

Artigo

Estimativa da Evapotranspiração com Redes Neurais Artificiais e Dados Espectrais: Aplicação em uma Unidade de Conservação

Liliane Moreira Nery¹ , Gabriela Gomes¹ , Nicholas de Paula Nicomedes¹ ,
Luis Armando de Oro Arenas¹ , Darllan Collins da Cunha e Silva¹ 

¹*Universidade Estadual Paulista “Júlio de Mesquita Filho”, Instituto de Ciência e Tecnologia, Sorocaba, Brasil.*

Recebido em: 18 de Janeiro de 2025 - Aceito em: 1 de Julho de 2025

Resumo

O mapeamento e a análise espacial das mudanças no uso e cobertura da terra (UCT) são essenciais para monitorar dinâmicas ambientais e gerir recursos hídricos. Estudos que avaliam a evapotranspiração (ET) considerando alterações no UCT ajudam a quantificar os impactos antrópicos no ciclo hidrológico. Redes Neurais Artificiais (RNA) têm sido usadas para estimar a ET, mas dependem de séries meteorológicas. Portanto, o objetivo deste estudo é estimar a ET real utilizando uma RNA *Multilayer Perceptron* (RNA-MLP), para a Área de Proteção Ambiental de Itupararanga, região de importância hídrica para a Região Metropolitana de Sorocaba, utilizando dados de UCT e bandas espectrais do satélite Landsat. A ET de 2021 foi calculada com o algoritmo SEBAL e utilizada como base para treinamento e classificação supervisionada no modelo RNA-MLP do software TerrSet. As estimativas da RNA foram avaliadas com critérios do TerrSet, destacando diferenças visuais que indicam a necessidade de ajustes nos parâmetros do MLP para maior aproximação das estimativas do SEBAL, previamente validadas. Esta abordagem inovadora complementa o uso de RNA na modelagem da ET, oferecendo novas perspectivas para a análise de dinâmicas ambientais.

Palavras-chave: APA de Itupararanga, Represa de Itupararanga, *machine learning*, sensoriamento remoto.

Estimation of Evapotranspiration Using Artificial Neural Networks and Spectral Data: Application in a Protected Area

Abstract

The mapping and spatial analysis of land use and land cover (LULC) changes are essential for monitoring environmental dynamics and managing water resources. Studies that evaluate evapotranspiration (ET) considering LULC changes help quantify the anthropogenic impacts on the hydrological cycle. Artificial Neural Networks (ANN) have been used to estimate ET but rely on meteorological data series. Therefore, the objective of this study is to estimate actual ET using a Multilayer Perceptron Artificial Neural Network (MLP-ANN) for the Itupararanga Environmental Protection Area, a region of hydrological importance for the Metropolitan Region of Sorocaba, utilizing LULC data and spectral bands from the Landsat satellite. The 2021 ET was calculated using the SEBAL algorithm and used as the basis for training and supervised classification in the ANN-MLP model of the TerrSet software. The ANN estimates were evaluated using TerrSet criteria, highlighting visual differences that indicate the need for parameter adjustments in the MLP to better align with the SEBAL estimates, which had been previously validated. This innovative approach complements the use of ANN in ET modeling, offering new perspectives for analyzing environmental dynamics.

Keywords: Itupararanga EPA, Itupararanga Reservoir, machine learning, remote sensing.

1. Introdução

A dinâmica das mudanças no uso e cobertura da terra (UCT) tem sido reconhecida como um dos principais fatores de transformação global, impactando significativa-

mente os processos que regulam as interações entre a superfície terrestre e a atmosfera, assim como os ciclos biogeoquímicos, a emissão de carbono, a produtividade biológica e a biodiversidade (Manuschevich *et al.*, 2019).

Alterações no UCT são uma preocupação crescente tanto em escalas regionais quanto globais, devido aos impactos ambientais que elas promovem, especialmente no que se refere ao manejo dos recursos naturais e à sustentabilidade (Oliveira *et al.*, 2024).

O mapeamento e a análise espacial das alterações no UCT são fundamentais para o monitoramento das dinâmicas ambientais. Isso permite a avaliação de mudanças espaciais e temporais em diferentes períodos, fornecendo dados essenciais para a gestão territorial e a formulação de políticas públicas (Koko *et al.*, 2020). Essas alterações ocorrem sob pressões naturais e antropogênicas, gerando impactos que variam conforme a escala espacial e temporal (Leta *et al.*, 2021). Tais pressões são globais, dado o vínculo intrínseco entre ecossistemas e a subsistência humana, com efeitos que se manifestam de forma não linear e resultam em complexas transformações da paisagem (Bunyanga *et al.*, 2021).

A ausência de um planejamento adequado do uso do solo leva a conflitos entre setores e à degradação dos recursos naturais, exigindo que decisões sobre o ordenamento territorial envolvam a comunidade e múltiplos atores sociais (Henriquez-Dole *et al.*, 2018), além de uma análise multidisciplinar dos ecossistemas naturais e antropizados. Como a cobertura terrestre é majoritariamente modificada por ações humanas, políticas públicas eficientes são essenciais para regulamentar atividades econômicas que afetam o meio ambiente (Manuschevich *et al.*, 2019).

Estudos voltados para a interpretação da evapotranspiração (ET), que consideram os efeitos das mudanças do UCT, são capazes de quantificar os impactos gerados pela influência antrópica no ciclo hidrológico, ajudando de maneira efetiva na gestão dos recursos hídricos (Li *et al.*, 2017; Liu e Hu, 2019). Todavia, determinar a ET envolve a utilização de parâmetros climáticos obtidos por meio de estações meteorológicas, que nem sempre estão disponíveis devido à dificuldade na manutenção e existência de uma rede meteorológica ativa em muitos países.

Nesse sentido, o sensoriamento remoto (SR) é uma ferramenta capaz de fornecer dados de variáveis que interagem entre si, resultando na ET, de modo que o mapeamento desse importante componente do ciclo hidrológico em grandes escalas por meio dessa geotecnologia, é realizado de maneira eficiente e econômica (Zhang *et al.*, 2016; Ghaderi *et al.*, 2020; Duarte *et al.*, 2024).

Isso ocorre porque os sensores presentes em satélites são capazes de adquirir dados espectrais além dos comprimentos de onda da região visível do espectro eletromagnético, como comprimentos de onda do infravermelho e termal (Lechner *et al.*, 2020), sendo esse o princípio utilizado no algoritmo SEBAL proposto por Bastiaansen *et al.* (1998).

O SEBAL estima a evapotranspiração a partir de uma sequência de cálculos que determinam a radiação líquida na superfície, o fluxo de calor do solo e o fluxo de

calor sensível transferido para a atmosfera (Waters *et al.*, 2002).

Porém, apesar de seus benefícios, o emprego de diversas equações e procedimentos, ao depender dos níveis do conhecimento do operador, complexificam a construção do banco de dados necessário para o cálculo da ET.

Deste modo, com os avanços das redes neurais artificiais (RNA) que surgiram como um campo promissor no campo da inteligência artificial (IA) no final da década de 1940 (McCulloch e Pitts, 1943), diversos estudos têm utilizado RNA para estimar a ET e projeções (Antonopoulos e Antonopoulos, 2017; Dezsai *et al.*, 2018; Ni *et al.*, 2018; Ajjur; Al-Ghamdi, 2021; Dimitriadou e Nikolakopoulos, 2022), contudo, tais estudos são dependentes de séries de dados meteorológicos.

