

Article Type

Technical paper

فنی و ترویجی

نوع مقاله

Utilization of Machine Learning Methods: Estimating Daily Evapotranspiration of Reference Plant Using Neural Networks in Razavi Khorasan Province

Z. Shirmohammadi Aliakbarkhani 

Associate Professor, Department of Water Science and Engineering, High Educational Complex of Torbat-e Jam, Torbat-e Jam, Iran.

Email: shirmohammadi@tjamcaas.ac.ir

Received > 30-01-2025
Revised > 29-03-2025
Accepted > 16-04-2025
Available Online > 20-09-2025

بهره‌گیری از روش‌های یادگیری ماشین: تخمین تبخیر و تعرق روزانه گیاه مرجع با استفاده از شبکه‌های عصبی در استان خراسان رضوی

زهره شیرمحمدی علی اکبرخانی

دانشیار گروه علوم و مهندسی آب، مجتمع آموزش عالی تربت جام، تربت جام، ایران.

رایانامه: shirmohammadi@tjamcaas.ac.ir

تاریخ دریافت < ۱۴۰۳/۱۱/۱۱
تاریخ بازنگری < ۱۴۰۴/۰۱/۰۹
تاریخ پذیرش < ۱۴۰۴/۰۱/۲۷
تاریخ انتشار < ۱۴۰۴/۰۶/۲۹

Abstract

Evapotranspiration is one of the most important components in water and energy balance, and its accurate estimation is necessary for water resource management, irrigation scheduling, and environmental studies. In recent years, the application of machine learning (ML) techniques has provided a promising approach to improving ET prediction accuracy. In this study, two artificial neural network models, multilayer perceptron (MLP) and radial basis function (RBF), were used to estimate reference crop ET at Mashhad, Sabzevar, and Torbat-e Jam stations in Razavi Khorasan province. Meteorological data, including temperature, relative humidity, wind speed, and sunshine hours, were collected and normalized from 1992 to 2023. The ET values calculated by the FAO Penman-Monteith method were used as target values for training the models. The results showed that the neural network models, especially MLP, could provide accurate estimates of ET and performed better than the Linacre and Hargreaves-Samani methods. Excluding wind speed at Torbat-e Jam and Mashhad stations resulted in a 5.1% decrease in the coefficient of determination (R^2), while at Sabzevar, this decrease was 11.3%. In contrast, excluding sunshine hours had a negligible impact on model accuracy. These findings emphasize the high potential of artificial neural networks in estimating ET in data-scarce conditions and can contribute to the optimal management of agricultural water resources in the studied region.

Keywords: Evapotranspiration, Machine Learning, Neural Networks, Modeling, Water Management.

چکیده

تبخیر و تعرق یکی از مهم‌ترین مؤلفه‌های بیلان آب و انرژی است که تخمین دقیق آن برای مدیریت منابع آب، برنامه‌ریزی آبیاری و مطالعات محیط‌زیستی ضروری است. در سال‌های اخیر، استفاده از تکنیک‌های یادگیری ماشین (ML) راهکار امیدوارکننده‌ای برای بهبود دقت پیش‌بینی تبخیر و تعرق ارائه کرده است. در این مطالعه، دو مدل شبکه عصبی مصنوعی، شامل پرسپترون چند لایه (MLP) و شبکه با پایه شعاعی (RBF)، برای تخمین تبخیر و تعرق گیاه مرجع در ایستگاه‌های مشهد، سبزوار و تربت جام در استان خراسان رضوی به کار گرفته شدند. داده‌های هواشناسی شامل دما، رطوبت نسبی، سرعت باد و ساعات آفتابی از سال ۱۳۷۱ تا ۱۴۰۲ جمع‌آوری و پس از نرمال‌سازی برای آموزش مدل‌ها استفاده شدند. مقادیر تبخیر و تعرق محاسبه شده با روش فائو-پنمن-مانتیت به عنوان داده‌های هدف جهت ارزیابی مدل‌ها در نظر گرفته شد. نتایج نشان داد این مدل‌ها، به‌ویژه MLP، عملکرد مطلوبی در تخمین تبخیر و تعرق داشته و دقت بالاتری نسبت به روش‌های لیناکر و هارگریوز-سامانی ارائه کردند. همچنین، حذف سرعت باد در ایستگاه‌های تربت جام و مشهد موجب کاهش ۵/۱ درصدی و در ایستگاه سبزوار باعث کاهش ۱۱/۳ درصدی ضریب تعیین (R^2) شد، در حالی که حذف ساعات آفتابی تأثیر ناچیزی بر دقت مدل داشت. این یافته‌ها بر پتانسیل بالای شبکه‌های عصبی مصنوعی در برآورد تبخیر و تعرق در شرایط کمبود داده تأکید داشته و می‌توانند به مدیریت بهینه منابع آب کشاورزی در منطقه مورد مطالعه کمک کنند.

واژه‌های کلیدی: تبخیر و تعرق، یادگیری ماشین، شبکه‌های عصبی، مدل‌سازی، مدیریت آب.

