrepôr à precisão numérica, pois, embora a precipitação não tenha ocorrido (falso positivo), a formação das nuvens e as mudanças nos parâmetros atmosféricos justificariam uma ação preventiva humana, de modo que o modelo MBE demonstrou certo sucesso ao "mimetizar" a percepção de risco humana, validando sua função como mecanismo de alerta preventivo.




Figura 11. Registro da iminência de chuva dia 11 de novembro de 2025

Fonte: Elaborado pelo autor.

4.2. Discussão das Abordagens e Comparação entre os Modelos de IA

Após a análise comparativa dos resultados, corrobora-se com as ideias de Chicco e Jurman (2020) que nem sempre as métricas e estatísticas globais podem ser consideradas como único ponto de avaliação da qualidade de um modelo de Inteligência Artificial, especialmente em classes desbalanceadas. Os modelos referência (MR) e curtíssimo prazo (MCP), ao serem treinados com dados interpolados e contínuos, alcançaram boas métricas de precisão no treinamento. No entanto, na realidade não se saíram muito bem diante da aleatoriedade e dos ruídos inerentes aos dados reais coletados em campo.

O comportamento conservador observado no modelo MR pode ser interpretado como consequência direta do elevado desbalanceamento de classes aliado à linearidade imposta pelo processo de interpolação, o que tende a induzir o modelo a respostas lentas e excessivamente suavizadas. Em contraste, o modelo MCP, apesar de compartilhar parte dessas limitações estruturais, opera sob um horizonte decisório significativamente mais curto, o que o torna particularmente sensível a flutuações aleatórias dos sensores. Tal combinação contribui para um comportamento mais instável e errático, especialmente em contextos onde pequenas variações não necessariamente representam mudanças atmosféricas relevantes.

A abordagem MBE representa uma ruptura conceitual em relação aos modelos anteriores, ao deslocar o foco da predição contínua para a detecção de padrões associados a eventos específicos. Ao eliminar a interpolação linear no conjunto de treinamento e priorizar variações relativas (Deltas) que antecedem episódios de precipitação, o modelo passa a operar sob uma lógica orientada à sensibilidade temporal. Como consequência, observa-se uma redução da precisão pontual em favor de um aumento na capacidade de antecipação de alertas, característica compatível com aplicações cujo objetivo principal é a mitigação de risco.

Ademais, ressaltando que o treinamento do MBE foi restrito aos eventos de precipitação, utilizando apenas a janela de 3 horas antecedente à chuva e sem a aplicação de técnicas de interpolação. Essa redução no volume de dados parte da hipótese de que um modelo treinado especificamente sobre a dinâmica dos eventos de interesse apresentaria uma maior sensibilidade na detecção da classe minoritária, em comparação a modelos treinados em bases de dados contínuas e massivamente desbalanceadas.

Nesse contexto, o comportamento mais persistente do modelo MBE após eventos de instabilidade, identificado em alguns cenários analisados, não deve ser interpretado exclusivamente como erro de classificação. Em aplicações de monitoramento meteorológico, o custo associado a um falso positivo tende a ser muito inferior ao custo de um falso negativo (HOFACKER, 2023; MARQUES; DERECHYNSKI, 2021), especialmente quando se trata de alertas preventivos. Assim, a manutenção de probabilidades elevadas em condições atmosféricas instáveis pode resultar na detecção correta de padrões físicos, mesmo na ausência de precipitação local imediata.

É importante destacar, contudo, que os resultados obtidos devem ser interpretados à luz das limitações do presente estudo. O período de coleta de dados foi relativamente curto, resultando em um número reduzido de eventos reais de precipitação disponíveis para inferência. Além disso, o sistema de aquisição carece de sensores diretos de vento e chuva, bem como de informações visuais do ambiente, o que restringe a capacidade

dos modelos de capturar a complexidade completa dos fenômenos meteorológicos. Essas restrições contribuem para a permanência de desbalanceamento mesmo na abordagem orientada a eventos e limitam a generalização dos resultados.

