

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS

AVALIAÇÃO DE TÉCNICAS DE MACHINE LEARNING NA ESTIMATIVA DE EVAPOTRANSPIRAÇÃO REAL DIÁRIA

*Eduardo Gonçalves Patriota¹; Cinthia Maria de Abreu Claudino²; José Lindemberg Vidal
Barbosa³; Filipe Carvalho Lemos⁴; Guillaume Francis Bertrand⁵; Cristiano das Neves Almeida⁶;
Victor Hugo Rabelo Coelho⁷*

Abstract: Actual evapotranspiration (ET) is a key process in the hydrological cycle, particularly relevant in tropical regions such as Brazil. The ESTIMET model was developed to provide ET estimates with high spatial and temporal resolution, but it still presents limitations in ecologically complex biomes. This study evaluated the application of three machine learning algorithms (Random Forest, Gradient Boosting, and K-Nearest Neighbours) to improve ESTIMET estimates using remote sensing and climate reanalysis data. Fourteen eddy covariance flux towers distributed across distinct Brazilian biomes were used as reference for observed ET. The models were calibrated using surface temperature, precipitation, soil moisture, and wind speed as input variables. The results showed significant improvements in all evaluated performance metrics (MAE, RMSE, R², and KGE), with RF standing out by achieving an average R² of 0.87 and a KGE of 0.89. Model performance varied across biomes, with greater accuracy in regions with marked seasonality, such as the Cerrado. Overall, machine learning algorithms proved effective in capturing nonlinear interactions and regional ET patterns, emerging as a promising alternative to enhance ET estimates on a large spatial scale.

Resumo: A evapotranspiração real (ET) é um processo chave do ciclo hidrológico, especialmente relevante para regiões tropicais como o Brasil. O modelo ESTIMET foi desenvolvido para gerar estimativas de ET com alta resolução espacial e temporal, porém ainda apresenta limitações em biomas ecologicamente complexos. Este trabalho avaliou a aplicação de três algoritmos de aprendizado de máquina (*Random Forest*, *Gradient Boosting* e *K-Nearest Neighbours*) para aprimorar as estimativas do ESTIMET com base em dados de sensoriamento remoto e reanálise climática. Foram utilizadas 14 torres de fluxo distribuídas por diferentes biomas brasileiros como referência para a ET observada. A calibração dos modelos considerou variáveis como temperatura da superfície, precipitação, umidade do solo e velocidade do vento. Os resultados demonstraram melhorias significativas em todas as métricas avaliadas (MAE, RMSE, R² e KGE), com destaque para o RF, que alcançou um R² médio de 0,87 e KGE de 0,89. A performance variou entre os biomas, com maior acurácia em regiões com forte sazonalidade, como o Cerrado. Os modelos de ML mostraram-se eficazes em capturar interações não lineares e padrões regionais, sendo uma alternativa promissora para o aprimoramento das estimativas de ET em larga escala.

Palavras-Chave – ESTIMET, sensoriamento remoto, reanálise climática.

1) Doutorando em Engenharia Civil e Ambiental, UFPB, Campus João Pessoa, (83) 99655-3877, e-mail: edugoncalvespatriota@gmail.com

2) Doutoranda em Engenharia Civil e Ambiental, UFPB, Campus João Pessoa, (83) 9996189626, cinthiamariaac@gmail.com

3) Doutorando em Engenharia Civil e Ambiental, UFPB, Campus João Pessoa, (83) 99729552, lindembergvidal@gmail.com

4) Doutorando em Engenharia Civil e Ambiental, UFPB, Campus João Pessoa, (83) 99964-3487, filipe_carvalho_1@hotmail.com

5) Prof. Dr. do Departamento de Engenharia Civil e Ambiental, UFPB, Campus João Pessoa; (33)6466578 37, Bourgogne Franche-Comté University, UMR UFC CNRS 6249 Chrono-Environnement, 25200 Montbéliard, France; guillaume353@gmail.com

6) Prof. Dr. do Departamento de Engenharia Civil e Ambiental, UFPB, Campus João Pessoa, (83) 993490880, almeida74br@yahoo.com.br

7) Prof. Dr. do Departamento de Geociências, UFPB, Campus João Pessoa, (83) 988861663, victor.coelho@academico.ufpb.br