Por serem classificadores de padrões genéricos, as RNA não exigem um modelo estatístico prévio dos dados de entrada, tornando-as extremamente versáteis através da combinação de diferentes tipos de dados em um único modelo (Mohan e Giridhar, 2022). As RNA são um tipo de IA que se baseiam na estrutura de uma célula neural e no modo em que as informações são transmitidas nessas células.

Um modelo de RNA de apenas uma camada neural consiste em: (1) receber dados de entrada; (2) multiplicá-los por pesos; (3) somar esses valores; (4) calcular a diferença das somas ponderadas das entradas e o limiar de ativação (*bias*); (5) gerar o dado de saída de acordo com uma função de ativação (Jain *et al.*, 1996; Abiodun *et al.*, 2018).

Uma estrutura de uma RNA de múltiplas camadas pode ser dividida em: (1) camadas de entrada, (2) camadas ocultas e (3) camadas de saída. Na existência de mais de uma camada oculta, essas redes passam a integrar o denominado aprendizado profundo *deep learning* (DL). As interações que ocorrem entre as camadas são denominadas nós, que irão depender da quantidade de variáveis consideradas na introdução das camadas (Pham *et al.*, 2019), portanto, a quantidade de neurônios ocultos nas camadas ocultas depende da quantidade do conjunto de dados utilizados para o treinamento do modelo (Saputra e Lee, 2019).

Entre as RNA envolvidas no contexto do DL, destaca-se a RNA-MLP (*Multilayer Perceptron*). Enquanto o *deep learning* é uma subárea da aprendizagem de máquina que utiliza redes neurais com múltiplas camadas ocultas para extrair representações hierárquicas e progressivamente mais abstratas dos dados de entrada (Deng e Yu, 2014).

A RNA - MLP, por sua vez, é um tipo de rede *feed-forward* que permite a modelagem de múltiplas transições simultaneamente por meio de um processo iterativo de treinamento supervisionado. Nesse processo, cada pixel das camadas de entrada é avaliado em termos de existência ou não de transições quando o treinamento está sendo execu-

tado, permitindo que a aprendizagem e as interações ocorram de forma dinâmica, até que o modelo atinja critérios de parada, como o número máximo de iterações ou uma convergência mínima de erro (Eastman, 2016).

As RNA têm atraído grande interesse na modelagem de processos ambientais devido à sua capacidade de identificar relações complexas entre entradas e saídas, sido amplamente aplicadas em estudos meteorológicos e hidrológicos (Rahimikhoob, 2010; Raihan, 2023). A preparação de dados, análise espacial exploratória, treinamento de modelos, disseminação de resultados por meio de mapas interativos, são componentes intrínsecos das geotecnologias que apoiam a análise de dados (Raihan, 2023).

Por outro lado, os algoritmos de DL lidam com estruturas de dados complexas, proporcionando alta precisão, flexibilidade e capacidade de generalização, tornando a integração entre geotecnologia e DL, uma excelente ferramenta para o desenvolvimento de modelos que consideram variáveis geográficas complexas e dinâmicas, representando padrões espaciais com maior precisão (Raihan, 2023).

Diante do exposto, identifica-se uma oportunidade para explorar o uso das RNA na estimativa da ET de for-

ma eficiente e acessível, visando reduzir barreiras tecnológicas e direcionar estudos futuros para o desenvolvimento de ferramentas práticas que beneficiem usuários não acadêmicos e científicos.

Nesse sentido, o objetivo deste artigo é estimar a ET real na Área de Proteção Ambiental de Itupararanga (APA de Itupararanga), utilizando RNA-MLP em conjunto com dados espectrais do satélite Landsat, considerando as a influência do uso e cobertura da terra (UCT) sobre a ET na região. Essa é uma região de grande importância ecológica, com papel fundamental na conservação dos recursos hídricos e naturais do estado da Região Metropolitana de Sorocaba.

2. Materiais e Métodos

2.1. Caracterização da área de estudo

A Área de Proteção Ambiental de Itupararanga (APA de Itupararanga) foi criada em 1998 pela Lei Estadual n. 10.100 e abrange os municípios de Vargem Grande Paulista, Ibiúna, São Roque, Mairinque, Alumínio, Piedade, Cotia e Votorantim (Fig. 1).




Figura 1 - Localização da Área de Proteção Ambiental de Itupararanga.

A APA, conforme o Comitê de Bacia Hidrográfica do Rio Sorocaba e Médio Tietê (CBH-SMT), é um território estratégico para a gestão hídrica, abrigando a Represa de Itupararanga e outros recursos hídricos responsáveis pelo abastecimento de mais de um milhão de habitantes (Simonetti *et al.*, 2019; CBH-SMT, 2022).

A vegetação predominante é caracterizada como Floresta Ombrófila Densa do bioma Mata Atlântica. No entanto, grande parte da cobertura vegetal foi removida, restando apenas fragmentos da vegetação original. Essa é uma característica marcante do bioma, historicamente degradado (Nery *et al.*, 2025).

De acordo com a classificação de Köppen, o clima é subtropical úmido (Cwa). O clima da região apresenta verões chuvosos e invernos secos, com média anual de 1.492 mm de precipitação. Janeiro é o mês mais chuvoso (248 mm), e agosto o mais seco (43 mm) (Nery *et al.*, 2025).

2.2. Reclassificação da evapotranspiração e amostragem para o treinamento da rede neural artificial

A ET calculada para o ano de 2021, utilizando o algoritmo SEBAL, foi reclassificada em dois intervalos principais: 1,00 e 0,5, conforme observado na Fig. 2, para ser utilizada como a imagem de treinamento e classificação

supervisionada. Essa decisão foi tomada com o intuito de simplificar o processo de estimativa por meio RNA-MLP.

A reclassificação dos dados em intervalos pré-definidos facilita a aprendizagem e o treinamento da RNA, devido à generalização, reduzindo a complexidade dos padrões a serem reconhecidos pelo modelo, diminuindo a quantidade de variáveis de saída e contribuindo para um desempenho mais ágil devido ao menor tempo de processamento e sobrecarga computacional.

Também se justifica a reclassificação para reconhecimento da distribuição da quantidade de pixels em cada intervalo de ET, para realizar uma amostragem equilibrada entre as diferentes classes, evitando que uma classe seja mais representativa que a outra. Esse processo considera as variações inerentes aos padrões geográficos, que refletem a heterogeneidade espacial presente nos dados analisados. Portanto, verificou a distribuição da quantidade de pixels em cada classe, conforme organizado na Tabela 1.

Posteriormente, calculou-se o número de amostras em cada classe, considerando que ao todo 5.000 pixels deveriam ser amostrados. A definição da quantidade de pixels mínimos foi realizada a partir da classe que apresentava a menor quantidade dos mesmos, a proporcionalidade da quantidade de pixels foi obtida de acordo com a Eq. (1).

$$n = \left(\frac{N_p}{N} \right) * (5000 - (N_c * n_a)) \quad (1)$$




Figura 2 - Evapotranspiração real (mm/dia) de 2021 reclassificada.

Tabela 1 - Descrição da quantidade de pixels a serem amostrados em cada imagem reclassificada.

