



# I CONGRESSO PERNAMBUCANO DE RECURSOS HÍDRICOS

Água para o Desenvolvimento  
Recife, 24, 25 e 26 de Março de 2026

## USO DE TÉCNICAS DE MACHINE LEARNING NA ESTIMATIVA DE EVAPOTRANSPIRAÇÃO EM CENÁRIOS ATUAIS E FUTUROS

*Ana Patrícia Gomes Silva<sup>1</sup> ; Rebecca Borja Gonçalves Gomes de Menezes<sup>2</sup>; Débora Rodrigues Soares<sup>3</sup>; Alfredo Ribeiro Neto<sup>4</sup>; João Maria de Andrade<sup>5</sup> & Leidjane Maria Maciel de Oliveira<sup>6</sup>*

**Palavras-chave:** Evapotranspiração de referência, MIROC6, CMIP6, mudanças climáticas, Semiárido.

### INTRODUÇÃO

A evapotranspiração (ET) é um componente fundamental do ciclo hidrológico, exercendo papel central no balanço de energia e na disponibilidade hídrica em ambientes naturais e agrícolas (Tang *et al.*, 2024). Em regiões semiáridas, como o Nordeste Brasileiro (NEB), sua variabilidade está fortemente relacionada às condições atmosféricas e ao regime de chuvas, sendo um indicador relevante para o planejamento hídrico e o manejo agrícola. Contudo, a escassez de séries meteorológicas completas limita a aplicação de métodos tradicionais, como o Penman–Monteith (FAO-56), que requer dados de radiação, vento, temperatura e umidade (Wu *et al.*, 2021; Acharki *et al.*, 2025). Nesse contexto, métodos alternativos capazes de operar com conjuntos reduzidos de variáveis tornam-se necessários e eficientes para manter desempenho estatístico satisfatório.

No contexto brasileiro, a necessidade de aprimorar a estimativa da evapotranspiração de referência (ET<sub>o</sub>) é particularmente relevante na bacia do riacho do Pontal (UP15), localizada no Sertão pernambucano, região Semiárida, com baixos índices pluviométricos, elevadas taxas anuais de evapotranspiração (2300–2400 mm) e forte dependência da agricultura irrigada, fatores esses que reforçam a vulnerabilidade frente às mudanças climáticas (Silva *et al.*, 2023). Assim, métodos baseados em Machine Learning (ML) constituem alternativas estratégicas para melhorar o diagnóstico e a previsão da ET<sub>o</sub>.

O presente estudo tem como objetivo avaliar o desempenho de diferentes modelos de machine learning na estimativa da ET<sub>o</sub> sob condições atuais e futuras na UP15. Também são analisados cenários climáticos de médio prazo (2035–2044) provenientes do modelo MIROC6 (CMIP6), considerando os caminhos SSP245 e SSP585, cenários intermediários e pessimista, respectivamente, de modo a compreender como potenciais

---

<sup>1</sup>) Doutoranda do Programa de Pós-Graduação em Engenharia Civil – PPGEC, Universidade Federal de Pernambuco – UFPE, Recife – PE - Brasil, ana.apgs@ufpe.br.

<sup>2</sup>) Doutoranda do PPGE, UFPE, Recife – PE - Brasil, rebecca.borja@ufpe.br.

<sup>3</sup>) Doutoranda do PPGE, UFPE, Recife – PE - Brasil, debora.rsoares@ufpe.br.

<sup>4</sup>) Professor Titular do DECIV / PPGE / UFPE, Recife – PE - Brasil, alfredo.ribeiro@ufpe.br.

<sup>5</sup>) Professor da Universidade Federal Rural de Pernambuco (UFRPE/UABJ), joao.jma@ufpe.br.

<sup>6</sup>) Professora Adjunta do DECIV / PPGE / UFPE, Recife – PE - Brasil, leidjane.oliveira@ufpe.br.

alterações na temperatura, umidade, precipitação e radiação poderão modificar as dinâmicas de ETo na região.

