

● REVISTA

INOVA Ciência & Tecnologia

● CIÊNCIAS EXATAS E DA TERRA
CIÊNCIA DA COMPUTAÇÃO

COMPARAÇÃO DE MODELOS *PERCEPTRON* MULTICAMADAS NA ESTIMATIVA DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA

*[Roberto Luís da Silva Carvalho](#)¹ , [Angel Ramon Sanchez Delgado](#)² 

1 Instituto Federal de Educação, Ciência e Tecnologia Fluminense, Campus Bom Jesus do Itabapoana (IFF-CBJI), Bom Jesus do Itabapoana, RJ, Brasil.

2 Universidade Federal Rural do Rio de Janeiro, (UFRRJ), Seropédica, RJ, Brasil.

RESUMO: O estudo teve como objetivo modelar por redes neurais artificiais *perceptron* multicamadas (RNA-MLP) a evapotranspiração de referência ET_0 , em função das variáveis climáticas para o município de Ariquemes – RO. Para a caracterização das séries temporais das temperaturas do ar (médias, máximas e mínimas), umidade do ar e precipitação pluviométrica foram utilizados os dados disponíveis no Instituto Nacional de Meteorologia - INMET, obtidos na estação meteorológica automática de Ariquemes/RO, no período de janeiro de 2011 até dezembro de 2013. Os dados da evapotranspiração utilizados foram calculados seguindo o modelo Penman-Monteith-FAO. Dentre os resultados, observou-se que a utilização de modelos RNA-MLP com variáveis de mais simples obtenção, entre elas a precipitação chuvosa, temperatura do ar e umidade foram satisfatórias para estimar a ET_0 , pois foram consideradas como “muito boas” no índice de concordância.

* **Autor correspondente:**
roberto.carvalho@iff.edu.br

Recebido: 18/02/2021.
Aprovado: 30/06/2021.

Como citar: Carvalho, R. L. da S., & Delgado, A. R. S. (2022). Comparação de modelos perceptron multicamadas na estimativa da evapotranspiração de referência. *Revista Inova Ciência & Tecnologia / Innovative Science & Technology Journal*, 2022;8:e0221213
doi.org/10.46921/riict2022-1213

Editores:

Dr. Adelar Jose Fabian 
Dr. Hugo Leonardo Pereira Rufino 

Copyright: este é um artigo de acesso aberto distribuído sob os termos da Licença de atribuição Creative Commons, que permite uso irrestrito, distribuição, e reprodução em qualquer meio, desde que o autor original e a fonte sejam creditados.

Palavras-chave: Penman-Monteith-FAO. Séries temporais. Modelagem.

COMPARISON OF MULTILAYER PECEPTRON MODELS IN THE ESTIMATION OF REFERENCE EVAPOTRANSPIRATION

ABSTRACT: The aim of the study was to model by artificial neural networks multilayer perceptron (RNA-MLP) the reference evapotranspiration (ET_0) with climatic variables for the municipality of Ariquemes - RO. To characterize the time series of air temperatures (average, maximum and minimum), air humidity and rainfall, the data available at the National Institute of Meteorology (INMET) of Ariquemes / RO, from January 2011 to December 2013 was used. The evapotranspiration data that was used in the study was calculated following the Penman-Monteith-FAO model. Among the results, it was observed that the use of RNA-MLP models with variables of simpler obtain, among them the rainy precipitation, air temperature and humidity were satisfactory to estimate the ET_0 , because they were considered as “very good” in the concordance index.

Keywords: Penman-Monteith-FAO. Time series. Modelling.



INTRODUÇÃO

A otimização dos recursos hídricos é um fator essencial para o desenvolvimento de qualquer processo agrícola. Especificamente no que tange à irrigação, o dimensionamento do uso da água é objeto de estudo por diversos pesquisadores. Nesse contexto, utiliza-se a evapotranspiração de uma cultura agrícola (ET_c), medida baseada na composição da evapotranspiração de referência (ET_0) (DOORENBOS; PRUITT, 1977) com o coeficiente da cultura (k_c), para dimensionar o uso da água (ALVES SOBRINHO *et al.*, 2011; CARVALHO *et al.*, 2011; PEIXOTO *et al.*, 2010). Segundo Araujo; Reis e Moreira (2011), um fator que precisa ser sempre aprimorado para o gerenciamento da irrigação no Brasil é a qualidade das informações sobre o uso da água pelas culturas, pois considera-se de suma importância o entendimento das variáveis com maior relevância na estimativa da evapotranspiração de referência, já que tal entendimento facilita na seleção dos modelos ajustados por região. Nesse aspecto, Tanaka *et al.* (2016) consideram que calibrações locais e regionais, bem como a avaliação de desempenho estatístico de modelos, são importantes para avaliar os erros nas estimativas da ET_0 . Por outro lado, a aplicação de outros métodos de estimação pode trazer um ganho na estimativa de ET_0 , como por exemplo a relação estrutural entre as variáveis correlacionadas com o fenômeno de evapotranspiração.

