

ANÁLISE COMPARATIVA DA EVOLUÇÃO DE TECNOLOGIAS APLICADAS A EVENTOS EXTREMOS DE DESASTRES NATURAIS: USO DE MODELOS PREDITIVOS CLIMÁTICOS APLICADOS ATRAVÉS DA IA

Cleide Martins ¹; Marcelo Franco ²; Rafael Augusto ³;

Resumo – Este artigo destaca a importância da implementação do aprendizado de máquina na reanálise meteorológica para gestão de eventos extremos. Considerando as diversas metodologias para reanálise de eventos extremos existentes, este estudo concentrou-se em comparar o desempenho duas tecnologias inovadoras, recentemente desenvolvidas como resposta a um problema recorrente. E qual seria esse problema? O tempo, que constantemente é insuficiente para realizar uma gestão eficaz de eventos extremos. A pesquisa possibilitou a avaliação do desempenho da tecnologia da Nvidia Omniverse integrada ao machine learning, que foi treinada com um conjunto de dados para reanálise preditiva em eventos diversos, com ênfase na análise meteorológica e otimização para prever. A análise dos resultados por meio de gráficos permitiu identificar os pontos fortes e as limitações da tecnologia. Esse processo ajudou a entender a forma mais adequada de utilizar a tecnologia e de como deve ser realizada a análise preditiva. As informações obtidas serão importantes para futuras aplicações com abordagem na reanálise preditiva, utilizando aprendizado de máquina integrado à tecnologia da Nvidia, contribuindo para o avanço das técnicas meteorológicas e gestão de eventos extremos.

Abstract – This article highlights the importance of implementing machine learning in meteorological reanalysis for extreme event management. Considering the various methodologies for re-analysis of existing extreme events, this study focused on comparing the performance of two innovative technologies, recently developed as a response to a recurring problem. And what would that problem be? Time, which is constantly insufficient to carry out effective management of extreme events. The research made it possible to evaluate the performance of Nvidia's Omniverse technology integrated with machine learning, which was trained with a dataset for predictive reanalysis in various events, with an emphasis on meteorological analysis and optimization to predict. The analysis of the results through graphs allowed us to identify the strengths and limitations of the technology. This process helped to understand the most appropriate way to use technology and how predictive analysis should be performed. The information obtained will be important for future applications with a predictive reanalysis approach, using machine learning integrated with Nvidia technology, contributing to the advancement of meteorological techniques and management of extreme events.

Palavras-Chave – Inteligência artificial; Desastres naturais; Reanálise Climática;

1. Introdução

Cada vez mais eventos climáticos extremos, como ciclones, furacões, tufões e enchentes, vem se intensificando com mais frequência nas últimas décadas. Segundo Sobel et al. (2021) e Kilpua et al. (2019), o aumento desses eventos estão diretamente associados as mudanças climáticas e o constante aumento das ações antrópicas do homem na natureza elevando os padrões de temperaturas médias globais. De acordo com Solares et al. (2016) e Pogorelov et al. (2017), reforçam que com o aumento dos fenômenos atmosféricos vem exigindo integração de dados e aprimoramentos contínuos das tecnologias para previsão e gestão de riscos.

¹ Eng. Civil., MSc, Universidade Federal de Minas Gerais, cleidemm1981@gmail.com

² Eng. Civil, PhD, Universidade Federal de Minas Gerais, marcelo@etg.ufmg.br

³ Eng.Civil, Esp, Universidade Federal de Minas Gerais, ra2361982@ufmg.br

Neste sentido é importante entender o conceito de eventos extremos hidrológicos, que abrange diversos fenômenos meteorológicos. Tufões e furacões, embora semelhantes em estrutura, são diferenciados principalmente por sua zona de pressão e de como ocorrem. Furacões podem ter sua formação inicial no Atlântico e nordeste do Pacífico chegar a atingir não só a região costeira como também a demais regiões expostas, enquanto ciclones podem ter sua formação inicial no Pacífico Noroeste atingir região costeira. A figura 2 destaca o poder destrutivo (Tuluri et al., 2010; Selvam et al., (2025).



Figura 1. Poder destrutivo adaptado de MetSul Meteorologia (2025)

No entanto Moore et al., (2012); Hoque et al., 2017, descreve que é muito importante ter habilidade precisa para prever estes eventos meteorológicos devastadores que ocorrem de forma repentina. Nesse contexto, o advento de novas abordagens tecnológicas, em especial aquelas baseadas em Inteligência Artificial (IA), surge como uma alternativa promissora para otimizar a precisão das previsões climáticas e mitigar impactos socioeconômicos e ambientais dos desastres naturais.

A reanálise atmosférica surge como uma ferramenta fundamental para compreender a evolução dos eventos extremos e aprimorar a gestão de riscos. Modelos como o ERA5 têm sido amplamente utilizados para reconstruir as condições climáticas passadas, permitindo uma base sólida para a calibração de modelos preditivos, conforme apontam Price et al. (2025) e Kashinath et al. (2023). Trabalhos como os de Bolla et al. (2022) e Kilpua et al. (2019) destacam que o uso de reanálises facilita a identificação de padrões climáticos recorrentes, aprimorando a emissão de alertas antecipados e a formulação de políticas de adaptação.

Neste sentido nos últimos anos, a integração de técnicas de Inteligência Artificial (IA) aos modelos de previsão climática tem promovido avanços significativos na capacidade preditiva de eventos extremos. Modelos como o GenCast (Price et al., 2025) e o NeuralGCM (Wang et al., 2024) demonstram desempenho superior em relação aos métodos numéricos tradicionais, especialmente na previsão de ciclones tropicais e tempestades severas. Segundo Schanz et al. (2023) ressaltam que o treinamento desses modelos com dados de reanálise tem potencializado a precisão na estimativa da trajetória e da intensidade de fenômenos meteorológicos críticos. A figura 2 descreve um pouco a curva evolutiva de reanálise.