INTRODUÇÃO

A evapotranspiração real (ET) é um componente fundamental do ciclo hidrológico, representando a principal via de transferência de água da superfície para a atmosfera (Melo et al., 2021) e que é fundamental para o planejamento hídrico, a modelagem hidrológica e o monitoramento ambiental (Frappart et al., 2019; Ferreira et al., 2024). Entre os métodos disponíveis para quantificar ET, destacam-se as técnicas baseadas em sensoriamento remoto, que permitem a obtenção de estimativas em grande escala espacial e temporal, superando as limitações das medições *in situ* (Claudino et al., 2025). No entanto, produtos globais de ET baseados em sensoriamento remoto, como *Moderate Resolution Imaging Spectroradiometer Global Evapotranspiration Product* (MOD16), *Penman-Monteith-Leuning Evapotranspiration Model* (PML) e *Global Land Evaporation Amsterdam Model* (GLEAM), apresentam limitações em regiões ecologicamente complexas, como a Amazônia e o Cerrado, devido à heterogeneidade da cobertura vegetal e variações microclimáticas (Marengo et al., 2018).

Visando reduzir essas incertezas, o modelo ESTIMET (*Evaluation and Spatial-Temporal Improvement of MODIS EvapoTranspiration*) foi desenvolvido para melhorar a resolução espacial e temporal das estimativas de ET no Brasil, alcançando 250 m de resolução espacial e periodicidade diária (Claudino et al., 2025). Embora o ESTIMET apresente desempenho superior em relação aos modelos globais, divergências ainda são observadas em biomas tropicais complexos, indicando a necessidade de aperfeiçoamentos e maior acurácia das estimativas (Claudino et al., 2025).

Um dos principais desafios encontrados na modelagem da ET em escala regional é a captura das interações não lineares entre variáveis atmosféricas e de superfície, que são influenciadas por mudanças sazonais, eventos extremos e variações microclimáticas (Andrade et al., 2021; Chen et al., 2020). Nesse cenário, técnicas de *machine learning* (ML) emergem como ferramentas promissoras para superar essas limitações, permitindo o aprendizado de padrões complexos e a modelagem de processos hidrológicos com maior precisão (Mirmazloumi et al., 2024; Tripathy et al., 2024). Modelos de ML demonstram elevada capacidade de generalização em cenários hidrológicos diversos, otimizando a integração de dados provenientes de reanálises climáticas e sensoriamento remoto (Li et al., 2024; Santos et al., 2022). Dentre os algoritmos mais promissores para a estimativa de ET destacam-se o *Random Forest* (RF), o *Gradient Boosting* (GB) e o *K-Nearest Neighbors* (KNN), amplamente utilizados pela sua robustez e capacidade de lidar com variáveis heterogêneas e complexas. Esses algoritmos são capazes de explorar múltiplos preditores simultaneamente,

identificando relações não lineares que tradicionalmente escapam aos métodos convencionais de modelagem.

Assim, este trabalho propõe avaliar diferentes modelos de ML na melhoria das estimativas de ET do algoritmo ESTIMET. A calibração foi realizada com dados de reanálise climática e sensoriamento remoto e a avaliação dos resultados foi com o auxílio da ET proveniente de torres de fluxo. Espera-se que essa abordagem resulte em estimativas mais acuradas e representativas, contribuindo para o monitoramento de recursos hídricos, práticas agrícolas e planejamento ambiental em um contexto de mudanças climáticas e intensificação do uso do solo.