A evapotranspiração (ET) é definida como um processo combinado de transferência de água para a atmosfera por evaporação da água do solo e por transpiração das plantas (DOORENBOS; PRUITT, 1977; MENDONÇA *et al.* 2003; TESTEZLAF, 2011). Esse processo pode ser desmembrado nas componentes: transpiração, evaporação de água interceptada, evaporação do solo e evaporação de superfícies livres de água. Alves Sobrinho *et al.* (2011) consideram que a estimação de ET_0 para uma determinada região contribui com o planejamento de sistemas de irrigação, e com o desenvolvimento de modelos meteorológicos e hidrológicos que são fatores importantes na gestão de bacias hidrográficas.

A modelagem por redes neurais multicamadas (RNA) tem sido objeto de estudo por parte de pesquisadores que buscam melhor prever as variáveis climatológicas, neste sentido, Alves Sobrinho *et al.* (2011) estimaram a ET_0 da região de Dourados (MS), em função de dados diários de temperatura do ar, para o período de janeiro de 2005 a outubro de 2008. Os autores utilizaram a RNA do tipo *Feed Forward Multilayer Perceptron* para modelagem com variações do número de neurônios nas camadas intermediárias. Nessa modelagem, nas camadas intermediárias foram utilizadas funções de ativação do tipo tan-sigmóide e na camada de saída foram utilizadas funções de ativação do tipo lineares. Os resultados foram considerados satisfatórios. Ferraz (2014) utilizou uma rede neural artificial (RNA) para estimar a ET_0 em função de dados climáticos e coordenadas geográficas no Estado do Rio Grande do Sul. Coutinho; Silva e Delgado (2016) aplicaram modelos de redes neurais de perceptrons de múltiplas camadas (MLP) e função de base radial (RBF) na predição de um passo à frente, em dados dos municípios de Paty do Alferes e Paracambi – RJ.

Diversos estudos sugerem níveis de correlações (forte, mediana ou fraca) entre as variáveis climáticas e a ET_0 , por exemplo, no estudo realizado em Araujo; Reis e Moreira (2011) com dados do município de Alegre (ES) foram verificadas correlações fortes com as variáveis temperatura média ($r = 0,7932$), saldo da radiação solar (R_s) ($r = 0,9332$) e umidade relativa (UR) ($r = -0,7035$), sendo esta negativa, ou seja, conforme aumenta a umidade, diminui a ET_0 e vice-versa. Por outro lado, observaram correlação fraca ($r = 0,2876$) com a velocidade do vento (U_2) e correlação nula ($r = 0,0293$) com o fluxo de calor no solo (G).

Conceição e Marin (2004) citaram em seu estudo que, conforme as condições climáticas locais e a época do ano, as variáveis climáticas têm importância diferenciada na estimativa da ET_0 , sendo assim, buscaram identificar as principais correlações existentes na região de Jales, São Paulo – Brasil. Observou-se que a radiação solar incidente apresentou maior efeito sobre a ET_0 da região. Já Alves Sobrinho *et al.* (2011) modelaram a ET_0 por RNA sugerindo como principal fator de influência a temperatura, sendo assim, utilizaram somente as medidas de temperatura máxima, mínima e média diária em seus modelos. No que segue são consideradas como variáveis de entrada as temperaturas (média, máxima e mínima diárias do ar), umidade e precipitação pluviométrica. De modo a otimizar a aplicação dos modelos, o processo de ajuste garantirá a parcimônia do modelo, ou seja, serão utilizadas variáveis mais facilmente encontradas nas estações climáticas. Deve-se considerar que um bom modelo deverá ter pelo menos estas quatro qualidades fundamentais: parcimônia, generalidade, consiliência (em unidade com o conhecimento consolidado) e capacidade preditiva (MASSAD, 2004).

Nesse estudo busca-se comparar os resultados ajustados nos modelos RNA-MLP, com os valores estimados pelo método de estimação do padrão FAO. Como o padrão FAO é o método reconhecido para a estimação da ET_0 , pretende-se tomá-lo como referência para a modelagem por redes neurais multicamadas

Neste sentido, o objetivo do estudo é modelar por redes neurais artificiais perceptron multicamadas (RNA-MLP) a evapotranspiração de referência (ET_0), em função das variáveis climáticas para o município de Ariquemes (RO).

MATERIAL E MÉTODOS

Ariquemes é um município ao noroeste do estado de Rondônia, localizado a uma latitude $09^{\circ} 54' 48''$ e a uma longitude $63^{\circ} 02' 27''$ oeste, estando a uma altitude de 142 metros. Sua população estimada é de 107.345 habitantes (IBGE, 2017) e possui uma área de 4.427 km². O clima de Ariquemes é definido como Aw (clima quente de moção) na classificação de Köppen (ALVARES *et al.*, 2014). Este é predominantemente quente e úmido, pois consiste basicamente em muito calor e umidade intercalados com um período de seca de 3 meses, um período de chuva de 7 meses e 2 meses de transição (CARVALHO *et al.*, 2016).