Classificação da ET a cada 1 mm/dia				
Classe	Pixels totais	Pixels mínimos	Pixels adicionais (proporcional)	Pixels totais amostrados
0,00-1,00	119	100	1	101
1,00-2,00	4.884	100	22	122
2,00-3,00	798.663	100	3.541	3.641
> 3,00	233.770	100	1.037	1.137
Total	1.037.436			5000

Classificação da ET a cada 1 mm/dia				
Classe	Pixels totais	Pixels mínimos	Pixels adicionais (proporcional)	Pixels totais amostrados
0,00-0,50	22	20	0	20
0,50-1,00	97	20	0	20
1,00-1,50	385	20	2	22
1,50-2,00	4.499	20	21	41
2,00-2,50	132.610	20	619	639
2,50-3,00	666.053	20	3.107	3.127
3,00-3,50	231.867	20	1.082	1.102
>3,50	1.903	20	9	29
Total	1.037.436			5.000

sendo n o tamanho da amostra; N_p a quantidade de pixels totais em cada classe; N tamanho da população = 1.037.436 pixels; N_c a quantidade de classes; n_a a quantidade mínima de pixel para amostragem.

2.3. Estrutura da rede neural artificial utilizada

Utilizou-se o modelo RNA-MLP do *software* TerrSet, tradicionalmente usado para classificação de imagens. Esse tipo de RNA é recomendada para modelagens não lineares e se destaca por sua capacidade de generalizar com precisão quando apresentado a dados novos e nunca vistos (Gardner e Dorling, 1998). Essa capacidade de generalização torna a RNA-MLP uma escolha popular em diversas áreas, incluindo as ciências atmosféricas, onde suas aplicações são variadas e eficazes (Gardner e Dorling, 1998).

A estrutura da RNA-MLP consiste em um sistema de neurônios interconectados por pesos, também conhecidos como nós, capazes de mapear as relações não lineares entre um vetor de entrada e de saída (Gardner e Dorling, 1998). Os sinais de saída de cada nó são determinados pela

soma das entradas modificadas por uma função de transferência não linear, ou função de ativação (Gardner e Dorling, 1998).

Outra característica importante da RNA-MLP é o uso do algoritmo de retropropagação (*backpropagation*), que ajusta iterativamente os pesos das conexões dos neurônios durante o treinamento com base no erro entre a saída prevista e a esperada (Eastman, 2016). A cada iteração, os pesos são atualizados com o objetivo de minimizar a função de erro, permitindo que a rede aprenda com seus próprios erros. Portanto, cada nó da rede soma os sinais ponderados provenientes da camada anterior, aplica uma função de ativação não linear à soma e, em seguida, transmite o resultado para a próxima camada (Clark Labs, 2020).

Após a passagem direta, a saída é comparada aos resultados esperados para identificar erros na rede, que são enviados de volta pela rede para ajustar os pesos, assim, o treinamento continua até que a rede aprenda a classificar dados desconhecidos com precisão (Clark Labs, 2020). Sendo assim, o processo de aprendizagem supervisionado, depende de informações conhecidas do que se pretende classificar.

O uso de RNA em estudos hidrológicos também é observado desde a década de 1990, inicialmente através de modelagens de precipitação-escoamento (Kumar et al., 2011). Desde então, essas aplicações se expandiram para previsão de fluxo de córregos, modelagem de águas subterrâneas, qualidade da água, previsão de precipitação, operação de reservatórios e análise de séries temporais de processos hidrológicos, sendo o algoritmo de *backpropagation* o mais utilizado (Kumar et al., 2011), justificando a escolha dessa estrutura para a estimativa da ET.

Portanto, considerando a quantidade total de pixels nas imagens de ET (1.037.436) e um grau de 95% de confiança, separou-se amostra de 385 pixels, dos quais 70% foram selecionados para treinamento e 30% para teste, de acordo com a Eq. (2).

$$n = \frac{N * Z^2 * p * (1 - p)}{e^2 * (N - 1) + Z^2 * p * (1 - p)} \quad (2)$$

sendo n o tamanho da amostra; N : tamanho da população = 1.037.436 pixels; Z : valor crítico da distribuição normal padrão (95% de confiança $\rightarrow Z = 1,96$); p : proporção esperada (0,5); e : margem de erro (5%).

Os parâmetros de treinamento também foram ajustados, optando por realizar a modelagem com treinamento automático. O uso do treinamento automático significa que a RNA-MLP pode reiniciar seu processo de aprendizado sozinho se encontrar problemas, promovendo a procura por soluções melhores, pois ao usar o treinamento automático, após as 100 primeiras iterações, se forem detectadas oscilações significativas no RMSE, as taxas de aprendizado são reduzidas pela metade e o processo é

reiniciado, além de alterar os pesos novamente (Clark Labs, 2020).

Os nós da camada oculta são as unidades nas camadas intermediárias da rede neural que processam as informações e foram ajustados para comparação, verificando se o modelo apresentaria melhor desempenho com uma ou duas camadas ocultas, pois de acordo com as informações dos desenvolvedores do TerrSet, Clark Labs (2020), o número de nós da camada oculta é importante para o desempenho da rede e pode ser estimado pela Eq. (3), sendo recomendável ter pelo menos dois nós para garantir que a rede possa aprender de forma eficaz.

Além disso, um número muito pequeno de nós pode afetar a capacidade de generalização do modelo e, embora mais camadas ocultas possam aumentar a capacidade do modelo, os ganhos de desempenho podem não justificar a complexidade adicional, reforçando a ideia de que um equilíbrio deve ser alcançado entre a complexidade e o desempenho do modelo (Walls et al., 2020).

$$N_h = \sqrt{N_f \times N_i} \quad (3)$$

sendo N_h é a quantidade de nós na camada oculta, em número inteiro; N_f é a quantidade de nós na camada de saída; N_i é a quantidade de nós na camada de entrada.

O fator *momentum* necessita ser ajustado para obter melhor desempenho dos modelos, valores que dependem da quantidade das camadas ocultas e nós utilizados (Diamantopoulou et al., 2005). A Clark Labs (2020) recomenda valores de fator *momentum* 0,5 e 0,6, de forma que nos modelos testados, e como não existem diretrizes específicas para determinar a estrutura de uma RNA, sendo essa frequentemente otimizada por meio de regras empíricas combinadas com tentativas e erros (Rahimikhoob, 2010), nos modelos testados verificou-se melhor fator *momentum* igual a 0,5.

Esse é um componente crucial para ajudar a evitar problemas de oscilação durante a busca pelo valor mínimo local (Mallikarjuna et al., 2012; Yassin et al., 2016), isso é particularmente importante em cenários complexos, nos quais os valores podem mudar rapidamente (Clark Labs, 2020). O fator *momentum* contribui para o processo de otimização e ajuda a suavizar as atualizações e fornece um caminho mais estável em direção à solução (Clark Labs, 2020).

Também foi necessário ajustar a função sigmóide, uma função matemática que desempenha um papel de ativação, de natureza não linear, que permite que as redes neurais aprendam padrões complexos nos dados, introduzindo a não linearidade no modelo (Clark Labs, 2020). Valores superiores a 1 contribuem para que a função se comporte de forma mais linear, enquanto valores inferiores geram uma situação de não linearidade ao modelo. Nos modelos testados, o melhor valor de função sigmóide utilizado foi o de 0,8, pois, em conjunto com o valor do fator

momentum, apresentou melhor ajuste na taxa de treinamento mais rapidez na resposta desse ajuste.

Foram realizadas seis execuções para cada configuração. Os experimentos consistiram em ajustar o modelo até alcançar a condição ótima, realizando correções nos parâmetros de fator *momentum* e na função sigmoide. As execuções foram realizadas para as configurações com dados de evapotranspiração a cada 1 mm e na evapotranspiração a cada 0,50 mm.

