

Redes Neurais LSTM Aplicadas à Previsão de Eventos Climáticos Extremos e Detecção de Anomalias

Débora S. Rodrigues¹, Angélica N. Caseri², Sinésio Pesco³
Departamento de Matemática / PUC - Rio, Rio de Janeiro, RJ

Nos últimos anos, a frequência e intensidade de eventos climáticos extremos têm aumentado, impactando comunidades, ecossistemas e economias. No Rio de Janeiro, as chuvas intensas, impulsionadas pelas mudanças climáticas e urbanização, causam inundações e deslizamentos, destacando a necessidade de infraestrutura e políticas de gestão de riscos. A previsão de precipitação extrema enfrenta desafios devido à complexa interação de fatores atmosféricos, oceânicos e terrestres. Modelos numéricos de previsão do tempo (NWP) apresentam limitações, como erros sistemáticos e resoluções insuficientes para capturar eventos extremos em escalas menores, exigindo simplificações ou parametrizações que podem introduzir erros [3].

O uso de Inteligência Artificial e Machine Learning tem aprimorado a previsão de chuvas extremas ao identificar padrões em séries temporais e variáveis meteorológicas. Estudos recentes exploram arquiteturas como Transformers e redes convolucionais 3D para aumentar a precisão das previsões [2], [4]. Métodos baseados em redes neurais recorrentes, têm superado técnicas tradicionais na previsão de precipitações intensas, embora desafios persistam, como a dependência de dados de radar de alta qualidade e a adaptação a diferentes regiões [1].

Este trabalho propõe um modelo preditivo para antecipar eventos de precipitação intensa, identificando anomalias e picos de chuva. Para isso, uma rede neural LSTM (Long Short-Term Memory) é treinada exclusivamente com dados de eventos extremos de chuva, buscando contornar a escassez de informações sobre esses fenômenos. A metodologia utiliza dados de pluviômetros de três estações no Rio de Janeiro, coletados entre 2014 e 2023, e emprega janelas temporais deslizantes (lags) de diferentes tamanhos para capturar variações ao longo do tempo. O desempenho do modelo é avaliado por métricas como o RMSE (Root Mean Square Error), que mede a precisão das previsões em relação aos dados observados.

Em séries temporais, janelas deslizantes definem o número de períodos anteriores considerados para prever um valor futuro. Assim, cada janela contém um conjunto de observações passadas, permitindo que a rede capture padrões e dependências ao longo do tempo. Para representar a dinâmica da precipitação, foram testados múltiplos tamanhos de lag, formando uma estrutura tridimensional (amostras, lags, entradas) compatível com o modelo LSTM. O conjunto de eventos extremos inclui chuvas com duração mínima média de 5.6 horas, acumulado médio superior a 40.56 mm e taxa máxima de precipitação média acima de 17.1 mm/h. Dois métodos foram avaliados:

- Método 1 (M1): utiliza 80% do histórico de chuva, incluindo períodos sem precipitação, com janelas variando de 1 a 4 horas.
- Método 2 (M2): treina a rede apenas com eventos de chuva extrema (80% dos eventos selecionados), também com janelas de 1 a 4 horas.

O conjunto de validação e teste corresponde a 5% e 15% dos dados, respectivamente, para ambos os métodos.

A comparação entre os métodos M1 e M2, baseada no RMSE (Figura 1), revela diferenças na previsão de precipitações intensas para 1 hora à frente: O M1 apresenta erro mais elevado,

¹debora.rodrigues@aluno.puc-rio.br

²angelikacaseri@gmail.com

³sinesio@puc-rio.br

influenciado pela inclusão de períodos sem precipitação, o que compromete a especialização na previsão de eventos extremos. Além disso, o erro se mantém alto após picos de precipitação, reduzindo a precisão das previsões. Já o M2 apresenta menor RMSE, melhorando a captura do crescimento e dissipação da chuva. O erro diminui conforme o lag aumenta, sugerindo que um maior histórico de dados favorece a previsão e reduz inconsistências em cenários onde a taxa de precipitação muda rapidamente.

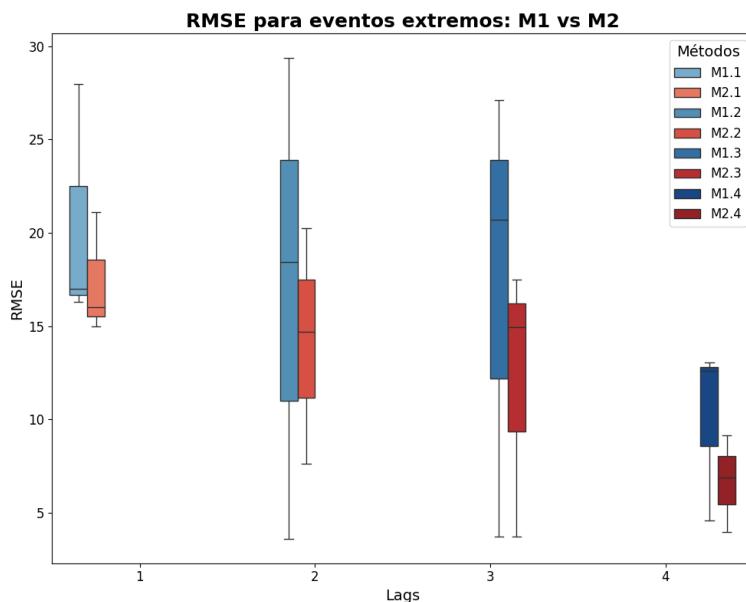


Figura 1: RMSE: M1 vs. M2. Fonte: Autores.

Contudo, melhorias na previsão de chuvas intensas podem ser alcançadas com ajustes nos modelos, como otimização de parâmetros e seleção de janelas temporais adequadas, além do uso de redes neurais convolucionais (CNNs) para análise de imagens de satélite e radar, identificando padrões espaciais de precipitação. Como trabalho futuro, estamos explorando técnicas de geostatística, com ênfase na krigagem, para gerar mapas espaciais de precipitação. Esses mapas serão integrados a modelos de Machine Learning, visando aprimorar as previsões e contribuir para sistemas de alerta precoce mais eficazes. Esses avanços fortalecem estratégias de gestão de riscos em áreas como defesa civil, transporte e recursos hídricos.

Referências

- [1] A. N. Caseri, L. B. L. Santos e S. Stephany, “A convolutional recurrent neural network for strong convective rainfall nowcasting using weather radar data in Southeastern Brazil,” **Artificial Intelligence in Geosciences**, v. 3, pp. 8–13, 2022.
- [2] G. Chen e W.-C. Wang, “Short-term precipitation prediction for contiguous United States using deep learning,” **Geophysical Research Letters**, v. 49, n. 8, e2022GL, 2022.
- [3] E. J. Kendon, N. M. Roberts, H. J. Fowler, M. J. Roberts, S. C. Chan e C. A. Senior, “Heavier summer downpours with climate change revealed by weather forecast resolution model,” **Nature Climate Change**, v. 4, n. 7, pp. 570–576, 2014.
- [4] Y. Sha, R. A. Sobash e D. J. Gagne II, “Improving ensemble extreme precipitation forecasts using generative artificial intelligence,” **arXiv preprint arXiv:2407.04882**, 2024.