Para a caracterização das séries temporais das temperaturas do ar (médias, máximas e mínimas), umidade do ar e precipitação pluviométrica foram utilizados os dados diários disponíveis no Instituto Nacional de Meteorologia - INMET, obtidos na estação Meteorológica Automática de Ariquemes/RO, no período de janeiro de 2011 até dezembro de 2013. A torre de estação meteorológica está situada nas coordenadas geográficas 09° 56' S e 62° 57' W, em 140 metros acima do nível do mar. Os gráficos das variáveis climáticas foram publicados por Carvalho *et al.* (2016).

Os dados da evapotranspiração utilizados no estudo foram calculados seguindo o modelo Penman-Monteith-FAO (ALLEN *et al.*, 1998) e publicados por Carvalho e Delgado (2016) para a região de Ariquemes (RO). A evapotranspiração de referência é definida como a evapotranspiração de uma cultura hipotética (normalmente grama) que cobre todo o solo, em crescimento ativo, sem restrição hídrica e nutricional, com parâmetros de altura entre 0,08 metro (m) a 0,15 m, albedo igual a 0,23 e resistência da cultura ao transporte de vapor d'água igual a 70 segundos por metro (s m⁻¹) (ALLEN *et al.*, 1998; CARVALHO *et al.*, 2011).

O método de estimativa padrão FAO é sintetizado em (1) (ALLEN *et al.*, 1998):

$$ET_o = \frac{0,408 \Delta (R_n - G) + \gamma \frac{900}{T+273} U_2 (e_s - e_a)}{\Delta + \gamma (1 + 0,34 U_2)} \quad (1)$$

em que:

- ET_o - Evapotranspiração de referência (mm d⁻¹);
- Δ - Declividade da curva de pressão de vapor na saturação versus temperatura do ar (KPa °C⁻¹);
- R_n - Saldo de radiação na superfície do cultivo (MJ m⁻² d⁻¹);
- G - Densidade de fluxo de calor no solo (MJ m⁻² d⁻¹), sendo (G = 0) para dados diários;
- γ - Constante psicrométrica (KPa °C⁻¹);
- U₂ - Velocidade do vento a 2 m de altura (m s⁻¹);
- e_s - Pressão de vapor na saturação KPa °;
- e_a - Pressão de vapor atual, KPa °;
- T - Temperatura média do ar tomada a 2 m de altura (°C).

O cálculo de T é definido por: $T = \frac{T_{Max} + T_{Min}}{2}$. A declividade da curva de saturação Δ foi calculada em (2):

$$\Delta = \frac{4098 \left[0,6108 \exp \left(\frac{17,27 T}{T+237,3} \right) \right]}{(T+237,3)^2} \quad (2)$$

A constante psicrométrica γ foi calculada pela expressão (3):

$$\gamma = 0,665 \times 10^{-3} Patm. \quad (3)$$

Por sua vez a pressão atmosférica local (4) (Patm) foi calculada com base na altitude local (z), em metros:

$$Patm = 101,3 \left(\frac{293 - 0,0065 z}{293} \right)^{5,26} \quad (4)$$

A saturação da pressão de vapor de uma determinada temperatura t é calculada por (5):

$$e^0(t) = 0,6108 \exp \left[\frac{17,27 t}{t+237,3} \right].$$

Com isso, para se encontrar os valores da pressão

de vapor saturação (e_s) e pressão de vapor atual (e_a) foram utilizadas as expressões (6) e (7):

$$e_s = \frac{e^0(T_{max}) + e^0(T_{min})}{2} \quad (5)$$

e

$$e_a = \frac{e^0(T_{min}) \frac{UR_{max}}{100} + e^0(T_{max}) \frac{UR_{min}}{100}}{2} \quad (6)$$

em que UR é a umidade relativa do ar (%).

O déficit de saturação foi calculado pela diferença destas expressões (e_s - e_a). A estimativa do saldo de radiação (Rn) foi obtida em (8):

$$Rn = Rns - Rnl.$$

Rns é o saldo da radiação de ondas curtas (MJ m⁻² d⁻¹), obtido por Rns = (1 - α)Rs, com o valor de α = 0,23 referente ao coeficiente de reflexão da vegetação (albedo) e Rs é radiação solar incidente (MJ m⁻² d⁻¹), mensurada na estação meteorológica. Rnl é o saldo de radiação de ondas longas, calculada por (9):

$$Rnl = \sigma \left[\frac{(T_{max} + 273,16)^4 + (T_{min} + 273,16)^4}{2} \right] (0,34 - 0,14 \sqrt{e_a}) \left(1,35 \frac{R_s}{R_{so}} - 0,35 \right). \quad (9)$$

em que:

σ é a constante de Stefan-Boltzmann (4,903 × 10⁻⁹ MJ m⁻² d⁻¹); T_{max} e T_{min} são as temperaturas máximas e mínimas, em °C, do dia, respectivamente. A radiação solar incidente na ausência de nuvens (Rso) foi calculada por (10):

$$Rso = (0,75 + 2 \times 10^{-5} z) Ra \quad (10)$$

Para obtenção dos objetivos do estudo, buscou-se ajustar redes neurais MLP, sendo assim, a seguir serão descritas as principais estratégias da modelagem. Nos modelos ajustados foram consideradas as seguintes variáveis:

- Y = ET_o - Evapotranspiração de referência (mm d⁻¹);
- X₁ - Precipitação (mm/dia);
- X₂ - Umidade Relativa do Ar (%);
- X₃ - Temperatura Média Diária (°C);
- X₄ - Temperatura Máxima Diária (°C);
- X₅ - Temperatura Mínima Diária (°C).

Para essas variáveis, foram realizados os testes de raiz unitária KPSS - Kwiatkowski-Phillips-Schmidt-Shin (KWIATKOWSKI *et al.*, 1992) e PP - Phillips-Perron (PHILLIPS; PERRON, 1988), visando a identificação de estacionariedade das séries, premissa esta, que foi atendida para os ajustes dos modelos. Os p-valores observados no teste KPSS foram os seguintes 0,10; 0,10; 0,09; 0,10; 0,73; 0,10, respectivamente. Já para o teste PP os p-valores observados foram: 0,01; 0,01; 0,01; 0,01; 0,01; 0,01, respectivamente.

As redes neurais *perceptrons* de múltiplas camadas (MLP) possuem uma estrutura com a camada de entrada, pelo menos uma camada oculta (nós computacionais) e uma camada de saída. O sistema de treinamento da MLP funciona basicamente da seguinte maneira: a aprendizagem consiste em um passo à

frente, chamada de propagação (pesos sinápticos fixos), e um passo atrás, chamada de retropropagação do erro (pesos ajustados de acordo com a regra de correção). Este algoritmo é também conhecido como *error back-propagation* (HAYKIN, 2001).

Uma rede *perceptron* de múltiplas camadas possuiu as seguintes características (HAYKIN, 2001):

- 1 - Cada neurônio da rede é modelado com uma função de ativação não-linear. Geralmente se utiliza a função sigmoide (função logística), descrita por:

$$y_j = \frac{1}{1 + \exp(-v_j)} \quad (11)$$

tendo v_j como o campo local induzido (soma ponderada de todas as entradas sinápticas acrescidas das bias) do neurônio j , e y_j é a saída de cada neurônio.

- 2 - Contém uma ou mais camadas de neurônios ocultos, com o objetivo de capacitar a rede a aprender tarefas complexas extraindo progressivamente as características mais significativas dos padrões (vetores) de entrada.
- 3 - A rede exibe muita conectividade, determinado pelas sinapses da rede. Uma modificação na conectividade da rede requer uma mudança na população de conexões sinápticas ou de seus pesos.

Objetiva-se na rede neural comparar o valor de entrada no sistema com o real valor de saída que é desejado ou que se tem como objetivo a perseguir. Com isso ocorre o treinamento do sistema em um modo de aprendizado supervisionado, em que os valores reais e os de saída são comparados. Sendo assim, avaliam-se os valores residuais e caso não sejam satisfatórios, ocorre um novo ajuste no modelo visando diminuir os valores residuais.

De acordo com o teorema de Kolmogorov-Nielsen, no qual se afirma que dada uma função contínua arbitrária, existe sempre para essa função uma implementação exata com uma rede neural de três camadas, sendo a camada de entrada um vetor de dimensão n , a camada oculta composta por $(2n+1)$ neurônios, e a camada de saída com m neurônios representando as m componentes do vetor y , teoricamente basta uma camada oculta na rede. Justificando assim a aplicação das redes neurais para modelar fenômenos lineares e não lineares (MURTGATH, 1994; KOVACS, 2002).

O pacote "*neuralnet*" (FRITSCH; GUENTHER, 2016) do software R (R CORE TEAM, 2016) trabalha com os modelos *perceptron* multicamadas, nos quais busca identificar as relações funcionais entre as variáveis. Os neurônios são organizados em camadas, que são ligados pelas sinapses. No caso do *neuralnet*, uma sinapse só pode se conectar a camadas posteriores. A camada de entrada é composta pelas variáveis independentes (X_i), com $i=1,2,3,\dots,k$, enquanto a camada de saída é composta pela variável resposta (Y); por fim, as camadas intermediárias são denominadas de camadas ocul-

tas (Co), ou variáveis latentes. As camadas de entrada e as camadas ocultas incluem um neurônio constante (intercepto - I), sendo este não influenciado por qualquer covariável. Utilizou-se 70% da amostra para treinamento da rede e 30% para teste da rede neural.