How to cite this article: Shirmohammadi-Aliakbarkhani, Z. (2025). Utilization of Machine Learning Methods: Estimating Daily Evapotranspiration of Reference Plant Using Neural Networks in Razavi Khorasan Province. Journal of Water and Sustainable Development, 12(2), 177-192. <http://dx.doi.org/10.22067/jwsd.v12i2.2501-1402>

بنابراین، یک مدل که بتواند با استفاده از حداقل داده‌های هواشناسی، مقدار تبخیر- تعرق را به صورت دقیق برآورد کند، بسیار مفید خواهد بود (احمدزاده قره گو و همکاران، ۱۳۸۹). در سال‌های اخیر، ظهور تکنیک‌های یادگیری ماشین (ML) یک راه امیدوار کننده برای افزایش دقت و قابلیت اطمینان پیش‌بینی‌های تبخیر و تعرق ارائه کرده است. یادگیری ماشینی از الگوریتم‌های پیشرفته برای کشف الگوهای پیچیده در مجموعه داده‌های بزرگ استفاده می‌کند و درک دقیق‌تری از تعاملات پیچیده بین متغیرهای هواشناسی، ویژگی‌های پوشش گیاهی و فرآیندهای از دست دادن آب را ممکن می‌سازد. این مدل به عنوان رقیبی با عملکرد مطلوب‌تر نسبت به روش‌های فیزیک و تجربی عمل می‌کنند (Amani و Shafizadeh-Moghadam، ۲۰۲۳). از میان این مدل‌ها می‌توان به مدل جنگل تصادفی (RF)، (SVM) و مدل‌های شبکه عصبی مصنوعی (ANN) اشاره کرد. تا به امروز، شبکه‌های عصبی مصنوعی با معماری‌های مختلف توسعه یافته‌اند و در حوزه‌های گوناگونی به کار می‌روند.

فرآیند یادگیری در شبکه‌های عصبی مصنوعی اغلب با معرفی چند وزن تصادفی شروع می‌شود و سپس این وزن‌ها بهینه‌سازی می‌شوند تا خطا در پیش‌بینی به حداقل برسد. یکی از رایج‌ترین انواع شبکه‌های عصبی، پرسپترون چند لایه است. معمولاً ANN از سه لایه تشکیل شده است: لایه ورودی، لایه پردازش، و لایه خروجی، که به توزیع داده‌های ورودی حساس نیست (ROSENBLATT، ۱۹۵۸). الگوریتم شبکه عصبی مصنوعی (ANN) یکی از روش‌های پرکاربرد ML است که دقت بالایی دارد و به راحتی می‌تواند حجم زیادی از داده را مدیریت نماید (Adnan و همکاران، ۲۰۱۹؛ Antonopoulos و Antonopoulos، ۲۰۱۷).

اولین مدل‌سازی تبخیر و تعرق با شبکه عصبی مصنوعی توسط Bruton و همکاران (۲۰۰۰) انجام شده است، نتایج پژوهش آن‌ها نشان داد عملکرد شبکه عصبی مصنوعی در تخمین تبخیر روزانه تحت تبخیر در ایالات متحده آمریکا مناسب بوده است. Odhiambo و همکاران (۲۰۰۱)، Kumar و همکاران (۲۰۰۲، ۲۰۱۱) و Slavisa و همکاران (۲۰۰۳) نیز از همان داده‌های هواشناسی استفاده کردند و نشان دادند نتایج تخمین ET_0 با استفاده از شبکه عصبی مصنوعی نسبت به سایر روش‌های مرسوم دقیق‌تر است. Kisi (۲۰۰۸) سه مدل مختلف شبکه عصبی مصنوعی را بررسی کردند نتایج نشان داد که شبکه عصبی مصنوعی پرسپترون چند لایه بهتر از روش‌های تجربی برای تخمین ET_0 است. Zanetti و همکاران

تبخیر و تعرق (ET) یک جزء کلیدی در چرخه هیدرولوژیکی و یک عامل اساسی در آبیاری، تخمین عملکرد محصول، جنگل‌داری و مدیریت محیط‌زیستی در نظر گرفته می‌شود که حدود ۵۰ درصد از تابش خالص را مصرف می‌کند و ۷۰ درصد از کل بارش را به جو برمی‌گرداند (Amani و Shafizadeh-Moghadam، ۲۰۲۳؛ Maroufpoor و همکاران، ۲۰۲۰). برآورد دقیق ET برای مدیریت مؤثر منابع آب درک فرآیندهای هیدرولوژیکی و اکولوژیکی (Allen و همکاران، ۲۰۰۵)، شناسایی و کاهش خشک‌سالی کشاورزی و مدیریت منابع آب بسیار مهم است (Anderson و همکاران، ۲۰۰۷؛ Teuling و همکاران، ۲۰۰۹). تخمین ET همچنین برای مطالعه رویدادهای آب و هوایی (به عنوان مثال خشک‌سالی) و درک روابط بین جو، هیدروسفر و سیستم‌های بیوسفر ضروری است (Orth و Destouni، ۲۰۱۸). تبخیر و تعرق می‌تواند به طور مستقیم توسط لایسیمتر با روش بیلان آب اندازه‌گیری شده و یا با استفاده از روش‌های تجربی تخمین زده شود.