Figura 2. Infográfico panorâmico evolutivo tecnológico.

Além dos avanços algorítmicos, o desenvolvimento de plataformas tecnológicas, como o “NVIDIA Omniverse Earth-2”, tem redefinido o conceito de modelagem climática. Segundo Kashinath et al. (2023) e Pathak et al. (2022), a iniciativa “Earth-2” combina “supercomputação de alto desempenho (HPC)” com “modelos baseados em aprendizado profundo”, como o “FourCastNet”, que

proporcionando simulações de alta resolução e em tempo quase real. Essa integração permite a criação de uma simulação digital da Terra (“*Digital Twins*”), que otimiza a previsão de eventos climáticos extremos e ampliando as possibilidades de análise em diferentes escalas espaço-temporais.

Diante desse panorama, este artigo tem como objetivo de fazer uma análise comparativa das novas tecnológica de reanálise meteorológicas de desastres naturais, com foco em “modelos preditivos climáticos aprimorados por machine e Inteligência Artificial”. Conforme destacam Soomro et al. (2019) e Bolla et al. (2022), a convergência entre dados de reanálise, sensoriamento remoto e aprendizado de máquina tem gerado resultados promissores, mas ainda existem desafios quanto à escalabilidade, generalização e representatividade de eventos extremos em diferentes cenários. Assim, busca-se contribuir para o avanço do conhecimento científico voltado à mitigação de riscos e à gestão de desastres naturais em um contexto de crescente incerteza climática.

2. REVISÃO DE LITERATURA

Para compreender o tema e analisar como a produção científica tem sido aplicada, realizou-se uma revisão sistemática da literatura com o objetivo de apresentar um panorama sobre a reanálise meteorológica, comparando-a ao uso de machine learning e IA nos modelos preditivos climáticos aprimorados. Foram utilizadas palavras-chave como reanálise preditiva climática, reanálise climática, evolução tecnológica, inteligência artificial, machine learning e NVIDIA Earth-2, sendo aplicados filtros para restringir títulos fora do tema e resumos de artigos. Foram encontrados 1.157 artigos, dos quais 42 foram selecionados para leitura. Após essa filtragem, restaram 25 artigos que se destacaram para compor o referencial teórico.

3. METODOLOGIA

O presente estudo foi dividido em etapas, definição e preparação do ambiente de análise climática, integração dos dados, seleção tecnológica e validação dos dados obtidos. Para uma melhor compreensão dos métodos empregados, foi desenvolvido um framework visual que descreve todas as fases do processo de análise, conforme demonstrado na Figura 3.

FRAMEWORK

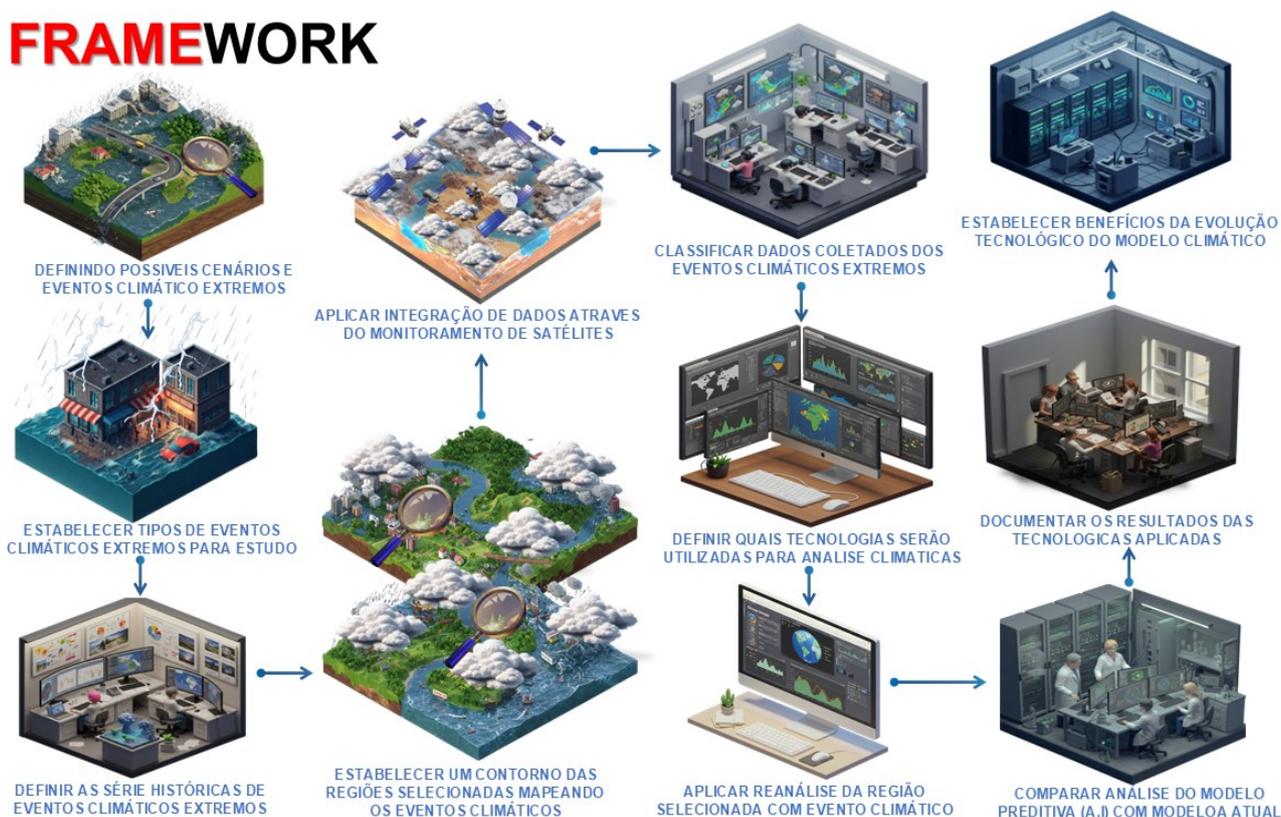


Figura 3. Framework de desenvolvimento da pesquisa.