Para atender as demandas do pacote *neuralnet* e da função de ativação (logística) e até mesmo para minimizar os efeitos das diferenças nas escalas das variáveis climáticas, os dados foram padronizados (12) para o intervalo $[0,1]$:

$$y_t = \frac{x_t - x_{min}}{x_{max} - x_{min}} \quad (12)$$

sendo x_t o valor observado da variável x no instante t , x_{min} e x_{max} os valores de mínimo e máximo da variável, respectivamente. Ao final do processo de ajuste os valores são transformados (13) para a escala original da ET_0 :

$$x_t = y_t(x_{max} - x_{min}) + x_{min}. \quad (13)$$

Para a análise de dados foi utilizado o software R Versão 3.3.1 (R CORE TEAM, 2016) com os pacotes *nnet* (VENABLES; RIPLEY, 2002) e *neuralnet* (FRITSCH; GUENTHER, 2016) para redes neurais.

A programação em R foi editada no software *Tinn-R GUI/Editor for R Environment* versão 5.01.02.00 (FARIA *et al.*, 2016). O procedimento para a análise de dados se inicia com um análise exploratória dos dados procurando identificar valores médios observados, valores máximos e mínimos para o período e a identificação de possíveis erros ou valores extremos.

Seguidamente, foram ajustados os modelos RNA-MLP para a ET_0 , neste caso, tomou-se como melhor modelo ajustado aquele com menor erro quadrático médio dos valores preditos. Ressalta-se que neste estudo os dados da ET_0 foram calculados pelo método Penman-Monteith-FAO, ou seja, um método indireto. Sendo assim, a medida do erro quadrático médio será uma *proxy* do valor real. O erro quadrático médio - EQM (*Mean Square Error* - MSE) é definido por (14):

$$EQM = \frac{1}{n} \sum_{i=1}^n \epsilon_i^2 \quad (14)$$

em que n é o número de prognósticos (MONTGOMERY; RUNGER, 2009; WILKS, 2006).

Para comparação dos métodos, foram utilizadas as seguintes medidas: índice de concordância (d), coeficiente de confiança (c) (WILLMOTT *et al.*, 1985; CAMARGO; SENTELHAS, 1997) e o coeficiente de correlação (r) (MONTGOMERY; RUNGER, 2009).

Segundo Willmott *et al.* (1985), o índice de concordância (d) expressa a aproximação dos valores de ET_0 estimados pelos modelos e o método Penman-Monteith, que é o método padrão da FAO. Foi utilizado o pacote *hydroGOF* do R (ZAMBRANO-BIGIARINI, 2017) para o cálculo do índice. Sua estatística é determinada por (15):

$$d = 1 - \left[\frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \right], \quad (15)$$

com:

- P_i- Valor estimado pelos modelos e suas variações (mm d⁻¹);
- O_i- Valor calculado pelo método de Penman-Monteih (mm d⁻¹);
- \bar{O} - Média dos valores calculada pelo método de Penman-Monteih.

O coeficiente de correlação de Pearson (r) é calculado (16):

$$r = \frac{\sum_{i=1}^n P_i O_i - n \bar{P} \bar{O}}{\sqrt{(\sum_{i=1}^n P_i^2 - n \bar{P}^2)(\sum_{i=1}^n O_i^2 - n \bar{O}^2)}} \quad (16)$$

Este coeficiente varia no intervalo [-1, 1], isto é, -1 ≤ r ≤ 1, em que P é a média dos valores estimados pelos modelos. No entanto, espera-se que a correlação entre as estimativas seja sempre positiva; ou seja, 0 ≤ r ≤ 1. O coeficiente de correlação (r) pode ser classificado como: “muito baixo” (|r| < 0,1); “baixo” (0,1 < |r| < 0,3); “moderado” (0,3 < |r| < 0,5); “alto” (0,5 < |r| < 0,7); “muito alto” (0,7 < |r| < 0,9); e “quase perfeito” (|r| > 0,9) (COHEN,

1988). O coeficiente de concordância (c) ou de ajuste de Willmott (17) é dado por:

$$c = r \times d. \quad (17)$$

Este índice mede o desempenho de acordo com as seguintes classes sugeridas por Camargo e Sentelhas (1997): péssimo, c ≤ 0,40; mau, 0,41 ≤ c ≤ 0,50; sofrível, 0,51 ≤ c ≤ 0,60; mediano, 0,61 ≤ c ≤ 0,65; bom, 0,66 ≤ c ≤ 0,75; muito bom, 0,76 ≤ c ≤ 0,85; e ótimo, c > 0,85.

RESULTADOS E DISCUSSÃO

As estatísticas descritivas das séries climáticas para o período de janeiro de 2011 a dezembro de 2013 estão apresentadas na Tabela 1; não foram observados valores discrepantes para a localidade.

Tabela 1. Estatísticas descritivas das séries temporais climáticas do Município de Ariquemes (RO) no período de janeiro de 2011 a dezembro de 2013.