Ainda assim, os experimentos indicam que a estratégia baseada em eventos e em variações temporais se mostrou mais adequada para identificar mudanças sutis e progressivas nas condições atmosféricas, fornecendo alertas antecipados de forma mais consistente do que abordagens puramente contínuas. Dessa forma, o trabalho evidencia que, em aplicações de IoT meteorológico, a engenharia de dados, a definição explícita do objetivo do modelo, alerta versus precisão numérica, e a forma de estruturação do conjunto de treinamento, são fatores tão determinantes quanto a escolha da arquitetura da rede neural.

5. Considerações Finais

O presente trabalho teve como objetivo de desenvolver e validar uma arquitetura de sistema residencial inteligente, integrando Internet das Coisas (IoT) e Inteligência Artificial, voltada para o monitoramento microclimático e a emissão de alertas de precipitação. Nesse contexto, a pesquisa demonstrou que a utilização de *hardware* de baixo custo (ESP32 e sensores resistivos), quando aliada a uma estratégia de processamento de dados local e orientada a eventos, é capaz de preencher a lacuna de informação existente entre as previsões regionais oficiais e a realidade imediata do usuário doméstico.

Nesse contexto, a análise comparativa entre os modelos preditivos revelou que a abordagem baseado em eventos (MBE), fundamentada na detecção de variações temporais (Deltas) de pressão e temperatura direcionada às chuvas, mostrou-se mais adequada para a finalidade de segurança e alerta do que as abordagens focadas em séries contínuas (referência e curtíssimo prazo). Embora o modelo MBE tenha apresentado métricas globais de precisão inferiores, ele demonstrou maior sensibilidade e capacidade de antecipação aos eventos de instabilidade atmosférica. Este resultado corrobora a premissa de que, em sistemas de apoio à decisão residencial, a capacidade de identificar a iminência de um risco (mesmo com a ocorrência de falsos positivos) é prioritária em relação à exatidão numérica da previsão.

5.1. Limitações do Estudo

É importante reconhecer as limitações inerentes a esta pesquisa. Primeiramente, o período de coleta de dados locais foi restrito, o que limitou o volume de eventos de chuva disponíveis para validação plena do modelo, especialmente mudanças sazonais e de transição que muitas vezes demonstram de fato os defeitos do sistema. Em segundo lugar, a utilização de sensores de baixo custo introduz ruídos de leitura que, embora mitigados pelo pré-processamento, ainda impõem desafios à estabilidade do modelo em períodos de transição climática suave.

Por fim, a ausência de dados de vento e imagens de céu (câmeras) restringiu as variáveis de entrada do modelo a parâmetros termodinâmicos, dificultando e limitando a detecção de chuvas formadas por advecção rápida ou o término de um evento já registrado. Tais fatores, quando somados a complexidade do problema proposto, somam-se como grandes desafios para a precisão e efetividade do sistema em detectar e alertar esses eventos.

5.2. Trabalhos Futuros

Para a continuidade e evolução desta pesquisa, tem-se como objetivo inicialmente o aprimoramento do modelo baseado em eventos. O treinamento da inteligência artificial pode ser refinado através da utilização de uma base de dados mais extensa, que cubra um período maior de tempo e diferentes estações do ano. Além disso, a realização de ajustes mais finos nos cálculos e nos parâmetros de configuração da rede neural pode contribuir para aumentar tanto a precisão dos alertas, quanto a identificação do fim das chuvas.

Outra possibilidade de expansão está na melhoria da coleta de dados, isto é, a inclusão de novas variáveis, como a intensidade do vento, ajudaria o sistema a identificar chuvas rápidas trazidas por ventanias, que muitas vezes não são detectadas apenas pela queda de pressão. Ademais, o uso de visão computacional também se apresenta como um caminho promissor, tendo em vista que a adição de uma câmera simples para monitorar o céu poderia servir como uma validação visual para o modelo, confirmando a presença de nuvens carregadas antes de emitir um alerta.

Por fim, o sistema pode também evoluir de uma ferramenta de apenas monitoramento para uma solução de automação ativa. A integração do protótipo com atuadores físicos permitiria que o sistema, por exemplo, agisse de forma proativa e preventiva ao detectar a iminência ou o início de chuva, ou seja, o sistema poderia não apenas avisar o usuário, mas executar ações automáticas, como fechar janelas motorizadas ou recolher varais inteligentes, oferecendo uma proteção completa para o ambiente residencial.