به دلیل زمان‌بر بودن و نیاز به برنامه‌ریزی دقیق امکان استفاده از روش لایسیمتر به طور گسترده وجود ندارد (صیادی و همکاران، ۱۳۸۸). طی سال‌های گذشته مدل‌های متعددی به صورت روابط ساده تجربی تا معادلات پیچیده علمی، بسته به در دسترس بودن داده‌های هواشناسی توسط دانشمندان به منظور تخمین تبخیر و تعرق گیاه مرجع (ET_0) توسعه یافته و در حال استفاده است (Amiri و Pourghasemi، ۲۰۱۹؛ Shirmohammadi-Aliakbarkhani و همکاران، ۲۰۲۰). بسیاری از روش‌های تخمین تبخیر- تعرق اغلب از طریق واسنجی محلی به دست می‌آیند و اعتبار محدودی در مقیاس جهانی دارند.

همچنین، به دلیل مشکلات فنی و اقتصادی در کشورهای در حال توسعه، ممکن است استفاده از ایستگاه‌های هواشناسی مجهز برای جمع‌آوری و ثبت دقیق داده‌های هواشناسی مقدور نباشد و یا در بعضی ایستگاه‌ها تنها برخی از پارامترهای هواشناسی اندازه‌گیری شود. در این صورت، تخمین دقیق تبخیر- تعرق با استفاده از داده‌های هواشناسی محدود، مشکل خواهد بود (احمدزاده قره گو و همکاران، ۱۳۸۹). از سویی دیگر، اثر متقابل پارامترهای هواشناسی مانند دما، رطوبت نسبی، سرعت باد، تشعشع و برخی پارامترهای ناشناخته، باعث شده است که روابط ارائه شده برای تخمین تبخیر- تعرق به روابطی غیرخطی و پیچیده تبدیل شوند.

(۲۰۰۷)، Landaras و همکاران (۲۰۰۸)، Moghaddamnia و همکاران (۲۰۰۹) و Wang و همکاران (۲۰۱۱) نیز نتایج مشابهی از پژوهش‌های خود به دست آوردند. Rahimi Khoob (۲۰۰۸) و Diamantopoulou و همکاران (۲۰۱۱) شبکه عصبی مصنوعی را با روش هارگریوز برای تخمین ET_0 مقایسه کردند. همچنین نتایج شبکه پرسپترون چندلایه برای تخمین ET_0 را با روش تست تبخیر مقایسه کردند. آن‌ها در پژوهش‌های خود تایید کردند شبکه پرسپترون چند لایه دقت بالایی برای تخمین ET_0 دارد. Dehbozorgi و Sepaskhah (۲۰۱۲)، Khoshhal و Mokarram (۲۰۱۲) و Laaboudi و همکاران (۲۰۱۲) از شبکه عصبی مصنوعی پرسپترون چندلایه استفاده کردند و ET_0 را با استفاده از معادله پنمن-مونتیث به عنوان خروجی برای تخمین ET_0 تخمین زدند. نتایج آن‌ها عملکرد بالا و دقیق شبکه‌های عصبی مصنوعی را نشان داده است. Mohawesh (۲۰۱۳) نیز نتایج مشابهی به دست آورد و استفاده از شبکه عصبی مصنوعی را برای سایر کاربردها، هیدرولوژی و برنامه‌ریزی مدیریت آب توصیه کرد. Traore و همکاران (۲۰۱۰) عملکرد شبکه عصبی مصنوعی را در مقابل روش هارگریوز سامانی در منطقه سودانو-ساحلی بورکینافاسو بررسی کردند. نتایج نشان داد در مقایسه با روش پنمن مانتیث، مدل‌های شبکه عصبی مصنوعی مبتنی بر دما بهتر از هارگریوز سامانی عمل می‌کنند. Feng و همکاران (۲۰۱۶) در مناطق گرم و مرطوب جنوب غربی چین عملکرد شبکه عصبی مصنوعی را در تخمین تبخیر و تعرق ارزیابی کردند، نتایج آن‌ها نشان داد شبکه‌های عصبی پس انتشار بهینه شده توسط الگوریتم ژنتیک مبتنی بر دما، عملکرد بهتری نسبت به روش‌های هارگریوز سامانی و روش شبکه عصبی مبتنی بر تابش عملکرد بهتری از روش ماکیناک و پرستلی تیلور از خود نشان دادند Antonopoulos (۲۰۱۷) تبخیر تعرق روزانه را در شمال یونان با مدل‌های تجربی و مدل‌های شبکه عصبی ارزیابی کردند نتایج نشان داد شبکه‌های عصبی تبخیر تعرق را با دقت قابل قبولی در این ناحیه تخمین زدند.