Séries Climáticas	Média	Mediana	Desvio Padrão	Mínimo	Máximo
Precipitação (mm/dia)	6,27	0,20	14,16	0,00	120,80
Umidade Relativa do Ar (%)	80,63	82,94	8,69	39,79	94,33
Temperatura Média (°C)	25,64	25,71	1,25	17,86	29,08
Temperatura Máxima (°C)	32,05	32,10	2,52	23,60	38,10
Temperatura Mínima (°C)	21,79	22,30	1,76	13,10	24,50
Evapotranspiração de Referência ETo (mm/dia)	4,03	4,11	0,97	1,06	6,76

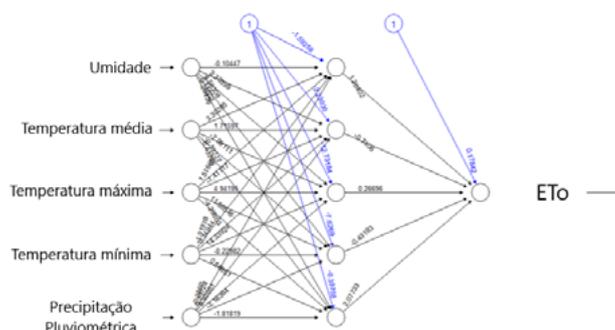
A seguir será descrito o histórico de ajuste (Tabela 2) da rede neural com as variáveis precipitação pluviométrica, umidade e temperaturas (máxima, mínima e média), variáveis que são de encontradas com maior facilidade. Inicialmente, foi ajustado um modelo com 3 variáveis, seguidamente 4 e por fim 5 variáveis.

Tabela 2: Histórico de ajuste dos modelos com até 5 variáveis da ETo.

Variáveis	Quantidade de variáveis	Quantidade de nós	Camadas ocultas	Erro	EQM
Precipitação, Umidade, Temperatura média	3	3	1	3,85258	0,22863
Umidade, Temperaturas máxima, mínima e média	4	4	1	3,57293	0,21203
Umidade, Temperaturas máxima, mínima e média e precipitação	5	5	1	3,50569	0,21192

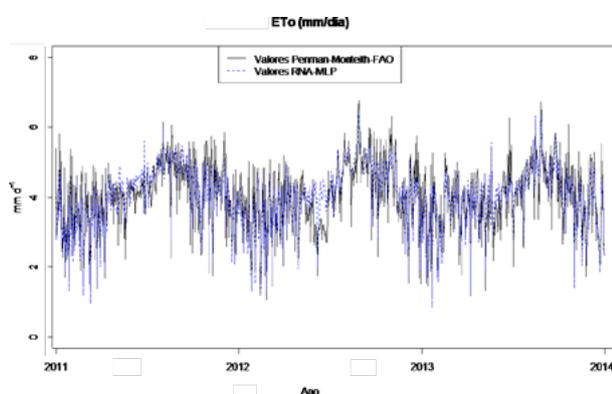
Observa-se na Tabela 2 que somente com as três variáveis climáticas o EQM = 0,22863, mas com 5 variáveis o EQM observado foi de 0,21192, obtendo-se um ganho modesto. A Figura 1, apresenta a estrutura da Rede Neural MLP.

Figura 1. Estrutura da rede neural MLP para a ETo, com as variáveis independentes umidade média, precipitação, temperaturas máxima, mínima e média



Observou-se correlação forte positiva entre as estimativas Penman-Monteith-56 com as estimativas do modelo RNA ($r = 0,878$; $p = 0,000$). Da mesma forma, foram observados bons índices de concordância (d) com as estimativas da RNA ($d = 0,932$). Resultando, assim, em níveis muito bons nos coeficientes de concordância (c), segundo a escala proposta por Camargo e Sentelhas (1997), para as modelagens RNA-MLP ($c = 0,818$). De acordo com esses índices, observou-se que as modelagens obtiveram resultados similares quanto ao ajuste aos dados estimados pelo padrão FAO, no entanto, se configura um ganho visto que estes modelos foram ajustados com variáveis de mais simples obtenção, como temperatura, umidade e precipitação pluviométrica. Os valores ajustados e observados são apresentados na Figura 2.

Figura 2. Valores observados e ajustados da rede neural MLP para a ET_0



No estudo realizado por Alves Sobrinho *et al.* (2011), os autores afirmaram como satisfatória a eficiência da modelagem por redes neurais artificiais (RNA) para estimar a evapotranspiração de referência (ET_0) em função de dados diários de temperatura do ar. No estudo foi utilizada uma RNA, do tipo *Feed-Forward Multilayer Perceptron*, treinada tomando-se por referência a (ET_0) diária obtida pelo método de Penman-Monteith. No entanto, os resultados foram comparados com os métodos de estimativa Blanney-Cridle-Hargreaves de (ET_0). Por sua vez, Ferraz (2014) propôs uma RNA para estimar a (ET_0) em função de dados climáticos e coordenadas geográficas no Estado do Rio Grande do Sul. Da mesma forma, utilizou-se o tipo *perceptron* de múltiplas camadas para estimativa, obtendo-se índices ótimos de desempenho; neste caso, os autores ressaltaram a qualidade das estimativas, afirmando que as RNAs são ferramentas poderosas para estimativa.