Inicialmente foram identificados cenários e eventos climáticos extremos, levantadas séries históricas e delimitadas regiões por geoprocessamento. As áreas afetadas tiveram seu contorno geográfico estabelecido por meio da integração de dados de satélites e sistemas de monitoramento. Em seguida, os dados coletados foram classificados e aplicados para cada análise específica de cada região selecionada. Após a confirmação dos resultados, foram comparados os desempenhos das tecnologias utilizadas para avaliação climatológica.

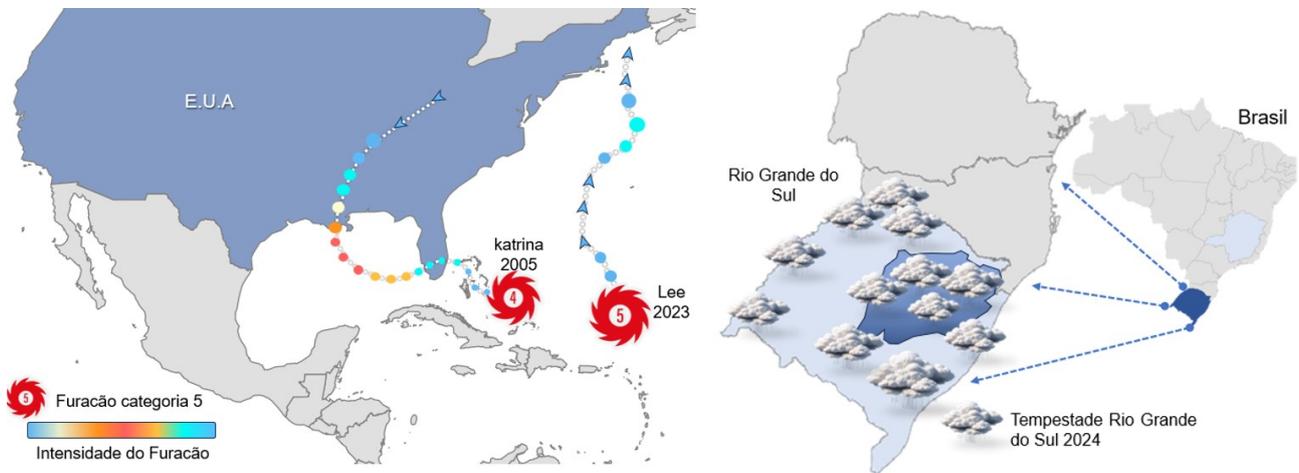


Figura 4. Mapa com localização dos eventos climáticos selecionados.

Na Figura 5, foi realizada a reanálise meteorológica de furacões utilizando metodologia numérica. A primeira imagem, proveniente do Copernicus Marine Service, reconstituiu o Furacão Katrina (2005) com foco na altura significativa das ondas e na intensidade dos ventos na superfície do mar. O gráfico 01, foi gerado pela NOAA, que mostra a evolução da velocidade do vento durante a passagem do Furacão Lee (2023) na costa da Flórida, destacando rajadas superiores a 10 m/s.

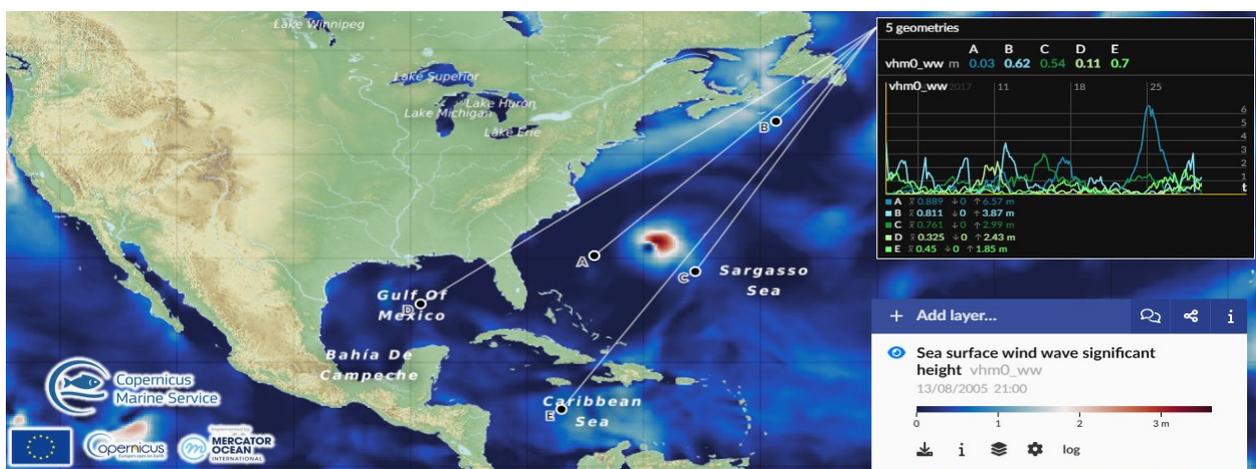


Figura 5. Reanálise do Furacão Katrina 2005 através do sistema copernicus.eu (2005). Fonte: Autores.