## METODOLOGIA

O estudo concentrou-se na UP15, que corresponde a bacia do riacho do Pontal, com nascente no município de Afrânio e exutório no rio São Francisco, área de 6.015,33 Km<sup>2</sup>, equivalente a 6,12% da área do Estado de Pernambuco (APAC, 2025).

A aquisição dos dados observados foi realizada na base Brazilian Daily Weather Gridded Data (BR DWGD) em (Xavier *et al.*, 2022). A estimativa de ETo para cenários futuros foi com base em dados da sexta versão do modelo Model for Interdisciplinary Research on Climate (MIROC), desenvolvido por uma comunidade japonesa de modelagem (Tatebe *et al.*, 2019).

Os modelos de ML utilizados foram: Regressão Linear Múltipla, Random Forest, K-Nearest Neighbors (KNN) e Artificial Neural Networks (ANN). Nesse estudo, os modelos foram aplicados sobre combinações baseadas nas variáveis preditoras obtidas do BR-DWGD (Tabela 1), para analisar a influência de cada variável na estimativa da ETo. Em um segundo momento, os dados do MIROC6 são aplicados em cada modelo para estimar a ETo futura nos dois cenários definidos. Nas duas etapas, a série de dados foi dividida em 70% para treino e 30% para teste.

Tabela 1 - Combinações das variáveis preditoras da ETo.

| Combinação | Variáveis                  |
|------------|----------------------------|
| C1         | pr, RH, Rs, Tmax, Tmin, u2 |
| C2         | pr, RH, Rs, Tmax, Tmin     |
| C3         | pr, Tmax, Tmin             |
| C4         | RH, Rs, Tmax, Tmin         |
| C5         | RH, Rs, Tmax, Tmin, u2     |
| C6         | Tmax, Tmin                 |

Em que: pr = precipitação; RH = umidade relativa; Rs = radiação solar; Tmax = temperatura máxima; Tmin = temperatura mínima; u2 = velocidade do vento

A avaliação dos modelos de ML foi realizada através do uso de três métricas: coeficiente de determinação ( $R^2$ ), raiz do erro quadrático médio (RMSE) e erro médio absoluto (MAE).


## RESULTADOS

O resultado das métricas obtidas para modelos ANN, KNN, MLR e RF, considerando as seis combinações das variáveis preditoras estão presentes na Figura 1. Nota-se que, para todos os modelos, os menores valores de MAE foram obtidos para as combinações C1 e C5, apresentando valor abaixo 0,2 mm/dia, e os maiores para as combinações C3 e C6, com erro acima de 0,6 mm/dia. O RMSE obteve comportamento semelhante ao MAE, com menores valores abaixo de 0,2 mm/dia e maiores acima de 0,8 mm/dia para as combinações. As mesmas combinações apresentaram  $R^2$  próximo a 1 para todos os modelos. Acharki *et al.* (2025) realizaram combinações das mesmas variáveis preditoras utilizadas nesse estudo, exceto a precipitação. Os Autores identificaram que a combinação composta por Rs, RH, Tmax, Tmin, e u2 possui o melhor desempenho, e a combinação de Tmax, Tmin e RH o menor desempenho.

As combinações indicaram que a retirada da velocidade do vento (u2) e da radiação solar (Rs) diminuíram a precisão dos modelos, portanto essas variáveis são as mais influentes na variabilidade da ETo na UP15. Além disso, a precipitação (pr) não gerou diferenças significativas entre as combinações C1-C5 e C2-C4. Elbeltagi *et al.* (2025)


identificaram as variáveis Tmax, Tmin e pr como as mais influentes na estimativa da ETo em regiões da China. Portanto, o desempenho dos modelos pode variar em função da área de estudo devido a influência que cada variável exerce sobre a região.