Jang و همکاران (۲۰۲۱) در بررسی تبخیر و تعرق روزانه داده‌های مادیس با شبکه عصبی مصنوعی نشان دادند در مقایسه با تبخیر و تعرق پتانسیل روش پنمن مانتیث، مدل شبکه عصبی مصنوعی تخمین‌های دقیق‌تری نسبت به داده‌های MODIS به دست آورد. Liu و همکاران (۲۰۲۱) گزارش دادند مدل ترکیبی مبتنی بر شبکه عصبی مصنوعی بهتر از مدل‌های RF و SVM با دقت بالاتر و کاربردهای گسترده‌تر عمل می‌کند Abrishami و همکاران (۲۰۱۹) عملکرد شبکه عصبی مصنوعی را در


تخمین تبخیر و تعرق گندم و ذرت در شیراز بررسی کردند و نتایج نشان داد عملکرد مناسب شبکه‌های عصبی در تخمین تبخیر تعرق روزانه گندم و ذرت بود.

Ghahreman و Sameti (۲۰۱۴) در کرمان و زاهدان عملکرد شبکه عصبی مصنوعی و مدل درختی M5 را بر تخمین تبخیر تعرق ارزیابی کردند و بیان کردند در مقایسه با شبکه عصبی عملکرد مدل درختی M5 در تخمین تبخیر و تعرق در این نواحی بهتر بود. باتوجه به بررسی پژوهش‌های انجام شده تاکنون در استان خراسان رضوی در این مورد پژوهشی صورت نگرفته است.

این پژوهش با استفاده از شبکه‌های عصبی، زیرمجموعه‌ای از مدل‌های یادگیری ماشین، کاوش روش‌های مبتنی بر داده برای تخمین تبخیر و تعرق را گسترش می‌دهد. شبکه‌های عصبی موفقیت قابل توجهی را در حوزه‌های مختلف نشان دادند و توانایی خود را در گرفتن روابط غیرخطی و سازگاری با مجموعه داده‌های متنوع نشان دادند. هدف از این مطالعه استفاده از شبکه‌های عصبی برای بهبود تخمین تبخیر و تعرق، ارائه یک جایگزین دقیق‌تر و انعطاف‌پذیرتر برای روش‌های سنتی در سه ایستگاه واقع در استان خراسان رضوی است.

مواد و روش‌ها

استان خراسان رضوی در شمالی شرقی ایران و در طول جغرافیایی 33° – 38° و در عرض جغرافیایی 56° – 62° شرقی و شمالی با مساحت 117200 کیلومترمربع گسترش یافته است. متوسط سالانه بارندگی در این استان 250 میلی‌متر گزارش شده است. این پژوهش با استفاده از داده‌های هواشناسی روزانه در سه ایستگاه سینوپتیک تربت جام، مشهد و سبزوار



شکل ۱- نقشه توزیع مکانی ایستگاه‌های همدید در منطقه مورد مطالعه

جدول ۱- مشخصات جغرافیایی و تعداد سال‌های آماری مورد استفاده در ایستگاه‌های سینوپتیک مورد مطالعه

ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع (متر)	سال‌های آماری
تربت‌جام	۶۰°۳۵'	۳۵°۱۶'	۹۵۰/۴	۱۳۷۱-۱۴۰۲
سبزوار	۵۷°۳۹'	۳۶°۱۲'	۹۶۲	۱۳۷۱-۱۴۰۲
مشهد	۵۹°۳۸'	۳۶°۱۴'	۹۹۹/۲	۱۳۷۱-۱۴۰۲

■ روش لیناکر

Linacre (۱۹۷۷) معادله‌ای بر اساس دمای هوا و نقطه شبنم برای محاسبه تبخیر و تعرق گیاه مرجع به صورت زیر ارائه داد.

$$ET_{LIN} = \frac{\frac{500 \times (T + 0.006 \times A)}{100 - \phi} + 15 \times (T - T_d)}{80 - T} \quad (2)$$

که در آن ET_{LIN} تبخیر و تعرق گیاه مرجع به روش لیناکر برحسب میلی‌متر در روز، A ارتفاع ایستگاه برحسب متر، ϕ عرض جغرافیایی ایستگاه برحسب درجه، T متوسط درجه حرارت هوا در ارتفاع دو متری برحسب درجه سانتی‌گراد و T_d دمای نقطه شبنم برحسب درجه سانتی‌گراد می‌باشد. به دلیل اینکه اندازه‌گیری داده‌های نقطه شبنم در ایستگاه‌ها به صورت مستقیم صورت نمی‌گیرد در روش لیناکر برای محاسبه نقطه شبنم از داده‌های حداقل و حداکثر رطوبت نسبی و حداقل و حداکثر درجه حرارت استفاده می‌شود. در انتخاب داده‌های ورودی به مدل از این مقادیر استفاده شد.

■ روش هارگریوز-سامانی

Hargreaves و Samani (۱۹۸۵) معادلات متعددی برای محاسبه تبخیر و تعرق گیاه مرجع ارائه نمودند. یکی از این معادلات که در این پژوهش استفاده شد به صورت زیر می‌باشد:

$$ET_{HS} = 0.0023(T_{max} - T_{min})^{0.5} (T + 17.8) \frac{R_a}{\lambda} \quad (3)$$

که در آن ET_{HS} تبخیر و تعرق گیاه مرجع به روش هارگریوز-سامانی برحسب میلی‌متر در روز R_a تابش فرازمینی برحسب مگا ژول بر مترمربع بر روز که از روش Allen و همکاران (۲۰۰۵) به دست می‌آید. T_{min} و T_{max} به ترتیب حداقل و حداکثر درجه حرارت برحسب درجه سانتی‌گراد، T متوسط درجه حرارت هوا در ارتفاع دو متری برحسب درجه سانتی‌گراد، λ گرمای نهان تبخیر برحسب مگا ژول بر کیلوگرم می‌باشد.