Optou-se por utilizar as bandas espectrais (radiância e reflectância) das imagens Landsat 8, datadas de 22 de agosto de 2021, como entradas para a RNA-MLP, uma vez que este é o formato de dados utilizado no algoritmo SEBAL, o que viabiliza uma comparação direta entre os resultados obtidos pelos modelos RNA-MLP e SEBAL. Também se utilizou o UCT de 2021, obtido por meio da plataforma MapBiomas, uma vez que o aumento das culturas temporárias foi associado a um incremento da ET, conforme observado por Nery (2025).

Inicialmente, utilizou-se as Bandas 2, 3, 4, 5, 6, 7 e 10 do satélite Landsat 8 (Tabela 2), em conjunto com UCT. Optou-se por trabalhar com tais bandas, foi orientada pelo conhecimento prévio do algoritmo SEBAL, que utiliza tais bandas em seu fluxo, seja para calcular fluxos de energia, seja para calcular índices de vegetação. Além disso, compreende-se que cada cobertura terrestre possui um comportamento espectral próprio, uma vez que fluxos energéticos influenciam a ET, entende-se que inserir dados espectrais são substanciais para definir a influência das mudanças de uso do solo sobre a ET.

Os dados de entradas foram inseridos em RNA distintas, uma com 1 camada oculta e outra com 2 camadas. Em seguida, variou-se a quantidade de entradas introduzidas nos modelos, após a avaliação das variáveis mais e menos influentes, realizando uma nova rodada de testes, com 1 e 2 camadas ocultas, excluindo as variáveis menos importantes.

2.3.1. Avaliação do modelo

As estimativas de ET geradas pela RNA foram analisadas considerando múltiplos critérios de avaliação disponibilizados pelo TerrSet, incluindo o *Kappa Index of Agreement (KIA)*, *Training RMS*, *Testing RMS*, *Accuracy Rate* e *Skill Measure*. Após a identificação dos melhores modelos, os mapas gerados pela classificação da RNA-MLP foram comparados aos obtidos pelo SEBAL para o mesmo período (2021), com o objetivo de verificar a acurácia do modelo.

Valores de KIA são observados para cada intervalo de classificação, medindo o nível de concordância entre a classificação obtida pelo modelo e os dados reais em cada categoria de ET. O RMS indica o quão distante, em média, os valores previstos estão dos valores reais, sendo calculado tanto durante o treinamento quanto durante os testes,

Tabela 2 - Descrição das bandas espectrais utilizadas na arquitetura das redes neurais artificiais modeladas.

Sensor	Banda espectral	Descrição	Resolução espectral (μm)
OLI (Optional Land Imager)	Banda 2	Azul	0,45-0,51
	Banda 3	Verde	0,53-0,59
	Banda 4	Vermelho	0,64-0,67
	Banda 5	Infravermelho próximo	0,85-0,88
	Banda 6	Infravermelho médio	1,57-1,65
	Banda 7	Infravermelho médio	2,11-2,29
TIRS (Thermal Infrared Sensor)	Banda 10	Infravermelho termal	10,60-11,19

ou seja, utilizando amostras que não foram usadas no treino (Clark Labs, 2020).

Accuracy Rate e *Skill Measure* avaliam, respectivamente, o desempenho do modelo: (1) em classificar corretamente cada pixel em comparação com dados reais; (2) em relação a uma classificação aleatória, indicando o quanto o modelo é melhor do que o acaso.

A classificação realizada pela RNA-MLP foi avaliada pelo método do Índice Kappa no módulo *validate* do software TerrSet. Os componentes do Índice Kappa analisados foram: *Kappa index agreement for no information* (Kno), *Kappa index agreement for location* (Klocation), *Kappa index agreement for location stratification* (Klocation-strata) e *Kappa index agreement standard* (Kstandard).

Os valores de Kno avaliam o quão bem o mapa projetado concorda com o mapa de referência quando não há informações disponíveis para fazer a comparação (Hasan et al., 2020; Koko et al., 2020), ou seja, quão melhor é o modelo em relação ao acaso. Já o Klocation indica a precisão espacial no cenário geral do mapa, considerando as atribuições corretas em cada categoria entre o mapa simulado e o mapa de referência (Hasan et al., 2020; Koko et al., 2020), evidenciando a capacidade do modelo de acertar a localização correta das classes em um mapa.

O KlocationStrata quantifica a precisão espacial dentro de estratos pré-identificados e indica o quão bem os pixels estão situadas nesses estratos (Hasan et al., 2020; Koko et al., 2020), indicando a capacidade do modelo classificar corretamente os pixels em cada categoria. Por fim, o Kstandard compara as alocações incorretas feitas por acaso com as atribuições corretas no mapa, medindo a concordância geral entre o modelo e os dados observados.

3. Resultados e Discussão

3.1. Modelos obtidos

A Tabela 3 apresenta uma organização detalhada dos resultados de desempenho dos modelos desenvolvidos,

incluindo as métricas de acurácia, raiz quadrada da média dos quadrados (RMS) e as variáveis de entrada utilizados em cada um deles. A identificação das variáveis menos influentes para ajuste dos modelos desenvolvidos a priori, foi realizada a partir dos relatórios gerados pelo módulo RNA-MLP do software TerrSet.

Este relatório apresenta a avaliação da perda de desempenho ao manter cada variável constante, bem como a análise de sua contribuição isolada. As variáveis são classificadas por ordem decrescente de importância, com base na variação da acurácia, permitindo identificar aquelas menos relevantes para a predição da ET (Clark Labs, 2020).

Os Modelos 1 e 2 (classificação a cada 0,50 mm/dia), apresentaram acurácia superior quando comparados com os modelos em que tiveram a redução das variáveis, Modelos 3 e 4. Ambos apresentam os mesmos valores de RMS para teste, ~0,24, e para RMS treino, ~0,24. A ligeira melhora no desempenho Modelo 2, que utiliza duas camadas, sugere que a adição de uma camada oculta auxilia na modelagem de variáveis mais complexa, pois a taxa de acurácia mede a capacidade do algoritmo de prever corretamente as classes de pixels de validação após cada iteração do treinamento da rede (Agudelo-Hz et al., 2023).

Em relação a classificação da ET a cada 1,00 mm/dia, diferentemente do observado para a classificação a cada 0,5, os modelos de apenas uma camada oculta, Modelo 5 e Modelo 8, apresentaram acurácia superior aos modelos com duas camadas ocultas, 77,42% e 75,95%, respectivamente. Valores de acurácia superiores a 70% indicam que o modelo possui um bom poder de previsão (Agudelo-Hz et al., 2023).

Apesar da maior acurácia indicar que intervalos maiores de ET facilitam a identificação de padrões, os valores de RMS para teste e treino foram mais altos, sugerindo maior erro médio. Além disso, conforme observado anteriormente, a redução das variáveis menos influentes não gerou maior acurácia. Todavia, todos os modelos apresentaram valores de Skill Measure superiores a 0,60, que os resultados das previsões são melhores que o acaso (Agudelo-Hz et al., 2023).

Em ambos os intervalos de ET, determinadas bandas e o UCT foram identificadas como menos influentes, mas mesmo após a sua remoção, não houve aumento de acurácia ou diminuição do erro. Isso sugere que, mesmo sendo variáveis de menor influência, elas ainda têm algum grau de correlação com o processo de ET, o que contribui para a modelagem de forma que sua remoção não impacta negativamente o desempenho do modelo.

Considerando que, as variáveis de entradas selecionadas desempenham um papel significativo na modelagem, de modo que as mesmas devem possuir qualidade e relevância (Walls et al., 2020), remover as variáveis menos importantes sem melhorar a acurácia, indica que o modelo já está capturando adequadamente a relação entre as variáveis e a ET.