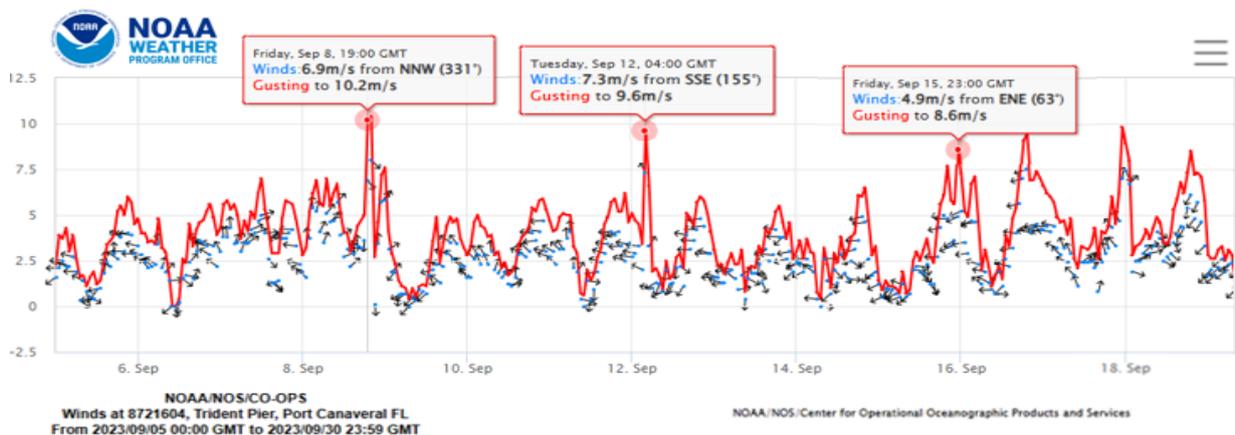


Gráfico 1. Reanálise do Furacão Le 2023 através do sistema NOAA(2023). Fonte: Autores 2025.

Entretanto a metodologia numérica, e precisa, porém, não consegue ser preditiva. Para fazer esse tipo de reanálise, é necessário que a simulação consiga utilizar os dados atuais, analisando a variabilidade temporal e espacial das medições sem comprometer a precisão dos modelos. Além disso deve conseguir, integrar diversas fontes de dados que requer calibração e validação rigorosas. Proposta que foi levada a sério, com a plataforma Nvidia através do sistema Omminverse que conseguiu superar todos os obstáculos. Utilizando um processo complexo, que exige alto poder computacional que executa análises meteorológicas robustas. A Figura 6 destaca uma pequena análise realizada através do sistema Nvidia Omminverse.

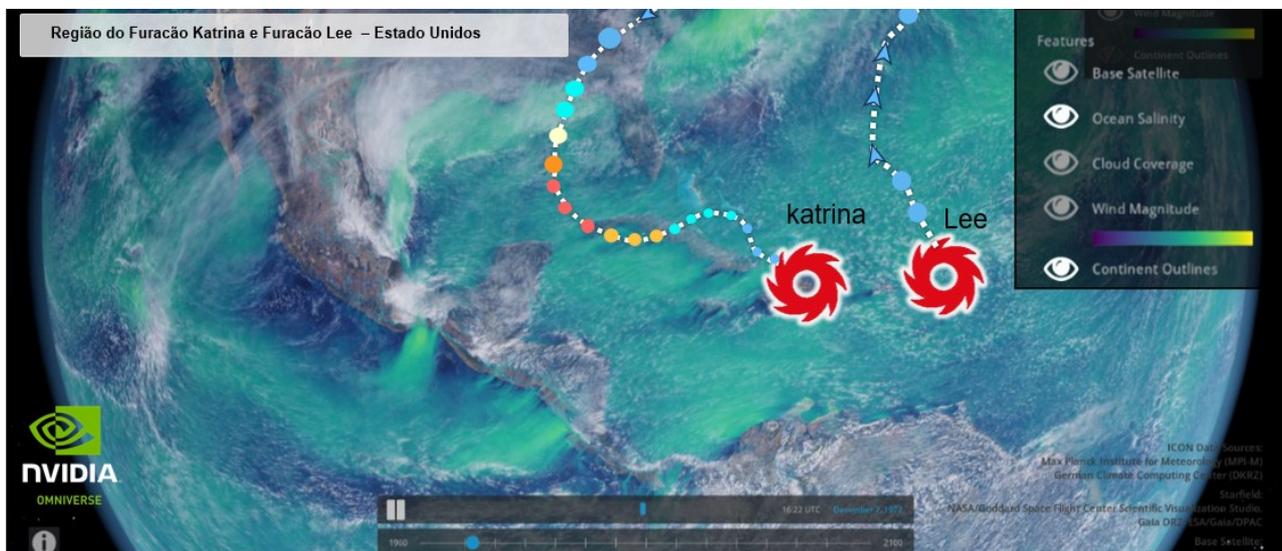


Figura 6. Reanálise através do sistema Nvidia Omminverse com A.I a magnitude dos ventos. Fonte: criadores (2025).

A figura 07 destaca uma reanálise desenvolvida pelo pesquisador Aragão, et al. (2024), que utilizou dados meteorológicos e séries dos institutos “IFS” do “ECMWF” dos satélites, desenvolvendo modelos numéricos e algoritmos de machine learning para reconstrução espacial e temporal das condições atmosféricas de “Santa Catarina”. Através de técnicas de aprendizado de máquina, foi possível gerar mapas de precipitação e temperatura com alta resolução, mesmo em áreas com baixa cobertura observacional.