Dessa forma, o sistema também apresenta potencial de aplicação em contextos geograficamente afastados, como comunidades rurais e quilombolas, que frequentemente possuem menor cobertura de monitoramento climático em tempo real. Nesses cenários, a utilização de dispositivos de baixo custo, aliada a modelos preditivos locais, pode contribuir para ampliar o acesso a alertas microclimáticos, especialmente quando consideradas limitações como conectividade reduzida, autonomia energética e a necessidade de formas alternativas de comunicação dos alertas.

Referências

- CHICCO, D.; JURMAN, G. The advantages of the matthews correlation coefficient (mcc) over f1 score and accuracy in binary classification evaluation. *BMC Genomics*, v. 21, 01 2020.
- FETZER, J. H. *Artificial Intelligence: Its Scope and Limits*. [S.l.]: Springer, 2007. (Studies in Cognitive Systems).
- GODOI, M. G. d.; ARAÚJO, L. S. d. A internet das coisas: evolução, impactos e benefícios. *Interface Tecnológica*, v. 16, n. 1, p. 19–29, 2019.
- HOFACKER, P. E. d. S. *Previsão do tempo no telejornalismo brasileiro e a possível articulação de um modelo de risco de deslizamento*. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2023.
- MAGRANI, E. *A internet das coisas*. Rio de Janeiro: FGV Editora, 2018.
- MARCHEZINI, V. et al. Participatory early warning systems: Youth, citizen science, and intergenerational dialogues on disaster risk reduction in brazil. *International Journal of Disaster Risk Science*, 12 2017.

- MARCONI, M. d. A.; LAKATOS, E. M. *Metodologia científica*. São Paulo: Atlas, 2004.
- MARQUES, V.; DEREZYNSKI, C. Weather forecasting in brazil: a concise historical review. *Anuário do Instituto de Geociências*, v. 44, 2021.
- METEOROLOGIA, I. N. de. *Dados históricos meteorológicos*. Brasília: [s.n.], 2025. Acesso em: 05 nov. 2025. Disponível em: <<https://portal.inmet.gov.br/dadoshistoricos>>.
- MUCAVELE, L.; MANHICA, R. *Desenvolvimento de um modelo de previsão da seca com recurso à inteligência artificial: caso de estudo Instituto Nacional de Meteorologia (INAM)*. 2025.
- OLIVEIRA, J. A. *O Conhecimento de Inteligência integrado à construção de cenários em apoio ao processo decisório: uma abordagem voltada para a Comunicação de Inteligência*. Dissertação (Mestrado), 02 2025.
- RAMOS, R. A. G. *Análise de métodos de inteligência artificial na previsão de dados pluviométricos*. 68 p. Monografia (Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica)) — Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Itumbiara, 2025.
- RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 4. ed. [S.l.]: Pearson, 2020.
- SAVI, M. A. *Dinâmica não-linear e caos*. [S.l.]: E-papers, 2006.
- SILVA, T. A. d. *Estação meteorológica sustentável aplicada com IoT e Machine Learning*. Brasília, 2021. 58 p. Relatório Final de Iniciação Científica (Graduação em Engenharia de Computação).
- SIVLE, A. D.; KOLSTØ, S. D. Use of online weather information in everyday decision-making by laypeople and implications for communication of weather information. *Meteorological Applications*, v. 23, n. 4, p. 650–662, 2016.
- SOARES, A. C. *Análise de séries temporais com uso de redes neurais artificiais em dados meteorológicos para previsão de chuva e eventos climáticos severos*. 2022.
- TANVIR, M. A.; NAIEMA, N. Rainfall prediction using machine learning: Lstm. *Journal of Computer Science and Information Technology*, v. 2, n. 2, p. 23–33, 2025.
- THARWAT, A. Classification assessment methods: a detailed tutorial. 08 2018.
- TRAN, T. et al. *Exploring Hybrid Models For Short-Term Local Weather Forecasting in IoT Environment*. 2023. 295-306 p.