Figura 1 - Resultados das métricas MAE, RMSE e R<sup>2</sup> para seis combinações de variáveis climáticas utilizadas para estimar a ETo por: A) Regressão linear múltipla (MLR), B) Random Forest (RF), C) Regressão K-Vizinhos mais próximos (KNN), D) Rede neural artificial (ANN).



A estimativa da ETo através dos quatro modelos para os cenários futuros ssp245 e ssp585 estão representados na Figura 2A e 2B, respectivamente.

Figura 2 - Estimativa da ETo para cenários futuros do MIRO6: A) ssp245, B) ssp585.



Os totais mensais médios futuros de 2035 a 2044 foram comparados com o total médio mensal dos dados observados do período de 1961 a 2024. Nota-se que as diferenças

entre os cenários não foram significativas, com ambos apresentando comportamento e valores semelhantes. O ssp245 (Figura 2A) apresentou valores acima dos dados observados só para os meses de junho a outubro, período que possivelmente tenha baixo regime pluviométrico e maior radiação incidindo na UP15. A ETo do cenário ssp585 apresentou menores valores no mês de março e maiores em abril quando comparado com o ssp245. Ganjei, Shiri e Karimi (2025) identificaram maior tendência de aumento da ETo no cenário ssp585, principalmente nos meses de junho, julho e agosto, cuja alteração pode aumentar o estresse hídrico das vegetações agrícolas.

## CONCLUSÕES

Os resultados indicam que técnicas de ML apresenta alto desempenho na estimativa da ETo na UP15, com destaque para a rede neural artificial, seguida por Random Forest, KNN e regressão linear múltipla, sendo a precisão fortemente influenciada por variáveis associadas ao balanço energético e ao movimento do ar, especialmente radiação solar e velocidade do vento. As projeções futuras apontam tendência de aumento da ETo entre junho e outubro, período seco da região, sugerindo intensificação da demanda evaporativa em um cenário climático mais quente e seco, enquanto nos meses chuvosos observou-se redução em relação à média histórica.

## REFERÊNCIAS

- ACHARKI, S. et al. Comparative assessment of empirical and hybrid machine learning models for estimating daily reference evapotranspiration in sub-humid and semi-arid climates. *Sci Rep*, 15, 2542, 2025.
- APAC. Agência Pernambucana de Águas e Clima. Bacia do Riacho Pontal. APAC, 2025. Disponível em: <https://www.apac.pe.gov.br/bacias-hidrograficas-riacho-pontal/170-bacias-hidrograficas-riacho-pontal/211-bacia-do-riacho-pontal>. Acesso em: 06 dez 2025.
- ELBELTAGI, A. et al. Bayesian-optimized machine learning boosts actual evapotranspiration prediction in water-stressed agricultural regions of China. *Sci Rep*, 15, 37548, 2025.
- GANJEI, S.; SHIRI, J.; KARIMI, S., 2025. Evaluating climate change impacts on reference evapotranspiration using CMIP6 projections and machine learning in the Aras River Basin. *Model. Earth Syst. Environ.* 12, 3, 2025.
- SILVA, L. A. P. et al. Mapping the effects of climate change on reference evapotranspiration in future scenarios in the Brazilian Semiarid Region - South America. *Revista Brasileira de Geografia Física*, 16(2), 1001–1012. 2023.
- TANG, R. et al. Spatial-temporal patterns of land surface evapotranspiration from global products. *Remote Sensing of Environment*, v. 304, p. 114066, 2024.
- TATEBE, H. et al. Description and basic evaluation of simulated mean state, internal variability, and climate sensitivity in MIROC6. *Geosci. Model Dev.*, 12, 2727–2765. 2019.
- WU, Y. et al. Global observations and CMIP6 simulations of compound extremes of monthly temperature and precipitation. *GeoHealth*, v. 5, (5), e2021GH000390. 2021.
- XAVIER, A. C., SCANLON, B. R., KING, C. W., ALVES, A. I. New Improved Brazilian Daily Weather Gridded Data (1961-2020). *Int. J. Climatol.* 2022.