Tabela 3 - Análise dos modelos de RNA-MLP avaliados.

Modelo	Intervalo ET (mm/dia)	Variáveis	Camadas ocultas	Nós	Acurácia (%)	RMS teste	RMS treino	Camadas menos influentes
1	0,5	Banda 2 Banda 3 Banda 4 Banda 5 Banda 6 Banda 7 Banda 10 UCT 2021	1	8	67,64	0,2390	0,2344	Banda 2, Banda 5, Banda 3, UCT
2	0,5	Banda 2 Banda 3 Banda 4 Banda 5 Banda 6 Banda 7 Banda 10 UCT 2021	2	4 e 8	68,18	0,2354	0,2306	Banda 10, Banda 2, Banda 7, UCT
3	0,5	Banda 3 Banda 4 Banda 5 Banda 6	2	3 e 6	65,78	0,2406	0,2354	-
4	0,5	Banda 4 Banda 6 Banda 7 Banda 10	1	6	65,85	0,2417	0,2421	-
5	1	Banda 2 Banda 3 Banda 4 Banda 5 Banda 6 Banda 7 Banda 10 UCT 2021	1	6	77,42	0,2775	0,2715	Banda 4, UCT, Banda 10, Banda 5
6	1	Banda 2 Banda 3 Banda 4 Banda 5 Banda 6 Banda 7 Banda 10 UCT 2021	2	3 e 6	74,42	0,2991	0,3018	Banda 6, Banda 10, Banda 2, Banda 5
7	1	Banda 2 Banda 3 Banda 6	2	6	74,08	0,3091	0,3047	-

(continua)

Tabela 3 - continua

Modelo	Intervalo ET (mm/dia)	Variáveis	Camadas ocultas	Nós	Acurácia (%)	RMS teste	RMS treino	Camadas menos influentes
8	1	Banda 7	1	4	75,95%	0,2880	0,2864	-
		Banda 3						
		Banda 4						
		Banda 7						
		UCT 2021						

Valores menores de RMS sugerem uma maior estabilidade e menor variabilidade nas previsões, sugerindo que o modelo consegue manter uma alta precisão sem grandes oscilações nos erros, (Khanal *et al.*, 2018; Hasan *et al.*, 2020). Apesar de não ser verificada uma diferença substancial dos valores de RMS para treino e teste, valores de RMS superiores no treino em relação ao teste, com exceção dos Modelos 4 e 6, caracteriza a presença *overfitting*, com destaque para o Modelo 5.

Este fenômeno ocorre quando o modelo se ajusta excessivamente aos dados de treinamento, capturando não apenas os padrões subjacentes, mas também o ruído presente nesses dados, conforme detalhado por Ying (2022), que aborda as implicações do *overfitting* e a importância de técnicas de validação e regularização para melhorar a robustez dos modelos preditivos. Como resultado, o modelo pode apresentar um desempenho superior nos dados de treino, mas sua capacidade de generalização para novos dados, ou seja, dados que não foram utilizados durante o treinamento (Bassi *et al.*, 2024).

Considerando os melhores desempenhos em termos de acurácia e menores valores de RMS, os Modelos 2 e 5 foram selecionados como os mais adequados para a modelagem da evapotranspiração utilizando Redes Neurais Artificiais (RNA-MLP).

3.2. Análise da acurácia dos melhores modelos obtidos

Os resultados apresentados na Tabela 4 indicam que o Modelo 5 apresenta um desempenho superior em termos do índice Kappa em comparação ao Modelo 2, quando observado especificamente o valor de Kstandard. Contudo, quando analisado isoladamente, ambos possuem Kstandard com baixa concordância.

Por outro lado, o Modelo 2 apresenta melhor desempenho em termos de concordância espacial (Klocation e Klocationstrata = 0,64), o que sugere maior precisão na identificação dos padrões de localização, mostrando que o Modelo 5 apresentou um desempenho global mais elevado na classificação geral (Kno = 0,79), mas teve maior dificuldade em capturar os padrões espaciais.

Todavia, apesar de balancear a amostragem, o Modelo 2 teve dificuldades em classificar dois intervalos de ET, de 1,00 - 1,50 e superior a 3,50 mm/dia, como pode ser observado na Tabela 5, revelando um desempenho mais instável, com falhas nessas classes. Contudo, para as

Tabela 4 - Valores do índice Kappa para cada modelo avaliado.

Modelo	Descrição	Símbolo	Valor
2	<i>Kappa index agreement for no information</i>	K _{no}	0,66
	<i>Kappa index agreement for location</i>	K _{location}	0,64
	<i>Kappa index agreement for location stratification</i>	K _{locationstrata}	0,64
	<i>Kappa index agreement standard</i>	K _{standard}	0,29
5	<i>Kappa index agreement for no information</i>	K _{no}	0,79
	<i>Kappa index agreement for location</i>	K _{location}	0,45
	<i>Kappa index agreement for location stratification</i>	K _{locationstrata}	0,45
	<i>Kappa index agreement standard</i>	K _{standard}	0,32

classes classificadas, verifica-se certa concordância espacial, como a identificação de áreas com maior ET no Sul e na Represa de Itupararanga, conforme pode ser observado na Fig. 3.

Em relação ao Modelo 5, verifica-se que, diferentemente do Modelo 2, as classes de ET de 0,00 até 2,00 apresentaram valores altos de KIA, conforme pode ser observado na Tabela 6, indicando uma alta concordância entre as previsões do modelo e os dados observados. Contudo, o desempenho é reduzido nas classes subsequentes, demonstrando que o Modelo 5 tem maior dificuldade em capturar padrões em valores mais altos de ET, conforme pode ser observado na espacialização dos valores de ET na Fig. 4.

Diferentemente de estudos recentes que utilizam diversos modelos de RNA para fins de regressão, e assim obter valores de ET que em sua maioria são valores de ET de referência ou de cultura, com base em variáveis meteorológicas ou climáticas e modelagem contínua (Granata e Nunno, 2021; Elbeltagi *et al.*, 2022; Vaz *et al.*, 2022), este trabalho propõe uma abordagem utilizando RNA para obter a classificação espacial da ET real com base em dados derivados de sensoriamento remoto.

Portanto, enquanto os estudos citados reportam resultados com alta acurácia (R^2 entre 0,83 e 0,99; RMSE entre 0,38 e 0,55 mm/dia), todos se restringem à previsão de um único dado de saída. Em contraste, este estudo classificou a ET em intervalos discretos (de 0,5 e 1,0 mm/dia),

Tabela 5 - Valores do Índice de Concordância Kappa (KIA) para cada classe do Modelo 2.

Modelo 2	
Classe	KIA
0,00-0,50	0,54
0,50-1,00	0,38
1,00-1,50	-
1,50-2,00	-0,01
2,00-2,50	0,62
2,50-3,00	0,17
3,00-3,50	0,57
> 3,50	-

o que permite identificar espacialmente os padrões de ET, agregando valor prático à gestão hídrica em territórios extensos e heterogêneos, como a APA de Itupararanga.

Além disso, os modelos desenvolvidos apresentaram acurácia global superior a 70% e erro global inferior a 30%, o que demonstra um bom desempenho geral mesmo com valores de Kstandard baixos (0,29 para o Modelo 2 e 0,32 para o Modelo 5), pois outros valores do índice Kappa sugerem que o Modelo 5 obteve boa concordância global entre as classes, enquanto o Modelo 2 capacidade razoável de captar padrões espaciais consistentes, reforçando o potencial do uso de RNA-MLP na modelagem

Tabela 6 - Valores do Índice de Concordância Kappa (KIA) para cada classe do Modelo 5.