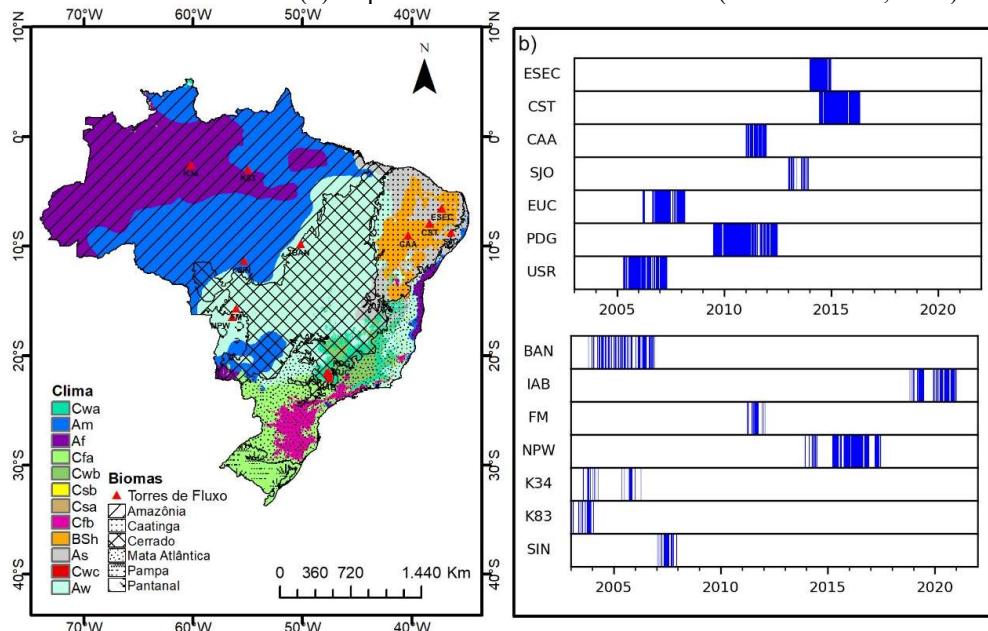
METODOLOGIA

Área de estudo e torres de fluxo

A área de estudo comprehende todo o território brasileiro (Figura 1), que se estende por aproximadamente 8,5 milhões de km², entre as latitudes 5°16'N e 33°45'S. O Brasil é dividido em seis biomas principais: Amazônia, Cerrado, Mata Atlântica, Caatinga, Pantanal e Pampa, que apresentam condições ecológicas e climáticas distintas (Roesch et al., 2009). A Amazônia ocupa cerca de 49% do território nacional, seguida pelo Cerrado com 24%, Mata Atlântica com 13%, Caatinga com 10%, e os biomas Pantanal e Pampa, cada um com aproximadamente 2% da área total (Roesch et al., 2009). Esses biomas variam significativamente em termos de disponibilidade hídrica, indo de regiões com abundância de água, como a Amazônia, até áreas de grande escassez, como a Caatinga. Devido à sua extensão continental, o Brasil apresenta uma ampla variação climática, classificada em doze tipos climáticos de acordo com Köppen, agrupados em três zonas principais: Tropical (A), Semiárido (B) e Subtropical Úmido (C) (Alvares et al., 2013). Essas zonas englobam variações significativas de temperatura e precipitação, com médias anuais de temperatura entre 10°C e 26°C e precipitações que variam de 380 mm a 4000 mm anuais (Gadelha et al., 2019).

Para a presente análise, foram consideradas 14 torres de fluxo (*Eddy Covariance*) como fonte para os dados de referência da ET real diária, localizadas na Figura 1a, com disponibilidade de dados apresentada na Figura 1b. Esses pontos de coleta são utilizados para a validação das estimativas do modelo ESTIMET (Claudino et al., 2025) e foram empregados para avaliar os ganhos de acurácia promovidos pela aplicação dos modelos de ML.

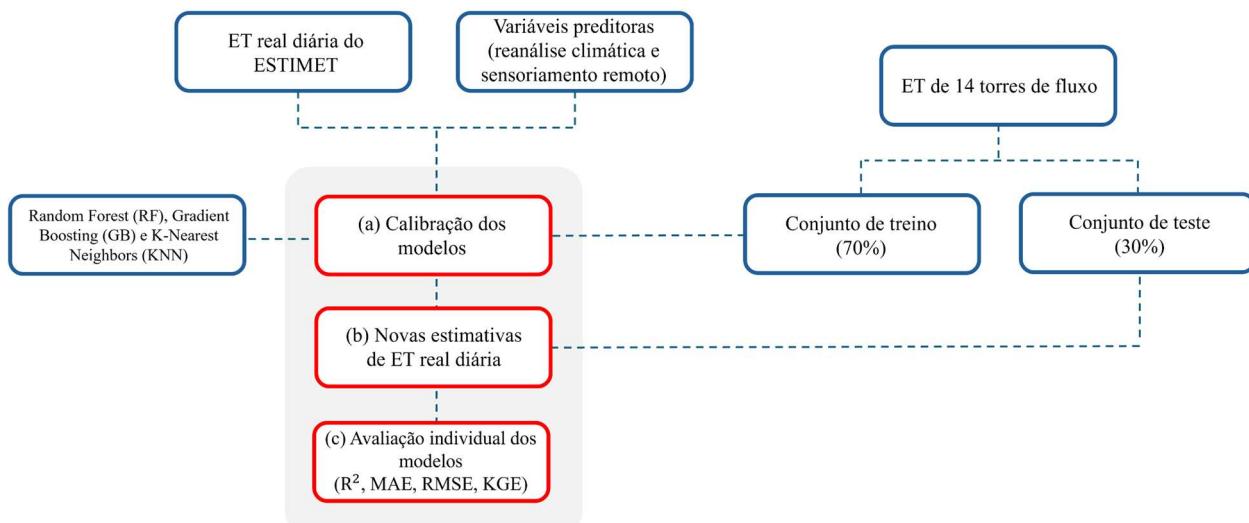
Figura 1 – (a) Biomas brasileiros e classificação climática do Brasil (Alvares et al., 2013) apresentando a localização das 14 torres de fluxo e (b) disponibilidade de dados das torres (Claudino et al., 2025).