واقع در این استان در دوره آماری ۱۳۷۱-۱۴۰۲ به صورت روزانه انجام شد (شکل ۱). مشخصات جغرافیایی و تعداد سال‌های آماری ایستگاه‌های مورد مطالعه در جدول (۱) آورده شده است. داده‌های دریافتی از ایستگاه سینوپتیک مورد مطالعه شامل حداقل، حداکثر و متوسط درجه حرارت، حداقل، حداکثر و متوسط رطوبت نسبی، سرعت باد و ساعات آفتابی می‌باشد.

روش محاسبه تبخیر و تعرق پتانسیل گیاه مرجع

■ روش فائو پنمن مانتیث

ابتدا با استفاده از داده‌های هواشناسی با روش پنمن مانتیث فائو تبخیر و تعرق گیاه مرجع به صورت روزانه محاسبه شد.

$$PET_{PM} = \frac{0.408 \Delta (R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 u_2)} \quad (1)$$

که در آن PET_{PM} تبخیر و تعرق گیاه مرجع به روش فائو پنمن مانتیث برحسب میلی‌متر در روز، Δ شیب منحنی فشار بخار اشباع آب نسبت به دما برحسب کیلو پاسکال بر درجه سانتی‌گراد، R_n تابش خالص ورودی برحسب مگا ژول بر مترمربع بر روز، G شار گرمای خاک برحسب مگا ژول بر مترمربع بر روز، T میانگین روزانه دمای هوا در ارتفاع دو متری برحسب درجه سانتی‌گراد، u_2 سرعت باد در ارتفاع دو متری برحسب متر بر ثانیه، e_s و e_a به ترتیب فشار بخار اشباع و واقعی هوا برحسب کیلو پاسکال، γ ثابت سایکرومتری برحسب کیلو پاسکال بر درجه سانتی‌گراد می‌باشد.

با توجه به اینکه در تحقیقات گذشته Shirmohammadi-Aliakbarkhani و همکاران (۲۰۲۰) در ایستگاه تربت جام بهترین روش برای محاسبه تبخیر و تعرق روزانه روش لیناکر و در دو ایستگاه مشهد و سبزوار روش هارگریوز سامانی به دست آمد در این پژوهش این روش‌ها هم در کنار مدل‌های یادگیری ماشین در این دوره آماری بررسی شدند.

تصحیح داده‌ها و نرمال‌سازی

ابتدا داده‌های ورودی بررسی شد و داده‌های گمشده با استفاده از میانگین دو داده قبل و بعد از آن‌ها تصحیح شد پس از آن به منظور ایجاد یک شبکه عصبی مصنوعی، ابتدا باید داده‌ها را نرمال‌سازی کرد. هدف این مرحله، تطبیق داده‌های ورودی با محدوده دینامیکی توابع فعال‌سازی شبکه عصبی است به طوری که در این پژوهش از تابع مماس هذلولی در لایه میانی و تابع خطی در لایه خروجی استفاده شد. همان طور که Bishop (۱۹۹۶) بیان کرده است، نرمال‌سازی داده‌های ورودی ضروری است، زیرا اگر داده‌ها در مقیاس‌های متفاوت باشند، شبکه قادر نخواهد بود به درستی الگوها و روابط میان آن‌ها را بیاموزد. فرآیند نرمال‌سازی داده‌ها بر اساس معادله (۴) انجام می‌شود:

$$x^* = \frac{x_0}{\bar{x} + n_s s} \quad (4)$$

که در آن x^* متغیر نرمال شده، x_0 متغیر اصلی، $\bar{x}$ میانگین به دست آمده از نمونه‌ها برای تشکیل مجموعه آموزشی، s انحراف استاندارد متغیرهای اصلی از مجموعه آموزشی، n_s تعداد انحرافات استاندارد است که باید در نظر گرفته شود.

مدل‌های یادگیری ماشین

• مدل شبکه عصبی مصنوعی پرسپترون چندلایه (MLP)