Modelo 5	
Classe	KIA
0,00-1,00	0,91
1,00-2,00	0,88
2-00-3,00	0,30
> 3,00	0,48

espacial da ET para a aplicabilidade prática do mapeamento temático na gestão hídrica.

A análise da quantidade de pixels por classe de ET (Tabela 5), revela padrões que afetaram o Modelo 2, pois verificou-se os valores de ET concentram-se entre 2,00-3,00 mm/dia, o que dificulta a identificação de pixels entre 0,00-1,50 mm/dia pelo mesmo, que acabou por generalizar tais informações e agrupá-los em outras classes, que pode estar relacionado a capacidade da RNA-MLP em generalizar regiões de maior densidade de dados (Bassi *et al.*, 2024). Contudo, para o Modelo 5, verifica-se que o método escolhido para amostragem se mostrou adequado para evitar generalizações excessivas.

A comparação entre as Figs. 3 e 4, sugere que o modelo RNA-MLP conseguiu replicar certos padrões espaciais de ET, mas apresenta algumas discrepâncias quanto




Figura 3 - Comparação da distribuição espacial da evapotranspiração real obtida por (a) SEBAL e (b) RNA-MLP na classificação a cada 0,50 mm/dia.




Figura 4 - Comparação da distribuição espacial da evapotranspiração real obtida por (a) SEBAL e (b) RNA-MLP na classificação a cada 1,00 mm/dia.

aos valores preditos. Embora as RNA sejam eficientes, sua abordagem não descreve explicitamente as relações físicas entre os componentes do processo modelado, pois dependem de dados de entrada e saída para aprender o comportamento do processo (Kumar et al., 2011)

Essas diferenças podem ser explicadas por limitações no ajuste da rede neural ou pela simplificação dos parâmetros de entrada no modelo, uma vez que ela trabalha de maneira automatizada e pode não capturar com precisão todas as variações espaciais sutis identificadas pelo SEBAL, como a variabilidade do fluxo energético, albedo, índices de vegetação e influência das condições meteorológicas, como a velocidade do vento e a temperatura do ar.

Um dos principais desafios no contexto desse trabalho é a transferibilidade do modelo. Alguns autores pontuam que um modelo treinado para uma localização específica geralmente não pode ser aplicado em outra sem novo treinamento local (Kumar et al., 2011), o que dificulta a comparação dos resultados. Por outro lado, a transferência de aprendizado (*transfer learning*) permite que modelos aproveitem o conhecimento adquirido anteriormente e sejam ajustados para tarefas específicas, reduzindo a necessidade de dados de treinamento extensivos e recursos computacionais (Gupta et al., 2022).

Todavia, considerando o trabalho exposto, um desafio considerável dos modelos desenvolvidos para o *trans-*

fer learning vai além de um ajuste fino (*fine turning*) da adaptação dos pesos já treinados, por exemplo. Como a classificação da ET foi feita a partir de dados espectrais e de UCT, e considerando homogeneidade ou heterogeneidade que possam existir em determinada área, um simples *fine tuning* poderia não ser suficiente para captar adequadamente os padrões locais de ET.

Trabalhos que utilizaram RNA em conjunto com dados climáticos, mostram-se eficientes no cálculo da ETo e ETr (Zanetti et al., 2007; Rahimikhoob, 2010; Laboudi et al., 2012; Walls et al., 2020). Zanetti et al. (2007) utilizaram uma RNA para estimar ETo com base nas temperaturas diárias máximas e mínimas do ar, com índices de desempenho variando de 0,76 a 0,85, indicando uma forte correlação com o método Penman-Monteith.

Rahimikhoob (2010) também estimou a ETo, com base nos dados de temperatura mínima e máxima do ar e de radiação extraterrestre, utilizando a RNA-MLP, encontrando valores de ETo com excelente concordância entre dados simulados e observados, com valores do coeficiente de determinação (R^2) superiores a 0,90, assim como Walls et al. (2020) na determinação da ETr. Laboudi et al. (2012) destacam em seu estudo que RNA utilizada superou o modelo de regressão linear múltipla, em vários critérios de desempenho, incluindo Erro Quadrático Médio

(MSE) e a Raiz do Erro Quadrático Médio (RMSE), indicando sua precisão preditiva superior.

Os trabalhos mencionados utilizam dados meteorológicos/climáticos como variáveis de entrada, tais como temperatura do ar (mínima e máxima), radiação extra-terrestre e outras informações atmosféricas. Esses dados, por sua natureza, apresentam relações diretas e bem estabelecidas com a evapotranspiração, facilitando a identificação de padrões pela RNA (Kumar *et al.*, 2011; Laboudi *et al.*, 2012).

Nos estudos citados, a saída da RNA é um único neurônio, o que simplifica o treinamento e a convergência do modelo, pois ele precisa estimar apenas um valor de ET, enquanto o presente estudo adota classes de ET como saídas, o que demanda uma classificação mais complexa e, portanto, maior esforço do modelo para diferenciar padrões entre as classes, pois as RNA podem não levar em conta adequadamente os aspectos espaciais, levando a uma modelagem e análise menos eficazes (Raihan, 2023), especialmente em regiões onde as transições de ET são mais sutis e a variabilidade espacial pode dificultar o desempenho.

Por outro lado, outras arquiteturas de redes neurais, como as CNNs (Redes Neurais Convolucionais) são amplamente utilizadas em desafios de visão computacional, onde a extração de características espaciais é fundamental para a classificação de imagens e reconhecimento de padrões (Gupta *et al.*, 2022). Isso sugere que CNNs poderiam ser utilizadas em estudos futuros para prever a ET, dado seu foco em aprender características espaciais.

Embora os valores contínuos de ET estimados por modelos de regressão possam ser posteriormente reclassificados em categorias, é importante destacar que há uma diferença substancial entre classificar diretamente durante o treinamento do modelo e apenas converter saídas a posteriori. A RNA-MLP foi treinada especificamente para reconhecer padrões espaciais e espectrais associados a classes ET, exigindo que o modelo aprendesse a delimitar faixas de ET durante o próprio processo de treinamento, uma tarefa significativamente frente ao desbalanceamento da distribuição de pixels por classes destacada nas Tabelas 4 e 5.

A falta de transferibilidade torna-se ainda mais evidente no presente estudo. A utilização de dados espectrais e a modelagem espacial da ET intensificam ainda mais esse desafio, uma vez que os modelos devem lidar com a heterogeneidade espacial e interferências locais, como a cobertura do solo e uso da terra.

4. Conclusão

Os valores de acurácia, RMS e o comparativo da distribuição espacial dos valores estimados de ET pela RNA-MLP em relação ao modelo SEBAL evidenciam a necessidade de aprofundamento e ajustes no processo de

modelagem. Os resultados indicam que as previsões ainda apresentam baixa precisão, sugerindo a necessidade de aprimoramentos nos seguintes aspectos: ajuste de parâmetros de treinamento, seleção de variáveis de entrada mais relevantes e refinamento do algoritmo para melhor captura das variações de ET.

Por fim, as diferenças visuais destacam a necessidade de ajustes finos nos parâmetros do MLP para que ele se aproxime mais das estimativas do SEBAL, que foram anteriormente validados. Embora os estudos com dados climáticos demonstrem alta eficiência, a utilização de dados derivados de SR, destacados neste artigo, oferece vantagens práticas, como a possibilidade de estimar a ET em escalas espaciais maiores e com menor dependência de estações meteorológicas.