No estudo com objetivo de modelar a evapotranspiração em quatro áreas de ecossistema de campo, os autores Dou e Yang (2018) compararam a eficiência dos modelos com sistemas de aprendizagem (Redes Neurais Artificiais, Sistema de Inferência Adaptativo Neurofuzzy, Máquina de Suporte de Vetores, Rede Neural de Regressão Geral, Máquina de aprendizado extremo, dentre outros). Dentre os resultados, verificam que os modelos com redes neurais são capazes de aproveitar a relação não linear entre a ET_0 e as variáveis ambientais.

CONCLUSÕES

1 - A utilização de modelos RNA-MLP com variáveis de mais simples obtenção, entre elas a precipitação chuvosa, temperatura do ar e umidade foram satisfatórias para estimar a ET_0 , pois, foram consideradas como “muito boas” no índice de concordância (c);

2 - Os modelos RNA-MLP se configuraram como opções de ajustes para os dados climáticos; no entanto, futuros estudos são sugeridos em outras áreas do conhecimento.

AGRADECIMENTOS

À Fundação de Apoio à Pesquisa de Rondônia (FAPERO).

REFERÊNCIAS

- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop evapotranspiration: guidelines for computing crop water requirements**. Rome: FAO, 1998. 300 p. (Irrigation and Drainage Paper, 56).
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2014.
- ALVES SOBRINHO, T.; RODRIGUES, D. B. B.; OLIVEIRA, P. T. S.; REBUCCI, L. C. S.; PERTUSSATTI, C. A. Estimativa da evapotranspiração de referência através de redes neurais artificiais. **Revista Brasileira de Meteorologia**, v. 26, n. 2, p. 197-203, 2011.
- ARAÚJO, G. L.; REIS, E. F.; MOREIRA, G. R. Correlações entre variáveis climatológicas e seus efeitos sobre a evapotranspiração de referência. **Revista Brasileira de Agricultura Irrigada**, v. 5, n. 2, p. 96-104, 2011.
- CAMARGO, A. P.; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativas da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, v. 5, n. 1, p. 8997, 1997.
- CARVALHO, L. G.; RIOS, G. F. A.; MIRANDA, W. L.; CASTRO NETO, P. Evapotranspiração de referência: uma abordagem atual de diferentes métodos de estimativa. **Pesquisa Agropecuária Tropical**, v. 41, n. 3, p. 456-465, 2011.
- CARVALHO, R. L. S.; DELGADO, A. R. S. Estimativas da evapotranspiração de referência do município de Ariquemes (RO) utilizando os métodos Penman-Monteith-FAO e Hargreaves-Samani. **Revista Brasileira de Agricultura Irrigada**, v. 10, n. 6, p. 1038 - 1048, 2016.
- CARVALHO, R. L. S.; NASCIMENTO, B. I. S.; QUERINO, C. A. S.; SILVA, M. J. G.; DELGADO, A. R. S. Comportamento das séries temporais de temperatura do ar, umidade e precipitação pluviométrica no município de Ariquemes (Rondônia-Brasil). **Revista Brasileira de Climatologia**, v. 18, n. 12, p. 123-142, 2016.