یک مدل شبکه عصبی مصنوعی پیشخور است که مجموعه داده‌های ورودی را به مجموعه‌ای از خروجی‌های متناسب نگاشت می‌دهد. شبکه‌های چند لایه پیشخور یکی از ساختارهای حیاتی در شبکه‌های عصبی مصنوعی هستند. این شبکه‌ها معمولاً شامل یک مجموعه از واحدهای حسی (نورون‌های پایه) هستند که تشکیل دهنده لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌شوند. سیگنال ورودی در طول شبکه و در مسیر جلو به صورت لایه به لایه منتقل می‌شود. این نوع شبکه به عنوان پرسپترون چند لایه (MLP) نیز شناخته می‌شود. شکل (۲) تصویر شماتیک این نوع شبکه عصبی را نمایش می‌دهد. انتخاب معماری شبکه عصبی MLP با دو لایه پنهان (۵۰ و ۱۰۰ نورون) بر اساس مطالعات پیشین و تنظیمات بهینه انجام شد. پژوهش‌ها نشان دادند که شبکه‌های دارای دو لایه پنهان عملکرد بهتری نسبت به مدل‌های تک لایه‌ای دارند و می‌توانند روابط غیرخطی پیچیده را بهتر مدل‌سازی کنند (Laaboudi و همکاران، ۲۰۱۲). انتخاب

تعداد ۱۰۰ و ۵۰ نورون بر اساس اصول طراحی شبکه‌های عصبی انجام شد، به طوری که لایه اول ویژگی‌های پیچیده‌تر را استخراج کرده و لایه دوم آن‌ها را بهینه‌سازی می‌کند (Marquina-Araujo و همکاران، ۲۰۲۴). بررسی ترکیب‌های مختلف نشان داد افزایش تعداد لایه‌ها یا نورون‌ها باعث پیچیدگی محاسباتی و بیش‌برازش می‌شود، در حالی که مدل‌های ساده‌تر دقت کمتری دارند. بنابراین، این معماری بهترین تعادل را بین دقت، پیچیدگی محاسباتی و جلوگیری از بیش‌برازش برقرار کرده و در این پژوهش استفاده شد.

• مدل شبکه عصبی با تابع پایه شعاعی (RBF)

یک شبکه تابع شعاعی، یک شبکه عصبی مصنوعی است که از توابع پایه شعاعی به عنوان توابع فعال‌ساز استفاده می‌کند. شبکه توابع پایه شعاعی، در حالت ساده‌تر خود، از سه لایه مجزا تشکیل شده است. لایه اول، لایه ورودی است که از مجموعه‌ای از گره‌های ابتدایی یا واحدهای حسی تشکیل شده است. لایه دوم، لایه‌های پنهان با ابعاد بالا هستند و لایه سوم، لایه خروجی است که پاسخ شبکه را بر اساس الگوهای فعال‌سازی ارائه شده در لایه ورودی تولید می‌کند. تبدیل فضای ورودی به فضای واحد پنهان، یک رابطه غیرخطی دارد. به عبارت دیگر، این تبدیل خصوصیت‌های غیرخطی دارد که اطلاعات را به صورت غیرخطی در فضای پنهان نمایش می‌دهد. در مقابل، تبدیل فضای پنهان به فضای خروجی، یک رابطه خطی دارد. این به آن معنا است که خروجی شبکه به صورت خطی از ویژگی‌های نهان در فضای پنهان ترکیب می‌شود تا خروجی نهایی ایجاد شود. شکل (۳) تصویر شماتیک این نوع شبکه عصبی را نمایش می‌دهد.

در این پژوهش، برای پیاده‌سازی شبکه‌های عصبی از کتابخانه‌های معروف یادگیری ماشین و پردازش داده در پایتون مانند Scikit-learn استفاده شده است. کد پیاده‌سازی مدل



شکل ۲- تصویر شماتیک شبکه عصبی پرسپترون چندلایه


• تا ۰/۲ بوده و ضریب نکویی برازش بین ۰/۸ و ۱ قرار گیرد (Lang و همکاران، ۲۰۱۷). برای محاسبه مقادیر این پارامترها از برنامه‌نویسی پایتون در محیط گوگل کولب استفاده شد.

نتایج و بحث

در این پژوهش ابتدا با استفاده از داده‌های هواشناسی مقادیر تبخیر و تعرق گیاه مرجع با روش پنمن مانتیث و روش لیناکر در ایستگاه تربت جام و روش‌هاگريوز سامانی در ایستگاه‌های سبزواری و مشهد در مقیاس روزانه محاسبه شد. سپس نمودار جعبه‌ای پارامترهای هواشناسی در طول دوره آماری برای تعیین وجود داده‌های پرت ترسیم شد (شکل‌های ۴ تا ۶).

از نمودار جعبه‌ای می‌توان به چگونگی توزیع پارامترهای هواشناسی پی برد. همان‌طور که در نمودارهای جعبه‌ای نشان داده شده است داده‌های درجه حرارت حداقل، رطوبت نسبی حداقل و سرعت باد دارای داده‌های پرت می‌باشند که پس از حذف داده‌های پرت، پارامترهای هواشناسی برای استفاده در مدل‌های شبکه عصبی نرمال‌سازی شد.

همچنین با استفاده از داده‌های هواشناسی به روش لیناکر و روش‌هاگريوز سامانی نیز تبخیر و تعرق روزانه محاسبه شد. سپس با استفاده از کتابخانه‌های موجود در نرم‌افزار پایتون و معرفی ۱۴ ساختار از پارامترهای مؤثر بر تبخیر تعرق، شبکه‌های متعددی با ورودی‌های متفاوت برای تخمین تبخیر و تعرق گیاه مرجع تعریف شد.