Dados e processamento

A metodologia empregada neste estudo se organiza em três passos principais (Figura 2): (a) Calibração dos modelos de ML com dados de reanálise climática e dados da superfície terrestre; (b) Obtenção das novas estimativas de ET a partir de cada um dos modelos; (c) avaliação das melhorias obtidas em comparação aos resultados originais do modelo ESTIMET.

Figura 2 – Metodologia empregada para melhoria de estimativa da ET com técnicas de ML



A calibração dos modelos de ML foi efetuada com o emprego de variáveis preditoras que correspondem a um conjunto de dados de reanálise climática e sensoriamento remoto. Esse conjunto

de variáveis, inclui parâmetros que não estavam diretamente envolvidos na metodologia de Claudino et al. (2025) para estimativa de ET. Assim, dados como temperatura do ar, radiação solar, pressão atmosférica e umidade relativa foram variáveis desconsideradas na presente análise. Escolheu-se esse caminho a fim de se aumentar o desempenho preditivo dos modelos e reduzir vieses existentes nas estimativas originais. As variáveis preditoras empregadas, acessadas através da plataforma Google Earth Engine (GEE), se encontram descritas na Tabela 1:

Tabela 1 – Dados e variáveis utilizadas

Variável preditora	Unidade	Produto/ Fonte	Resolução espacial	Resolução temporal	Cobertura temporal
Temperatura de superfície (LST)	°C	MOD11A2 MYD11A2	1 Km	1 dia	2000-atual
Velocidade do vento (W)	m/s	ERA5-Land	11.13 Km	1 h	1950- atual
Precipitação (P)	mm	ERA5-Land	10 Km	1 dia	2000- atual
Umidade do solo (0-10 cm)	%	GLDAS 2.1	27.83 Km	3 h	2000- atual
Umidade do solo (40-100 cm)	%	GLDAS 2.1	27.83 Km	3 h	2000- atual

Para a melhoria das estimativas de ET obtidas pelo modelo ESTIMET, foram selecionados três algoritmos baseados em regressão: Random Forest (RF), Gradient Boosting (GB) e K-Nearest Neighbors (KNN). A escolha desses modelos fundamenta-se em seu desempenho consolidado na modelagem de processos hidrológicos complexos e na estimativa precisa de fluxos evapotranspirativos em distintos cenários ambientais (Mirmazloumi et al., 2024; Li et al., 2024; Santos et al., 2022).

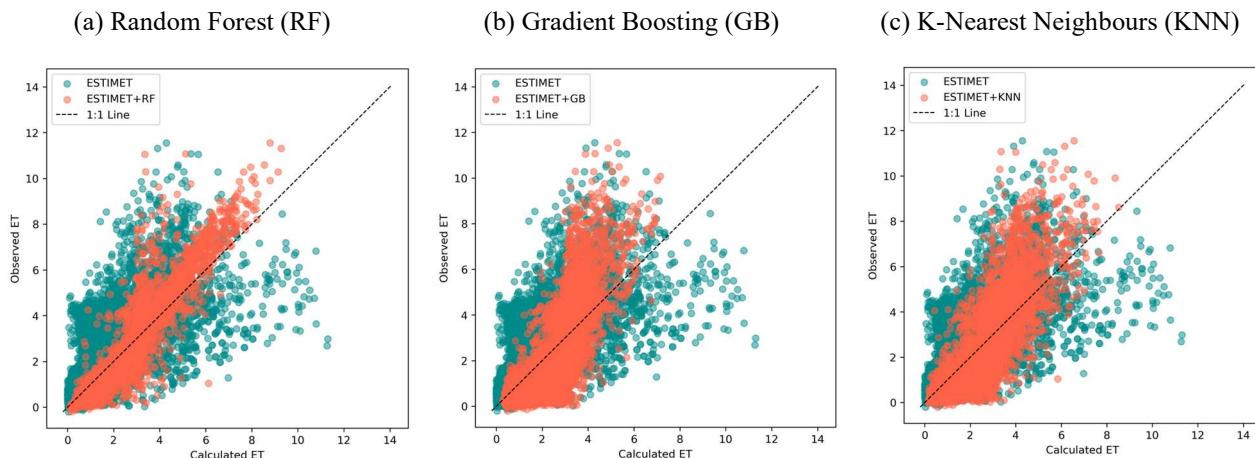
A etapa de calibração dos modelos foi realizada a partir dos dados diários de ET das 14 torres de fluxo. O conjunto de dados foi estratificado em 70% para treinamento e 30% para teste, visando garantir a robustez estatística das validações. Durante a fase de treinamento, os algoritmos aprenderam as relações entre as variáveis preditoras (Tabela 1) e as estimativas originais de ET fornecidas pelo ESTIMET. Posteriormente, a fase de teste foi empregada para validação independente dos modelos, assegurando uma avaliação confiável de sua capacidade de generalização e de predição em condições não observadas.