- COHEN, J. **Statistical power analysis for the behavioral sciences**. New Jersey: Lawrence Erlbaum, 1988. 569p.
- CONCEIÇÃO, M. A. F.; MARIN, F. R. Efeito de variáveis meteorológicas sobre a evapotranspiração de referência em uma região de clima tropical úmido do Brasil. In: REUNIÓN ARGENTINA Y LATINOAMERICANA DE AGROMETEOROLOGIA, 10., 2004, Mar del Plata, Argentina. **Anais...** Mar del Plata, Argentina: AADA, 2004. Disponível em: <<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/120322/1/1006.pdf>>. Acesso em: 18 dez. 2017.
- COUTINHO, E. R.; SILVA, R. M.; DELGADO, A. R. S. Utilização de técnicas de inteligência computacional na predição de dados meteorológicos. **Revista Brasileira de Meteorologia**, v. 31, n. 1, p. 24-36, 2016.
- DOORENBOS, J.; PRUITT, W. O. **Guidelines for predicting crop water requirements**. Rome: FAO, 179p. 1977. (FAO: Irrigation and Drainage Paper, 24).
- DOU, X.; YANG, Y. Modeling evapotranspiration response to climatic forcings using data-driven techniques in grassland ecosystems. **Advances in Meteorology**, v.1, p. 1-18. 2018. <https://doi.org/10.1155/2018/1824317>.
- FARIA, J. C.; GROSJEAN, P.; JELIHOVSCHI, E. G.; PIETROBON, R. FARIAS, P. S.; KRAMER, P. A. R.; LIMA, S. P. **Tinn-R GUI/Editor for R Environment**. 2016. Disponível em: <<https://tinn-r-editor-gui-for-r-language-and-environment.en.softonic.com/>>. Acesso em: 01 nov. 2016.
- FERRAZ, R. C. Estimativa de evapotranspiração de referência utilizando redes neurais artificiais para o estado do Rio Grande do Sul. **Revista Tecnológica**, v. 23, n. 1, p. 25-31, 2014.
- FRITSCH, S.; GUENTHER, F. **Neuralnet**: training of neural networks. 2016. R package version 1.33. Disponível em: <<https://CRAN.R-project.org/package=neuralnet>>. Acesso em: 16 jul. 2018.
- HAYKIN, S. **Redes neurais**: princípios e prática. Tradução: Paulo Martins Engel. 2.ed. Porto Alegre: Bookman, 2001.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Diretoria de Pesquisas, Coordenação de População e Indicadores Sociais. **Estimativas da população residente no Brasil e unidades da federação com data de referência em 1º de julho de 2017**. 2017. Disponível em: ftp://ftp.ibge.gov.br/Estimativas_de_Populacao/Estimativas_2017/estimativa_2017_TCU.pdf. Acesso em: 14 nov. 2017.
- KOVACS, Z. L. **Redes neurais artificiais**: fundamentos e aplicações. 4.ed. São Paulo: Livraria da Física, 2002. 174p.
- KWIATKOWSKI, D.; PHILLIPS, P. C. B.; SCHMIDT, P.; SHIN, Y. Testing the null hypothesis of stationarity against the alternative of a Unit Root. **Journal of Econometrics**, v. 54, p. 159-178, 1992.
- MASSAD, E. Modelos matemáticos em biomedicina. In: MASSAD, E., MENEZES, R. X.; SILVEIRA, P. S. P.; ORTEGA, N. R. S. (Org.). **Métodos quantitativos em medicina**. Barueri: Manole, 2004.
- MENDONÇA, J. C.; SOUSA, E. F.; BERNARDO, S.; DIAS, G. P.; GRIPPA, S. Comparação entre métodos de estimativa da evapotranspiração de referência (Eto) na região Norte Fluminense, RJ. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 7, n. 2, p. 275-279, 2003.
- MONTGOMERY, D. C.; RUNGER, G. C. **Estatística aplicada e probabilidade para engenheiros**. Tradução: Verônica Calado. 4.ed. Rio de Janeiro: LTC, 2009.
- MURTGATH, F. Neural networks and related "massively parallel" methods for statistics: a short review. **International Statistical Review**, v. 62, n. 3, p. 275-88, 1994.
- PEIXOTO, T. D. C.; LEVIEN, S. L. A.; BEZERRA, A. H. F.; SOBRINHO, J. E. Evapotranspiração de referência utilizando métodos de tanque classe A propostos pela FAO, na região de Mossoró, RN. **Enciclopédia Biosfera**, v.6, n. 11, p. 1-7, 2010.
- PHILLIPS, P. C. B.; PERRON, P. Testing for a Unit Root in time series regression. **Biometrika**, v. 75, n.2, p. 335-346, 1988.
- R CORE TEAM. **R**: a language and environment for statistical computing. Vienna, Austria: R Foundation for Statistical Computing, 2016. Disponível em: <<https://www.R-project.org/>>. Acesso em: 01 nov. 2016.
- TANAKA, A. A.; SOUZA, A. P.; KLAR, A. E.; SILVA, A. C.; GOMES, A. W. A. Evapotranspiração de referência estimada por modelos simplificados para o Estado do Mato Grosso. **Pesquisa Agropecuária Brasileira**, v. 51, n. 2, p. 91-104, 2016.
- TESTEZLAF, R. **Irrigação**: métodos, sistemas e aplicações. Campinas, SP: Faculdade de Engenharia Agrícola/ UNICAMP, 2011. 203p.
- VENABLES, W. N.; RIPLEY, B. D. **Modern applied statistics with S**. 4.ed. New York: Springer, 2002.
- WILKS, D. S. **Statistical methods in the atmospheric sciences**. 2ed. Amsterdam: Elsevier, 2006. 627p.
- WILLMOTT, C. J.; ACKLESON, S. G.; DAVIS, R. E.; FEDDEMA, J. J.; KLINK, K. M.; LEGATES, D. R.; O' DONNELL, J.; ROWE, C. M. Statistics for the evaluation and comparison for models. **Journal of Geophysical Research**, v. 90, n.5, p. 8995-9005, 1985.
- ZAMBRANO-BIGIARINI, M. **HydroGOF**: goodness-of-fit functions for comparison of simulated and observed hydrological time series. 2017. (R package version 0.3-10.). Disponível em: <<http://hzambran.github.io>>. Acesso em 16 jul. 2018.