Além disso, a reclassificação da ET impacta a resolução e a qualidade dos resultados. A classificação em intervalos de 0,50 mm/dia apresenta maior detalhamento, mas pode dificultar a identificação de padrões devido à heterogeneidade espacial sutil entre algumas classes, dada a quantidade de pixels em cada categoria. Por outro lado, a classificação em 1,00 mm/dia favorece uma melhor identificação de tendências globais, embora apresente maior erro médio.

Nesse sentido, mesmo que a eficiência do modelo ainda possa ser aprimorada, o presente estudo representa uma abordagem inovadora e complementar ao uso de RNA na modelagem da ET, especialmente para áreas com baixa densidade de dados climáticos ou para aplicações que demandam informações espaciais.

Portanto, a seleção do modelo mais adequado deve considerar um equilíbrio entre a complexidade computacional e a precisão na representação espacial da ET. Estudos futuros devem priorizar a avaliação de novos métodos de pré-processamento, bem como a integração de técnicas que reduzam o erro de previsão e aumentem a robustez dos modelos de RNA-MLP.

Agradecimentos

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de estudos, Código de Financiamento 001, e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo financiamento do Processo CNPq: 402601/2023-8.

Referências

- ABIODUN, O.I.; JANTAN, A.; OMOLARA, A.E.; DADA, K.V.; MOHAMED, N.A.; *et al.* State-of-the-art in artificial neural network applications: a survey. *Heliyon*, v. 4, n. 11, e00938, 2018. [doi](#)
- AGUDELO-HZ, W.J.; CASTILLO-BARRERA, N.C.; URIEL, M.G. Scenarios of land use and land cover change in the Colombian Amazon to evaluate alternative post-conflict pathways. *Scientific Reports*, v. 13, n. 1, 2152, 2023. [doi](#)

- AJJUR, S.B.; AL-GHAMDI, S.G. Evapotranspiration and water availability response to climate change in the Middle East and North Africa. **Climatic Change**, v. 166, n. 3-4, 28, 2021. [doi](#)
- ANA, AGÊNCIA NACIONAL DE ÁGUAS E SANEAMENTO BÁSICO. **Estimativas de Evapotranspiração Real por Sensoriamento Remoto no Brasil**. Brasília: ANA, 2020.
- ANTONOPOULOS, V.Z.; ANTONOPOULOS, A.V. Daily reference evapotranspiration estimates by artificial neural networks technique and empirical equations using limited input climate variables. **Computers and Electronics in Agriculture**, v. 132, p. 86-96, 2017. [doi](#)
- BASSI, P.R.A.S.; DERTKIGIL, S.S.J.; CAVALLI, A. Improving deep neural network generalization and robustness to background bias via layer-wise relevance propagation optimization. **Nature Communications**, v. 15, n. 1, 291, 2024. [doi](#)
- BASTIAANSEN, W.G.M.; MENENTI, M.; FEDDES, R.A.; HOLTSLAG, A.A.M. A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. **Journal of Hydrology**, v. 212-213, p. 198-212, 1998. [doi](#)
- BUNYANGHA, J.; MAJALIWA, M.J.G.; MUTHUMBI, A.W.; GICHUKI, N.N.; EGERU, A. Past and future land use/land cover changes from multi-temporal Landsat imagery in Mpologoma catchment, eastern Uganda. **The Egyptian Journal of Remote Sensing and Space Science**, v. 24, n. 3, p. 675-685, 2021. [doi](#)
- CBH-SMT, COMITÊ DA BACIA HIDROGRÁFICA SOROCABA-MÉDIO TIETÊ. **Relatório de Situação 2022: Ano Base 2021**. Disponível em <https://sigrh.sp.gov.br/public/uploads/documents/CBH-SMT/23316/rs-2022-2021.pdf>, acesso em 14 de jul. de 2023.
- CLARK LABS. **TerrSet Help System**. 2020. Disponível em <https://clarklabs.org/download/>, acesso em 28 nov. 2024.
- DEZSI, S.; MINDRESCU, M.; PETREA, D.; RAI, P.K.; HAMANN, A.; *et al.* High-resolution projections of evapotranspiration and water availability for Europe under climate change. **International Journal of Climatology**, v. 38, n. 10, p. 3832-3841, 2018. [doi](#)
- DIAMANTOPOULOU, M.J.; PAPAMICHAIL, D.M.; ANTONOPOULOS, V.Z. The use of a neural network technique for the prediction of water quality parameters. **Operational Research**, v. 5, n. 1, p. 115-125, 2005. [doi](#)
- DIMITRIADOU, S.; NIKOLAKOPOULOS, K.G. Artificial neural networks for the prediction of the reference evapotranspiration of the Peloponnese Peninsula, Greece. **Water**, v. 14, n. 13, 2027, 2022. [doi](#)
- DUARTE, M.L.; SILVA, D.C.C.; BARBOSA, R.L.; LOURENÇO, R.W. Modeling of soil organic matter using Sentinel-1 SAR and partial least squares (PLS) regression. **Arabian Journal of Geosciences**, v. 17, 32, 2024. [doi](#)
- EASTMAN, J.R. **TerrSet Manual: Geospatial Monitoring and Modeling System**. Clark Labs Clark University: Worcester, p. 470, 2016. Disponível em <https://clarklabs.org/wp-content/uploads/2016/10/Terrset-Manual.pdf>, acesso em 20 abr. 2022.
- GARDNER, M.W.; DORLING, S.R. Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences. **Atmospheric Environment**, v. 32, n. 14-15, p. 2627-2636, 1998. [doi](#)
- GHADERI, A.; DASINEH, M.; SHOKRI, M.; ABRAHAM, J. Estimation of actual evapotranspiration using the remote sensing method and SEBAL algorithm: a case study in Ein Khosh Plain, Iran. **Hydrology**, v. 7, n. 2, 36, 2020. [doi](#)
- GUPTA, J.; PATHAK, S.; KUMAR, G. Deep learning (CNN) and transfer learning: a review. **Journal of Physics: Conference Series**, v. 2273, 012029, 2022. [doi](#)
- HASAN, S.; SHI, W.; ZHU, X.; ABBAS, S.; KHAN, H.U.A. Future simulation of land use changes in rapidly urbanizing South China based on land change modeler and remote sensing data. **Sustainability**, v. 12, n. 11, 4350, 2020. [doi](#)
- HENRÍQUEZ-DOLE, L.; USÓN, T.J.; VICUÑA, S.; HENRÍQUEZ, C.; GIRONÁS, J.; *et al.* Integrating strategic land use planning in the construction of future land use scenarios and its performance: the Maipo River Basin, Chile. **Land Use Policy**, v. 78, p. 353-366, 2018. [doi](#)
- JAIN, A.K.; MAO, J.; MOHIUDDIN, K.M. Artificial neural networks: a tutorial. **Computer**, v. 29, n. 3, p. 31-44, 1996. [doi](#)
- KHANAL, S.; FULTON, J.; KLOPFENSTEIN, A.; DOURIDAS, N.; SHEARER, S. Integration of high resolution remotely sensed data and machine learning techniques for spatial prediction of soil properties and corn yield. **Computers and Electronics in Agriculture**, v. 153, p. 213-225, 2018. [doi](#)
- KOKO, A.F.; YUE, W.; ABUBAKAR, G.A.; HAMED, R.; ALABSI, A.A.N. Monitoring and predicting spatio-temporal land use/land cover changes in Zaria City, Nigeria, through an integrated cellular automata and markov chain model (CA-Markov). **Sustainability**, v. 12, n. 24, 10452, 2020. [doi](#)
- KUMAR, M.; RAGHUWANSHI, N.S.; SINGH, R. Artificial neural networks approach in evapotranspiration modeling: a review. **Irrigation Science**, v. 29, n. 1, p. 11-25, 2010. [doi](#)
- LAABOUDI, A.; MOUHOUCHE, B.; DRAOUI, B. Neural network approach to reference evapotranspiration modeling from limited climatic data in arid regions. **International Journal of Biometeorology**, v. 56, n. 5, p. 831-841, 2011. [doi](#)
- LECHNER, A.M.; FOODY, G.M.; BOYD, D.S. Applications in remote sensing to forest ecology and management. **One Earth**, v. 2, n. 5, p. 405-412, 2020. [doi](#)
- LETA, M.K.; DEMISSIE, T.A.; TRÄNCKNER, J. Modeling and prediction of land use land cover change dynamics based on Land Change Modeler (LCM) in Nashe Watershed, Upper Blue Nile Basin, Ethiopia. **Sustainability**, v. 13, n. 7, 3740, 2021. [doi](#)
- LI, G.; ZHANG, F.; JING, Y.; LIU, Y.; SUN, G. Response of evapotranspiration to changes in land use and land cover and climate in China during 2001-2013. **Science of The Total Environment**, v. 596-597, p. 256-265, 2017. [doi](#)
- LIU, M.; HU, D. Response of wetland evapotranspiration to land use/cover change and climate change in Liaohe River Delta, China. **Water**, v. 11, n. 5, 955, 2019. [doi](#)
- MALLIKARJUNA P.; JYOTHY A.S.; REDDY K.C. Daily Reference evapotranspiration estimation using linear regression and ANN models. **Journal of The Institution of Engineers (India): Series A**, v. 93, n. 4, p. 215-221, 2012. [doi](#)