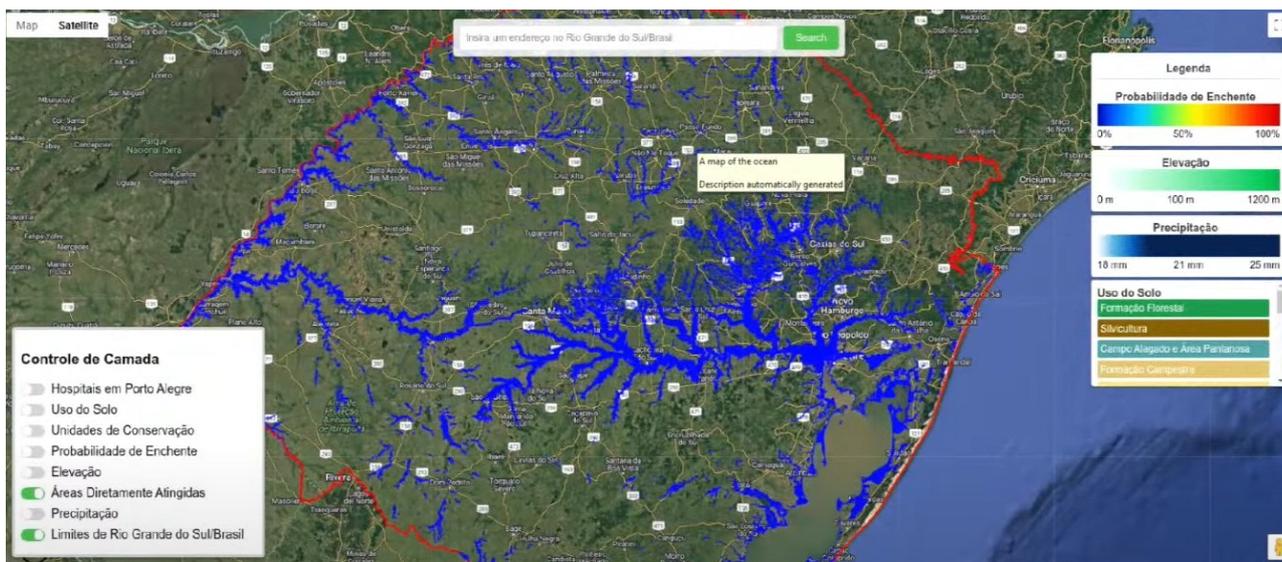


Figura 7. Reanálise através geoprocessamento com M.L na Região do Rio Sul. Fonte: Aragão, et al. (2024)

Comparando os dois métodos e seus fluxos, é possível ver que, com o uso da inteligência artificial e técnicas de geoprocessamento, aliado ao machine learning é possível ampliar a eficiência das reanálises meteorológicas, possibilitando a assimilação de grandes volumes de dados com maior precisão e em menor tempo. Nesse contexto, foi realizada uma outra reanálise comparativa preditiva com uso de machine learning, na Figura 8.

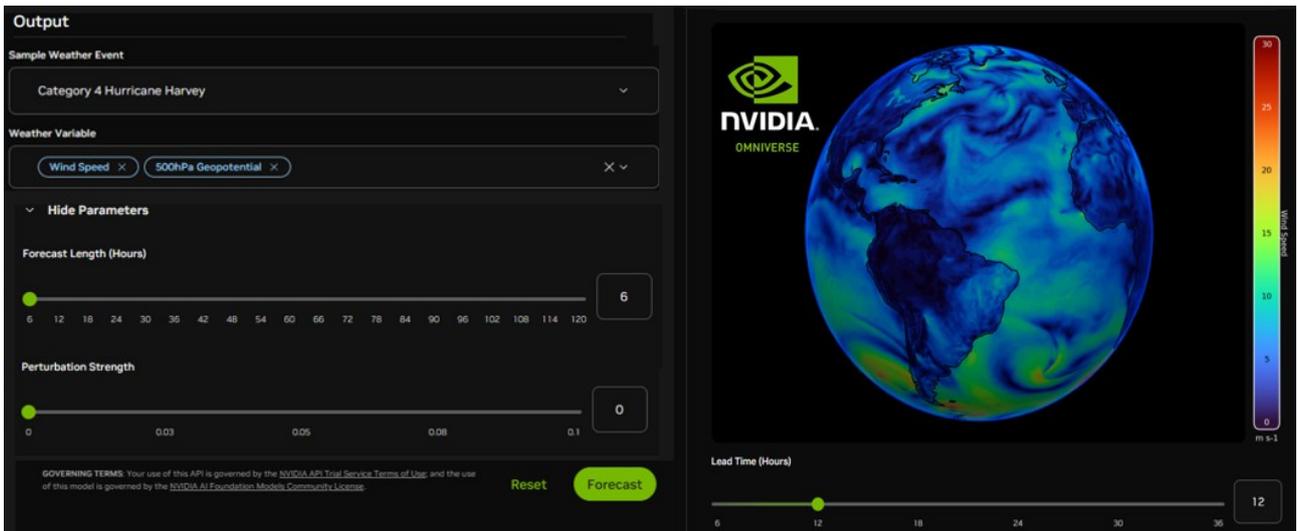


Figura 8. Mostra reanálise global através do “FourCastNet do sistema Nvidia Omminverse com A.I. Fonte: criadores (2025)

Nesse modelo foi criada uma análise preditiva que como trabalha com dados residuais, o “ResBlk” que é o bloco residual convolucional que forma a “unidade de construção” básica da rede, permitindo que o modelo “FourCastNet” seja profundo e estável, preservando detalhes finos enquanto mantém o treinamento eficiente. E a sigra “IFS” é a sigla de Integrated Forecast System, o modelo numérico operacional de previsão do tempo do ECMWF (European Centre for Medium-Range Weather Forecasts).