A fim de quantificar e avaliar as melhorias alcançadas por meio da previsão de novas séries temporais de ET geradas por cada modelo individualmente, as seguintes métricas de desempenho estatístico foram quantificadas: o coeficiente de determinação (R^2), erro absoluto médio (MAE), erro quadrático médio (RMSE) e a Eficiência de Kling-Gupta (KGE).

RESULTADOS E DISCUSSÃO

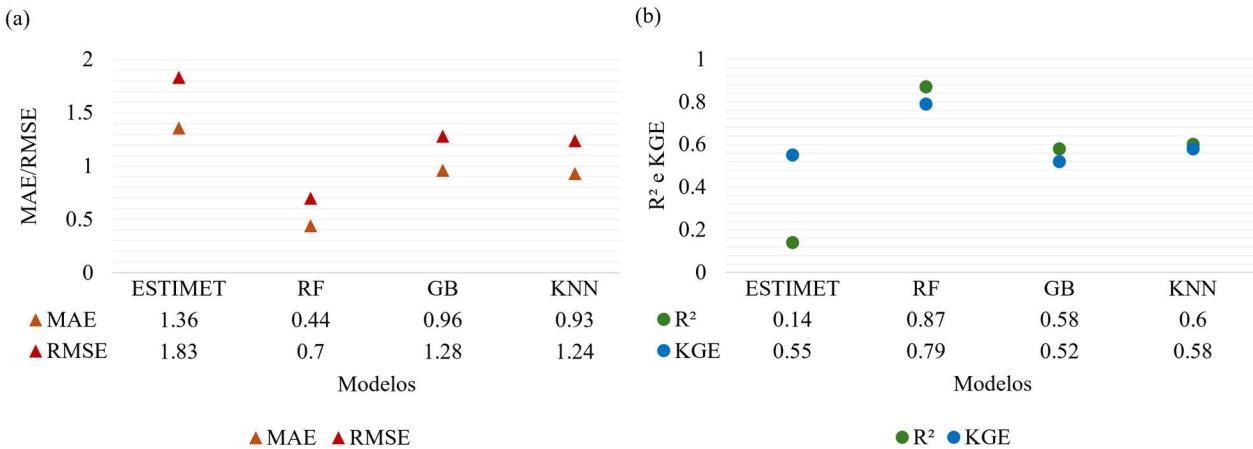
A aplicação de algoritmos às estimativas do modelo ESTIMET resultou em melhorias expressivas na acurácia da evapotranspiração real (ET) diária em múltiplos locais. Os modelos apresentaram, em diferentes graus, capacidade de capturar padrões não lineares e regionais complexos da ET não modelados pelo ESTIMET, como pode ser observado na Figura 3, na qual os *scatterplots* obtidos para cada um dos modelos indicam um aumento na acurácia dos resultados de ET, com os quais os valores estimados (eixo x) aproximaram-se ainda mais dos dados de referência (eixo y).

Figura 3 – *Scatterplots* de comparação entre dados estimados (ESTIMET e modelos de *machine learning* no eixo x) e de referência (no eixo y) para todas as torres utilizadas