شکل ۳- تصویر شماتیک شبکه عصبی با پایه شعاعی

در محیط گوگل کولب اجرا شده است، که امکان استفاده از شتاب‌دهنده‌های سخت‌افزاری (GPU) را برای بهبود سرعت آموزش فراهم می‌کند.


آنالیزهای آماری

برای ارزیابی و انتخاب بهترین مدل شبکه عصبی برای تخمین تبخیر و تعرق از شاخص‌های آماری ضریب نکویی برازش (R^2)، میانگین خطای مطلق (MAE) و ریشه میانگین مربعات خطا (RMSE) استفاده شد (جدول ۲). بهترین تطابق آماری بین مقادیر مدل و مقادیر مشاهداتی زمانی می‌باشد که محدوده قابل قبول خطای نسبی و ریشه میانگین مربعات خطای نرمال شده بین


جدول ۲- شاخص‌های آماری به منظور ارزیابی تبخیر تعرق تخمینی با کمک مدل‌های یادگیری ماشین

مقدار مطلوب	معادله	شاخص‌های آماری
۱	$R^2 = \left(\frac{\frac{1}{N} \sum_{n=1}^N (ETm_n - \overline{ETm})(ETPM_n - \overline{ETPM})}{\sqrt{\frac{1}{N} \sum_{n=1}^N (ETm_n - \overline{ETm})^2} \sqrt{\frac{1}{N} \sum_{n=1}^N (ETPM_n - \overline{ETPM})^2}} \right)^2$	ضریب نکویی برازش (R^2)
•	$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (ETm_n - ETPM_n)^2}$	ریشه میانگین مربعات خطا (RMSE)
•	$MAE = \frac{1}{N} \sum_{n=1}^N ETm_n - ETPM_n $	میانگین خطای مطلق (MAE)


که در آن n تعداد داده‌ها، مقادیر $ETPM_n$ مقدار تبخیر و تعرق به روش استاندارد پنمن مانتیث فائو ETm_n مقادیر تخمینی تبخیر و تعرق با استفاده از مدل



شکل ۴- نمودار جعبه‌ای پارامترهای آماری در ایستگاه تربت جام



شکل ۵- نمودار جعبه‌ای پارامترهای آماری در ایستگاه مشهد



شکل ۶- نمودار جعبه‌ای پارامترهای آماری در ایستگاه سبزوار

جدول ۳- ساختار داده‌های ورودی به شبکه عصبی

مدل	پارامتر ورودی
NN1	درجه حرارت حداقل و حداکثر، رطوبت نسبی حداقل و حداکثر، ساعات آفتابی، سرعت باد
NN2	درجه حرارت حداقل و حداکثر، رطوبت نسبی حداقل و حداکثر، سرعت باد
NN3	درجه حرارت حداقل و حداکثر، رطوبت نسبی حداقل و حداکثر، ساعات آفتابی
NN4	درجه حرارت حداقل و حداکثر، رطوبت نسبی حداقل و حداکثر
NN5	درجه حرارت حداقل و حداکثر
NN6	رطوبت نسبی حداقل و حداکثر
NN7	درجه حرارت متوسط، رطوبت نسبی متوسط
NN8	درجه حرارت حداقل و رطوبت نسبی حداقل
NN9	درجه حرارت حداقل و رطوبت نسبی حداکثر
NN10	درجه حرارت حداکثر و رطوبت نسبی حداکثر
NN11	درجه حرارت حداکثر و رطوبت نسبی حداقل
NN12	درجه حرارت متوسط
NN13	سرعت باد
NN14	ساعات آفتابی
NN15	تبخیر و تعرق لیناگر برای شهرستان تربت جام و روش‌ها رگريوز سامانی برای مشهد و سبزوار




جدول (۳) پارامترهای مورد نظر در هر ساختار را نشان می‌دهد. سپس بر اساس داده‌های ورودی دو مدل شبکه عصبی بر روی داده‌های مورد نظر اجرا شد.

مقایسه تبخیر و تعرق روش لیناگر با تبخیر و تعرق




پنمن مانیتث فائو

نتایج آنالیز آماری مقایسه تبخیر و تعرق به روش پنمن مانیتث فائو با روش لیناگر و هارگریوز سامانی در ایستگاه‌های مورد مطالعه در شکل (۷) آورده شده است. در ایستگاه تربت جام ضریب نکویی برازش در این مقایسه مقدار $0/88$ به دست آمد. ریشه میانگین مربعات خطا و میانگین خطای مطلق به ترتیب برابر با $1/36$ و $0/99$ میلی‌متر در روز به دست آمد. در ایستگاه مشهد ضریب نکویی برازش در این مقایسه مقدار $0/89$ به دست آمد. ریشه میانگین مربعات خطا و میانگین خطای مطلق به ترتیب برابر با $1/3$ و $0/73$ میلی‌متر در روز به دست آمد. در ایستگاه سبزوار ضریب نکویی برازش در این