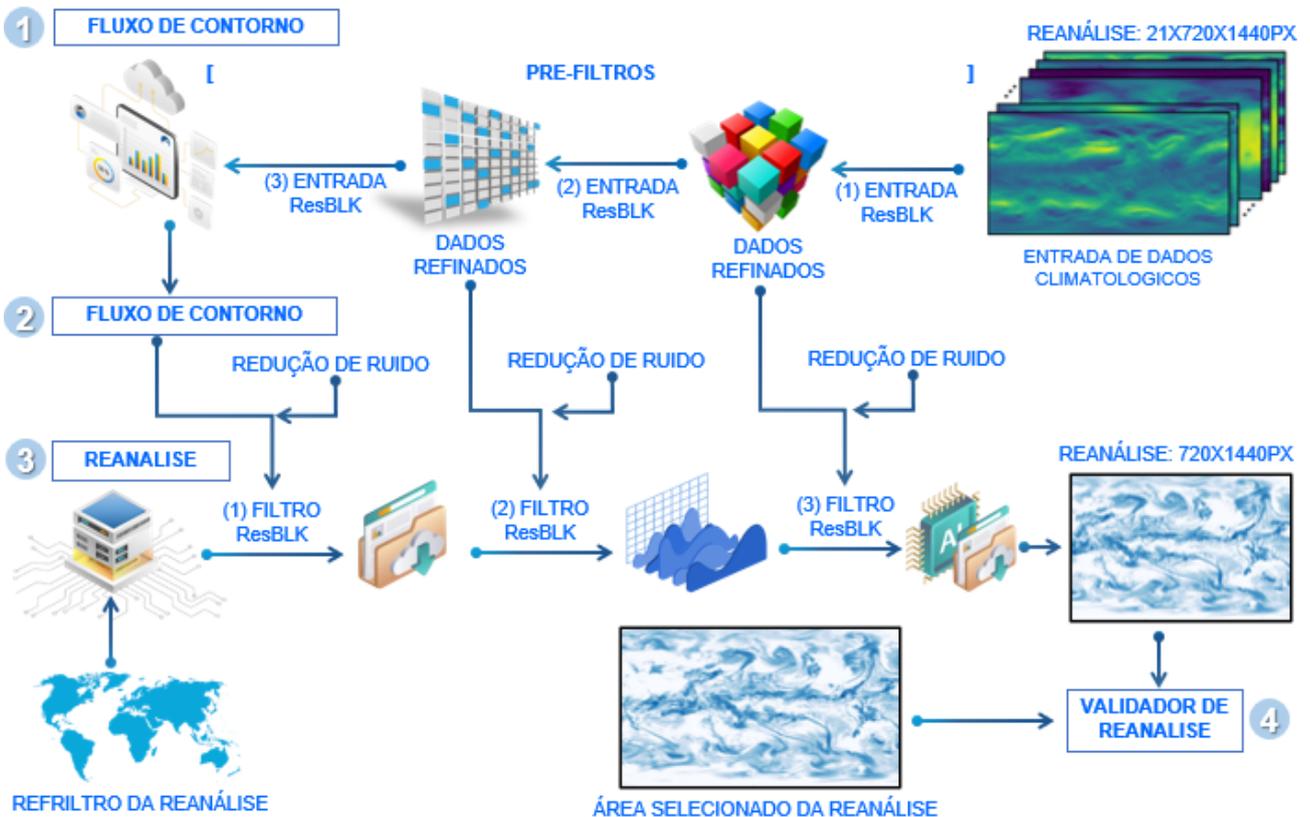


Figura 8 e 9. Descrição da metodologia de reanálise através M.L. Fonte: Duncan et al. (2022)

Nessa foi elabora temos um comparativo de tempo, descrevendo os tipos de modelos climático, e tempo para reanálise climática. A tabela 1. Ilustra essa comparação.

Tabela 1. Comparativo dos modelos de reanálise climatológicas

Aspecto	ERA5 (Reanálise)	Modelo NWP Operacional	IA Preditiva
Objetivo principal	Reconstrução histórica consistente	Previsão determinística 0 – 10 dias	Previsão data-driven rápida (≤ 2 dias)
Versão do modelo	Fixa (IFS 41r2) \Rightarrow climatologia homogênea	Atualização aproximadamente a cada 6 meses \Rightarrow drifts de skill	Única rede treinada, requer <i>re-train</i> para nova época de dados
Resolução horizontal	0,25° (\cong 31 km)	\cong 9 km (HRES 0,1°)	\cong 30 km (720 \times 1440)
Atualização / latency	\cong + 5 dias (produção offline)	4 \times dia, <i>near-real-time</i>	Inferência em segundos e <i>lead</i> (leitura útil 0–48 h)
Variáveis geradas	Atmosfera, superfície, ondas, solo	Atmosfera + superfície (centenas)	Neste artigo apenas precipitação 6 h; precisa variáveis condicionantes (20 campos)
Custo computacional	Muito alto (Processamento em nuvem retrospectivo)	Muito alto (Processamento em nuvem em tempo real)	Pode ser analisada com uma única GPU, sendo mais barato para fazer a reanálise.
Pontos fortes	Série homogênea 1940 – 2025, ideal para clima	Melhor físico-química, múltiplas variáveis	Captura extremos e detalhes finos e gera grandes ensembles baratos.
Limitações	Não antecipa futuro e depende de análise de dados anteriores.	Viés em precipitação convectiva; alto custo	A qualidade preditiva, pode ser reduzida decaindo aos poucos em 2 dias, dependendo da qualidade dos dados de treinamento.

O Gráfico 2, ilustra como a arquitetura FourCastNet de Nvidia (L1 + adversarial) com geoprocessamento usando M.L para fazer reanálise consegue aproxima ERA5, superar o modelo clássico.