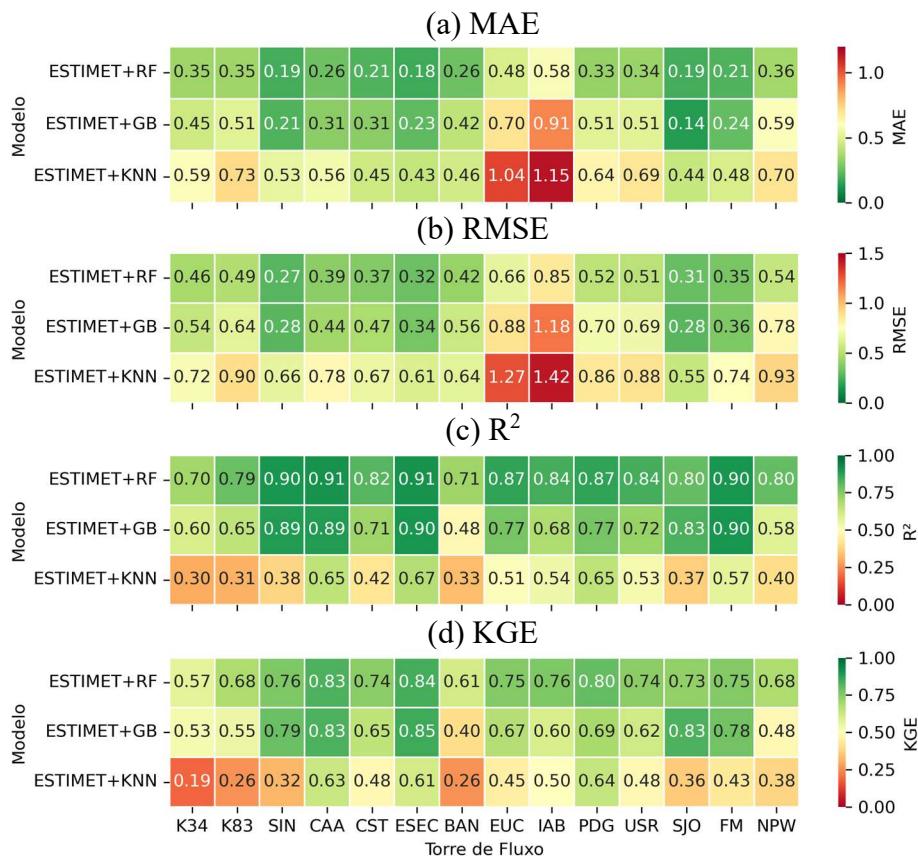
Tal cenário também foi observado através das métricas estatísticas quantificadas (Figura 4). Segundo a Figura 4(a), os três algoritmos reduziram de maneira significativa os erros presentes no ESTIMET (MAE e RMSE), com as maiores reduções realizadas pelo RF que diminuiu o MAE de 1,36 mm/dia para 0,44 mm/dia e o RMSE de 1,83 mm/dia para 0,70 mm/dia, que corresponderam a reduções de 32,35 % e 38,25 %, respectivamente. Além disso, a Figura 4(b) também corrobora para a superioridade global do modelo RF em comparação ao GB e o KNN, na qual o modelo apresentou um $R^2 = 0.87$ e $KGE = 0.89$, valores esses que foram ampliados em comparação aos valores originais do ESTIMET.

Figura 4 – Métricas estatísticas obtidas para a ET com o ESTIMET e ET com os modelos aplicados: Random Forest (RF), Gradient Boosting (GB) e K-Nearest Neighbours (KNN)



Como observado na Figura 5, essas métricas também indicaram padrões distintos entre as diferentes torres de fluxo utilizadas, com os maiores erros (MAE e RMSE) encontrados na torre IAB (MAE = 1,15 mm/dia; RMSE = 1,42 mm/dia) para o KNN. Já a maior aproximação foi gerada na torre ESEC (MAE = 0,18 mm/dia; RMSE = 0,32 mm/dia) para o RF.

Figura 5 –Métricas estatísticas (MAE, RMSE, R² e KGE) para cada uma das torres de fluxo utilizadas



O desempenho diferenciado entre os algoritmos pode ser explicado por suas características estruturais e capacidades de modelagem. O RF, por ser um modelo baseado em uma grande quantidade de árvores de decisão com amostragem aleatória dos dados e das variáveis (Jain e Gupta, 2024; Granata et al., 2020), apresenta alta robustez frente a ruídos e correlações ilegítimas, sendo capaz de capturar interações complexas e não lineares entre as variáveis preditoras (Biljwan et al., 2024; Bai et al., 2021). Isso o torna especialmente eficaz em contextos com elevada heterogeneidade espacial e temporal (Zhang et al., 2024), como os encontrados entre os diferentes biomas brasileiros. O GB, embora também baseado em árvores de decisão, realiza o treinamento de forma sequencial, ajustando os erros do modelo anterior a cada iteração (Liu et al., 2021). Essa abordagem permite melhor refinamento em alguns cenários, mas pode torná-lo mais sensível a *outliers* e ao sobreajuste em regiões com menos representatividade nos dados de treinamento (Stoffer et al., 2024). Já o KNN, apesar de sua simplicidade e baixo custo computacional (Jain e Gupta, 2024), depende fortemente da distribuição espacial dos dados e tende a apresentar desempenho inferior em regiões com elevada variabilidade ou baixa densidade amostral (Liu et al., 2021), como observado na torre IAB.