- MANUSCHEVICH, D.; SARRICOLEA, P.; GALLEGUILLOS, M. Integrating socio-ecological dynamics into land use policy outcomes: a spatial scenario approach for native forest conservation in south-central Chile. **Land Use Policy**, v. 84, p. 31-42, 2019. [doi](#)
- MCCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biology**, v. 52, n. 1-2, p. 99-115, 1990. [doi](#)
- MOHAN, S.; M.V.S.S, G. A brief review of recent developments in the integration of deep learning with GIS. **Geomatics and Environmental Engineering**, v. 16, n. 2, p. 21-38, 2022. [doi](#)
- NERY, L.M. **Análise Espacial e Estimativa da Evapotranspiração por meio de Redes Neurais Artificiais da APA de Itupararanga**. Tese de Doutorado em Ciências Ambientais, Instituto de Ciência e Tecnologia, Universidade Estadual Paulista, 2025.
- NERY, L.M.; GOMES, G.; MOURA, A.T.; SANTOS, A.P.; TONILO, B.P.; *et al.* Adaptation of SAVI to estimate the leaf area index considering different land covers in a Brazilian atlantic forest area. **Modeling Earth Systems and Environment**, v. 11, n. 104, p. 1-10, 2025. [doi](#)
- NI, W.; REN, K.; LU, L. Evapotranspiration estimation and prediction for oasis transect in middle reach of Heihe River Basin based on METRIC and CA_Markov model. **7th International Conference on Agro-geoinformatics (Agro-geoinformatics)**, IEEE, p. 1-6, 2018. [doi](#)
- OLIVEIRA, R.A.; NERY, L.M.; ANDRADE, E.L.; SIMONETTI, V.C.; ARANTES, L.T.; *et al.* Methodological proposal for an ecological corridor and financial cost estimate: a way to help conserve biodiversity. **Journal For Nature Conservation**, v. 79, 126606, 2024. [doi](#)
- OYEBODE, O.; STRETCH, D. Neural network modeling of hydrological systems: a review of implementation techniques. **Natural Resource Modeling**, v. 32, n. 1, e12189, 2018. [doi](#)
- PHAM, B.T.; NGUYEN, M.D.; BUI, K.-T.T.; PRAKASH, I.; CHAPI, K.; *et al.* A novel artificial intelligence approach based on multi-layer perceptron neural network and biogeography-based optimization for predicting coefficient of consolidation of soil. **CATENA**, v. 173, p. 302-311, 2019. [doi](#)
- RAHIMIKHOOB, A. Estimation of evapotranspiration based on only air temperature data using artificial neural networks for a subtropical climate in Iran. **Theoretical and Applied Climatology**, v. 101, n. 1-2, p. 83-91, 2009. [doi](#)
- RAIHAN, A. A comprehensive review of the recent advancement in integrating deep learning with geographic information systems. **Research Briefs on Information & Communication Technology Evolution**, v. 9, n. 6, p. 98-115, 2023. [doi](#)
- SAPUTRA, M.H.; LEE, H.S. Prediction of land use and land cover changes for North Sumatra, Indonesia, using an artificial-neural-network-based cellular automaton. **Sustainability**, v. 11, n. 11, 3024, 2019. [doi](#)
- SIMONETTI, V.C.; FRASCARELI, D.; GONTIJO, E.S.J.; MELO, D.S.; FRIESE, K.; *et al.* Water quality indices as a tool for evaluating water quality and effects of land use in a tropical catchment. **International Journal of River Basin Management**, v. 17, n. 2, p. 157-168, 2019. [doi](#)
- USGS, UNITED STATES GEOLOGICAL SURVEY. **Landsat 8**. Disponível em <https://www.usgs.gov/landsat-missions/landsat-8/>, acesso em 28 abr. 2024.
- WALLS, S.; BINNS, A.D.; LEVISON, J.; MACRITCHIE, S. Prediction of actual evapotranspiration by artificial neural network models using data from a Bowen ratio energy balance station. **Neural Computing and Applications**, v. 32, p. 14001-1418, 2020. [doi](#)
- WATERS, R.; ALLEN, R.; TASUMI, M.; TREZZA, R.; BASTIAANSEN, W. Surface energy balance algorithms for land: advanced training and users manual. **Idaho Department of Water Resources**, 2002. Disponível em: <https://posmet.ufv.br/wp-content/uploads/2017/04/MET-479-Waters-et-al-SEBAL.pdf>, acesso em 11 jul. 2025.
- YASSIN, M.A.; ALAZBA, A.A.; MATTAR, M.A. Artificial neural networks versus gene expression programming for estimating reference evapotranspiration in arid climate. **Agricultural Water Management**, v. 163, p. 110-124, 2016. [doi](#)
- YING, X. An overview of overfitting and its solutions. **Journal of Physics: Conference Series**, v. 1168, n. 2, 022022, 2019. [doi](#)
- ZANETTI, S.S.; SOUSA, E.F.; OLIVEIRA, V.P.; ALMEIDA, F.T.; BERNARDO, S. Estimating evapotranspiration using artificial neural network and minimum climatological data. **Journal of Irrigation and Drainage Engineering**, v. 133, n. 2, p. 83-89, 2007. [doi](#)
- ZHANG, K.; KIMBALL, J.S.; RUNNING, S.W. A review of remote sensing based actual evapotranspiration estimation. **Wires Water**, v. 3, n. 6, p. 834-853, 2016. [doi](#)

Endereços de Internet

MapBiomass, <https://brasil.mapbiomas.org/>.



License information: This is an open-access article distributed under the terms of the Creative Commons Attribution License (type CC-BY), which permits unrestricted use, distribution and reproduction in any medium, provided the original article is properly cited.