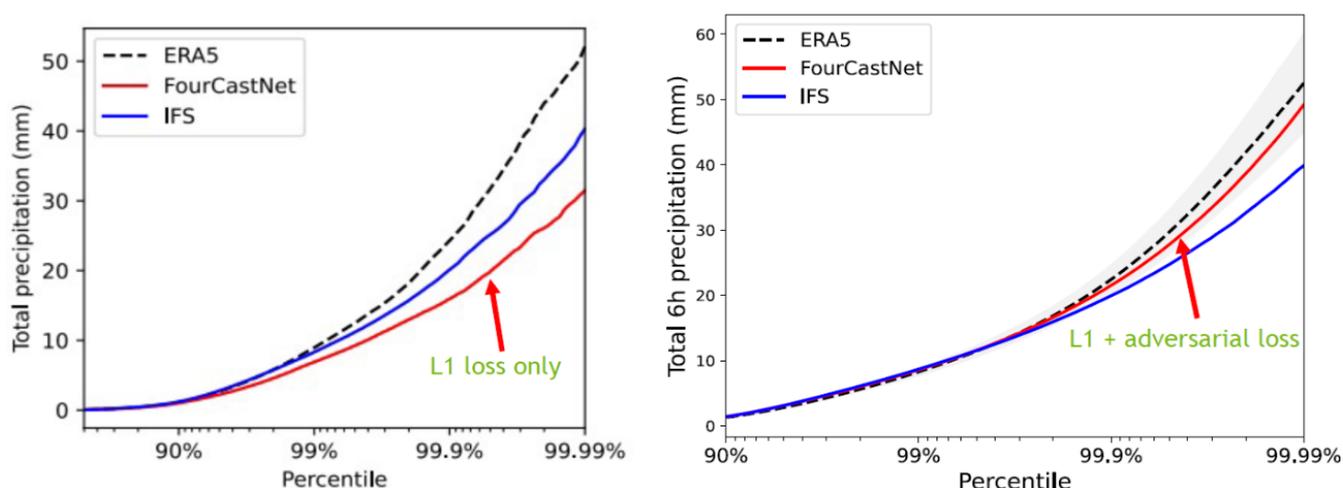


Gráfico 2. Comparativo tempo de reanálise usando machine learning. Fonte: Duncan et al. (2022)

A Figura 9 ilustra o fluxo de reanálise operacional via NVIDIA Omniverse, a integração entre modelos de alta resolução e reanálise através da gpu com ray tracing em nuvem viabiliza simulações climáticas escaláveis, reduzindo latência analítica e ampliando suporte a aplicações multi-setoriais e multi-plataforma.



Figura 9. Funcionamento da Reanalyse através Nvidia Ominverser. Fonte: Nvidia (2025)

4. CONCLUSÕES

Com estes resultados como o do geoprocessamento aliado ao machine learning contribuindo melhor análise e representação espacial e precisa para análise como mostra análise locais possíveis de enchente. Nesse contexto, destaca-se a plataforma NVIDIA, que integra diversos e modelos e tecnologias em tempo real usando IA melhorando bastante a reanálise climática. Além disso, iniciativas futuras podem focar na melhoria para integração.

5. AGRADECIMENTOS

Este trabalho foi financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico, pela Fundação de Amparo à Pesquisa do Estado de Minas Gerais e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Código de Financiamento 001).

REFERÊNCIAS

ARAGÃO, R. P. et al. "Machine Learning e Geotecnologias aplicadas à previsão de locais propensos a enchentes no estado do Rio Grande do Sul." In: SEMINÁRIO IA E MEIO AMBIENTE: CONSTRUINDO FUTUROS POSSÍVEIS, 2025, Brasília. Brasília: LIIA - Laboratório de Inovação em Inteligência Artificial / GNova / Enap, em parceria com AWS e SERPRO, 18 mar. 2024.

BAHADUR, F. T.; SHAH, S. R.; NIDAMANURI, R. R. "Applications of remote sensing vis-à-vis machine learning in air quality monitoring and modelling: a review". Environmental Monitoring and Assessment, Company: Springer Distributor: Springer Institution: Springer Label: Springer number: 12 publisher: Springer International Publishing, v. 195, n. 12, p. 1–31, 1 dez. 2023. Disponível em: <https://link.springer.com/article/10.1007/s10661-023-12001-2>. Acesso em: 6 abr. 2025.

BAUER, P.; THORPE, A.; BRUNET, G. "The quiet revolution of numerical weather prediction. Nature", v. 525, n. 7567, p. 47–55, set. 2015. Disponível em: <https://www.nature.com/articles/nature14956>. Acesso em: 6 abr. 2025.

BOLLA, S.; ANANDAN, R.; T., S. "Weather Forecasting Method from Sensor Transmitted Data for Smart Cities Using IoT". Scientific Programming, v. 2022, n. 1, p. 1426575, 2022. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1155/2022/1426575>. Acesso em: 6 abr. 2025.

CARMO, B. et al. "Cheias na Foz do Rio Sabor: comparação dos perímetros de inundação definidos pelo método hidro-histórico e pela modelação hidráulica (software Iber)". [S.l.: s.n.], 2019.

CHEN, W. et al. "A Coupled River Basin-urban Hydrological Model (DRIVE-Urban) for Real-time Urban Flood Modeling." Water Resources Research, v. 58, 3 nov. 2023.

DUNCAN, James; SUBRAMANIAN, Shashank; HARRINGTON, Peter. "Generative Modeling of High-resolution Global Precipitation Forecasts". Disponível: arXiv. Disponível em: <http://arxiv.org/abs/2210.12504>. Acesso em: 19 abr. 2025.

HOQUE, M. A. et al. "Tropical cyclone disaster management using remote sensing and spatial analysis: A review." International Journal of Disaster Risk Reduction, v. 22, p. 345–354, 1 jun. 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2212420916304794>. Acesso em: 6 abr. 2025.

KASHINATH, K., PRITCHARD, M. (2025). "NVIDIA'S Earth -2: Digital Twins For Weather and Climate" in: HPC - Climate / Weather / Ocean Modeling, 2025, Califórnia, EUA, September 2022/25. Disponível em: <https://www.nvidia.com/en-us/on-demand/session/gtcspring22-s41939/>. Acesso em: 6 abr. 2025.

KILPUA, E. k. j., Lugaz, N., Mays, M. L., & Temmer, M. (2019). Forecasting the Structure and Orientation of Earthbound Coronal Mass Ejections. Space Weather, 17(4), 498–526. Disponível em: <https://doi.org/10.1029/2018SW001944>. Acesso em: 6 abr. 2025.