A escolha pelas variáveis utilizadas se mostrou eficaz, uma vez que os 3 modelos apresentaram melhorias na ET original. Tanto a LST, como a velocidade do vento, precipitação e umidade do solo (superficial e profunda) desempenham papéis importantes na dinâmica da ET. Tais parâmetros possuem influência na variação térmica superficial (LST; Dai et al., 2024), disponibilidade hídrica (Precipitação; Zhang et al., 2017), capacidade de extração hídrica do solo pela vegetação (Umidade do solo; Chen et al., 2008) e perda de água por transporte (Velocidade do vento; Miralles et al., 2011). Tais influências não são captadas no algoritmo original do ESTIMET, demonstrando assim que os modelos aqui analisados se apresentam como alternativas eficazes de complementação das estimativas de ET.

CONCLUSÃO

Diante dos aspectos apresentados, conclui-se que as técnicas de ML apresentaram grande potencial em complementar e refinar as estimativas de ET fornecidas pelo modelo ESTIMET. A aplicação dos algoritmos RF, GB e KNN resultou em ganhos expressivos de desempenho estatístico, com superioridade encontrada no RF, que apresentou as menores taxas de erro e os maiores coeficientes de determinação e eficiência. Esses resultados evidenciam a capacidade desses modelos em capturar relações complexas entre as variáveis climáticas e de superfície, especialmente em um território ecologicamente diverso como o Brasil.

As variáveis selecionadas mostraram-se apropriadas para representar os principais controles da ET, e sua utilização em modelos capazes de explorar interações não lineares revelou-se eficaz para modelagem em diferentes biomas. A integração de dados de sensoriamento remoto orbital, reanálise climática e ML representa uma abordagem promissora para o monitoramento hidrológico. Estudos futuros podem desenvolver novos treinamentos através desses modelos, realizando testes de sensibilidade através da retirada e troca de covariáveis relacionadas a ET, bem como criar meta-modelos que refinem ainda mais a acurácia da estimativa da ET.

Espera-se que esses avanços contribuam significativamente para aplicações em gestão hídrica, agricultura e monitoramento ambiental, especialmente diante dos desafios impostos pelas mudanças climáticas e pelo uso intensivo do solo no país.

REFERÊNCIAS

- BAI, Y., ZHANG, S., BHATTARAI, N., MALLICK, K., LIU, Q., TANG, L., ZHANG, J. (2021). *“On the use of machine learning based ensemble approaches to improve evapotranspiration estimates from croplands across a wide environmental gradient”*. Agricultural and Forest Meteorology, 298, 108308.
- BIJLWAN, A., POKHRIYAL, S., RANJAN, R., SINGH, R., & JHA, A. K. (2024). *“Machine learning methods for estimating reference evapotranspiration”*. Journal of Agrometeorology, 26(1), 63–68.
- CHEN, X., RUBIN, Y., MA, S., & BALDOCCHI, D. D. (2008). *“Observations and stochastic modeling of soil moisture control on evapotranspiration in a Californian oak savanna”*. Water Resources Research, 44(8).
- CLAUDINO, C. M. DE A.; BERTRAND, G. F.; ALMEIDA, C. DAS N.; GUSMÃO, A. C. V.; PATRIOTA, E. G.; LEMOS, F. C.; COUTINHO, J. V.; SOUSA, J. W. G. DE; MELO, D. C. D.; SILVA, B. B.; RODRIGUES, D. F. B.; OLIVEIRA, L. M.; XUAN, Y.; MOURA, M. S. B. DE, MONTENEGRO, A. A. A.; MONTENEGRO, S. M.G. L., NÓBREGA, R. L.B; BROCCA, L.; CORBARI, C.; JIN, Y.; SUVOČAREV, K.; BEZERRA, B.; LIMA, J. R. DE S.; SOUZA, E.; COELHO, V. H. R. *“ESTIMET: Enhanced and Spatial-Temporal Improvement of MODIS EvapoTranspiration algorithm for all sky conditions in tropical biomes”*. Remote Sensing of Environment, 325, 114771.
- DAI, Y., LÜ, F., LIU, J., & BEN-QING, R. (2024). *“Estimation of actual evapotranspiration from different ecosystems on the Tibetan Plateau based on a generalized complementary evapotranspiration theory model”*. Ecohydrology, 17(3).
- FERREIRA, VAGNER G.; YANG, HAO; NDEHEDEHE, C.; WANG, H.; GE, Y.; XU, J.; XIA, KALU, I.; JING, M.; AGUTU, N. *“Estimating groundwater recharge across Africa during 2003-2023 34 using GRACE-derived groundwater storage changes”*. Journal of Hydrology: Regional Studies, 56, 102046, 2024.
- FRAPPART, F.; PAPA, F.; GÜNTNER, A.; TOMASELLA, J.; PFEFFER, J.; RAMILLIEN, G.; EMILIO, T.; SCHIETTI, J.; SEOANE, L.; CARVALHO, J. S.; MOREIRA, D. M.; BONNET, M.

P.; SEYLER, F. "The spatio-temporal variability of groundwater storage in the Amazon River Basin". *Advances in Water Resources*, v. 124, p. 41–52, 2019.

GRANATA, F., GARGANO, R., & DE MARINIS, G. (2020). "Artificial intelligence based approaches to evaluate actual evapotranspiration in wetlands". *Science of The Total Environment*, 703, 135653.

JAIN, S. K., & GUPTA, A. K. (2024). "Modeling and Estimation of Reference Evapotranspiration using Machine Learning Algorithms: A Comparative Performance Analysis". *Current Agriculture Research Journal*, 12(1).

LIU, Y., ZHANG, S., ZHANG, J., TANG, L., & BAI, Y. (2021). "Assessment and Comparison of Six Machine Learning Models in Estimating Evapotranspiration over Croplands Using Remote Sensing and Meteorological Factors". *Remote Sensing*, 13(19), 3838.

LIU, Y., ZHANG, S., ZHANG, J., TANG, L., BAI, Y. (2021). "Assessment and comparison of six machine learning models in estimating evapotranspiration over croplands using remote sensing and meteorological factors". *Remote Sensing*, 13(19), 3838.

MARENGO, J. A., SOUZA, C., THONICKE, K., BURTON, C., HALLADAY, K., BETTS, R., ALVES, L. M., & SOARES, W. R. (2018). "Changes in Climate and Land Use Over the Amazon Region: Current and Future Variability and Trends". *Frontiers in Earth Science*, 6, 228.

MELO, D. C. D.; ANACHE, J. A. A.; ALMEIDA, C. das N.; COUTINHO, J. V.; RAMOS FILHO, G. M.; ROSALEM, L. M. P.; PELINSON, N. S.; FERREIRA, G. L. R. A.; SCHWAMBACK, D.; CALIXTO, K. G.; SIQUEIRA, J. P. G.; DUARTE-CARVAJALINO, J. C.; JHUNIOR, H. C. S.; NÓBREGA, J. D.; MORITA, A. K. M.; LEITE, C. M. C.; GUEDES, A. C. E.; COELHO, V. H. R.; WENDLAND, E. "The big picture of field hydrology studies in Brazil". *Hydrological Science Journal*, v. 65, p. 1262–1280, 2021.

MIRALLES, D. G., DE JEU, R. A. M., GASH, J. H. C., HOLMES, T. R. H., HOLMES, T. R. H., & DOLMAN, A. J. (2011). "Magnitude and variability of land evaporation and its components at the global scale". *Hydrology and Earth System Sciences*, 15(3), 967–981.

MIRMAZLOUMI, S. M., NOURI, H., ABBASI, N., CHUKALLA, A. D., KIPKULEI, H. K., & GHAZARYAN, G. "Enhancing Evapotranspiration Estimates by Integrating Sentinel-3 LST and Sentinel-2 Data Through Machine Learning-Based Downscaling". 56, 2464–2468. 2024.

STOFFER, R., HARTOGENESIS, O., RODRÍGUEZ, J. C., VAN HEERWAARDEN, C. (2024). "Machine-learned actual evapotranspiration for an irrigated pecan orchard in Northwest Mexico". *Agricultural and Forest Meteorology*, 345, 109825.

TRIPATHY, S. C., & RAMADAS, M. "Data Fusion of Regional Reanalysis and Sentinel (Earth Observation) based Products with Machine Learning Tools for Monitoring Evapotranspiration and Drought". EGU General Assembly 2024, Vienna, Austria, 14–19 Apr 2024, EGU24-15184.

ZHANG, Y., CHIEW, F. H. S., PEÑA-ARANCIBIA, J. L., SUN, F., LI, H., & LEUNING, R. (2017). "Global variation of transpiration and soil evaporation and the role of their major climate drivers". *Journal of Geophysical Research*, 122(13), 6868–6881.

ZHANG, Y., HE, T. (2024). "Upscaling terrestrial Evapotranspiration: A framework based on a spatial heterogeneity model and machine learning algorithms" in EGU General Assembly 2024, Vienna, Austria, 14–19 Apr 2024, EGU24-9374.