MOORE, Todd W.; DIXON, Richard W. "Tropical cyclone-tornado casualties." Natural Hazards, Company: Springer Distributor: Springer Institution: Springer Label: Springer number: 2 publisher: Springer Netherlands, v. 61, n. 2, p. 621–634, 1 mar. 2012. Disponível em: <https://link.springer.com/article/10.1007/s11069-011-0050-z>. Acesso em: 5 abr. 2025.

PERKINS, W. A. et al. "Emulation of cloud microphysics in a climate model". [S.d.]. Disponível em: <https://www.authorea.com/users/546010/articles/647643-emulation-of-cloud-microphysics-in-a-climate-model?commit=d9f795cd9357e8a877a02cb991600ca9e2bbc7a3>. Acesso em: 6 abr. 2025.

Pogorelov, N. V., Borovikov, S. N., Kryukov, I. A., Wu, S. T., Yalim, M. S., Colella, P. C., & Van Straalen, B. (2017). "Modeling Coronal Mass Ejections with the Multi-Scale Fluid-Kinetic Simulation Suite". Journal of Physics: Conference Series, 837(1), 012014. Disponível em: <https://doi.org/10.1088/1742-6596/837/1/012014>. Acesso em: 6 abr. 2025.

Price, I., Sanchez-Gonzalez, A., Alet, F., Andersson, T. R., El-Kadi, A., Masters, D., Ewalds, T., Stott, J., Mohamed, S., Battaglia, P., Lam, R., & Willson, M. (2025). "Probabilistic weather forecasting with machine learning". Nature, 637(8044), 84–90. <https://doi.org/10.1038/s41586-024-08252-9>

RAPPAPORT, E. N. "Experimental Potential Storm Surge Flooding Map from Atlantic Tropical Cyclones: New Data and Interpretation." Bulletin of the American Meteorological Society, v. 95, n. 3, p. 341–346, 1 mar. 2014. Disponível em: <https://journals.ametsoc.org/doi/10.1175/BAMS-D-12-00074.1>. Acesso em: 31 jan. 2025.

REPPUCCI, Antonio et al. "Tropical Cyclone Intensity Estimated From Wide-Swath SAR Images".

IEEE Transactions on Geoscience and Remote Sensing, v. 48, n. 4, p. 1639–1649, abr. 2010. Disponível em: <https://ieeexplore.ieee.org/document/5411810>. Acesso em: 6 abr. 2025.

SCHANTZ, M. C. et al. "Evaluating Multimodel Ensemble Seasonal Climate Forecasts on Rangeland Plant Production in the California Annual Grassland". *Rangeland Ecology & Management*, v. 88, p. 135–142, 1 maio 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1550742423000313>. Acesso em: 6 abr. 2025.

SELVAM, A. Panneer; A., Safaa, N. S. "Environmental impact evaluation using smart real-time weather monitoring systems: a systematic review". *Innovative Infrastructure Solutions*, Company: Springer Distributor: Springer Institution: Springer Label: Springer number: 1 publisher: Springer International Publishing, v. 10, n. 1, p. 1–24, 1 jan. 2025. Disponível em: <https://link.springer.com/article/10.1007/s41062-024-01817-7>. Acesso em: 6 abr. 2025.

SOBEL, Adam H. et al. "Tropical Cyclone Frequency". *Earth's Future*, v. 9, n. 12, p. e2021EF002275, 2021. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1029/2021EF002275>. Acesso em: 5 abr. 2025.

Soomro, K., Bhutta, M. N. M., Khan, Z., & Tahir, M. A. (2019). "Smart city big data analytics: An advanced review". *WIREs Data Mining and Knowledge Discovery*, 9(5), e1319. Disponível em: <https://doi.org/10.1002/widm.1319>. Acesso em: 5 abr. 2025.

SOLARES, J. R. A. et al. "Modeling and prediction of global magnetic disturbance in near-Earth space: A case study for Kp index using NARX models". *SPACE WEATHER-THE INTERNATIONAL JOURNAL OF RESEARCH AND APPLICATIONS*, Web of Science ID: WOS:000387802900016, v. 14, n. 10, p. 899–916, out. 2016. Disponível em: <DOI: 10.1002/2016SW001463>. Acesso em: 6 abr. 2025.

TULURI, F. et al. "Environmental Modeling, Technology, and Communication for Land Falling Tropical Cyclone/Hurricane Prediction". *International Journal of Environmental Research and Public Health*, v. 7, n. 5, p. 1937–1952, maio 2010. Disponível em: <https://www.mdpi.com/1660-4601/7/5/1937>. Acesso em: 6 abr. 2025.

VELÁSQUEZ, E. S. G.; ALCÁNTARA, A., I. "Tropical Cyclones in Nicaragua: Historical Impact and Contemporary Exposure to Disaster Risk". *International Journal of Disaster Risk Science*, Company: Springer Distributor: Springer Institution: Springer Label: Springer number: 4 publisher: Springer Nature Singapore, v. 15, n. 4, p. 579–593, 1 ago. 2024. Disponível em: <https://link.springer.com/article/10.1007/s13753-024-00581-7>. Acesso em: 5 abr. 2025.

Wang, Y., Wang, H., Cui, P., Chen, D., Tang, J., Ou, T., Hao, J., Wang, J., Zhang, G., Lei, Y., & Wu, C. (2024). "Disaster effects of climate change and the associated scientific challenges". *CHINESE SCIENCE BULLETIN-CHINESE*, 69(2), 286–300. Disponível em: <https://doi.org/10.1360/TB-2023-0325>. Acesso em: 5 abr. 2025.

YILMAZ, K.; DINÇER, Ali E.; AYHAN, E. N. "Exploring flood and erosion risk indices for optimal solar PV site selection and assessing the influence of topographic resolution". *Renewable Energy*, v. 216, p. 119056, 1 nov. 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148123009709>. Acesso em: 30 out. 2024.