مقایسه مقدار $0/85$ به دست آمد. ریشه میانگین مربعات خطا و میانگین خطای مطلق به ترتیب برابر با $1/5$ و $1/1$ میلی‌متر در روز به دست آمد. ضریب نکویی برازش در تمام ایستگاه‌های مورد مطالعه در دامنه مطلوب می‌باشد. در شکل (۸) نمودار پراکندگی تبخیر و تعرق گیاه مرجع به روش پنمن مانیتث فائو در برابر تبخیر و تعرق تخمینی روش لیناگر و هارگریوز سامانی در ایستگاه‌های مورد مطالعه آورده شده است. بررسی داده‌ها در این نمودار نشان‌دهنده یک رابطه مثبت و خطی بین این دو متغیر در مناطق مورد مطالعه می‌باشد. نتایج نشان‌دهنده این است که روش لیناگر تبخیر و تعرق را در ایستگاه تربت جام بیش برآورد می‌کند. در ایستگاه مشهد بسیاری از نقاط در نزدیکی خط روند قرار دارند، که نشان‌دهنده این است که مدل خطی تقریباً می‌تواند پیش‌بینی دقیقی از پنمن مانیتث فائو بر اساس روش‌ها رگريوز سامانی ارائه دهد. در ایستگاه سبزوار نیز روش‌ها رگريوز سامانی تبخیر و تعرق را بیش برآورد می‌نماید.



شکل ۷- مقادیر ضریب نکویی برازش (R^2)، میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) محاسبه تبخیر و تعرق مرجع به روش فائو پنمن مانیت و روش های تجربی در شهرستان تربت جام (a)، مشهد (b)، سبزوار (c)




شکل ۸- نمودار پراکندگی تبخیر و تعرق گیاه مرجع (واقعی) در برابر تبخیر و تعرق تخمینی به روش های تجربی در شهرستان تربت جام (a)، مشهد (b)، سبزوار (c)

به ترتیب به میزان $0/310$ ، $0/336$ و $0/288$ در مدل MLP و در سناریو NN1 و بیشترین آن به ترتیب به میزان $2/444$ ، $2/776$ و $2/688$ در سناریوی NN13 حاصل شد. در برخی از سناریوها مدل RBF با تفاوت ناچیز نسبت به مدل MLP دقت بالاتری داشت. در کل نتایج نشان داد در هر سه منطقه مورد مطالعه، مدل MLP نسبتاً دقت بالاتری دارد.


نمودار ضریب نکویی برآزش در تخمین تبخیر و تعرق مدل‌ها در سناریوهای مختلف در ایستگاه‌های مورد مطالعه در شکل (۱۱) آورده شده است. در ایستگاه‌های مشهد، سبزوار و تربت‌جام بالاترین مقدار این ضریب به ترتیب به میزان $0/99$ ، $0/992$ و $0/994$ در مدل MLP و در سناریو NN1 و کمترین مقدار آن به ترتیب به میزان $0/369$ ، $0/474$ و $0/521$ در سناریوی NN13 حاصل شد. در برخی از سناریوها مدل RBF با تفاوت ناچیز نسبت به مدل MLP دقت بالاتری داشت. در کل نتایج نشان داد در هر سه منطقه مورد مطالعه، مدل MLP نسبتاً دقت بالاتری دارد.

نمودار مقادیر میانگین خطای مطلق در تخمین تبخیر و تعرق مدل‌ها در سناریوهای مختلف در ایستگاه‌های مورد مطالعه در شکل (۹) آورده شده است. در ایستگاه‌های مشهد، سبزوار و تربت‌جام کمترین میزان میانگین خطای مطلق به ترتیب به میزان $0/239$ ، $0/249$ و $0/216$ در مدل MLP و در سناریو NN1 و بیشترین آن به ترتیب به میزان $2/015$ ، $2/045$ و $2/263$ در مدل RBF و سناریوی NN13 حاصل شد. نتایج نشان داد در هر سه منطقه مورد مطالعه، مدل MLP دقت بالاتری دارد.


نمودار مقادیر ریشه میانگین مربعات خطا در تخمین تبخیر و تعرق مدل‌ها در سناریوهای مختلف در ایستگاه‌های مورد مطالعه در شکل (۱۰) آورده شده است. در ایستگاه‌های مشهد، سبزوار و تربت‌جام کمترین میزان ریشه میانگین مربعات خطا



شکل ۹- نمودار Heatmap مقادیر میانگین خطای مطلق در تخمین تبخیر و تعرق مدل‌ها در سناریوهای مختلف در ایستگاه‌های مورد مطالعه



شکل ۱۰- نمودار Heatmap مقادیر ریشه میانگین مربعات خطا در تخمین تبخیر و تعرق مدل‌ها در سناریوهای مختلف در ایستگاه‌های مورد مطالعه



شکل ۱۱- نمودار Heatmap مقادیر ضریب نکویی برازش در تخمین تبخیر و تعرق مدل‌ها در سناریوهای مختلف در ایستگاه‌های مورد مطالعه

سپس با توجه به آنالیزهای آماری ساختارهای ورودی به مدل‌های شبکه عصبی در مناطق مورد مطالعه رتبه‌بندی شد (جدول ۴).

با بررسی آنالیزهای آماری مشخص شد که روش‌های یادگیری ماشین مبتنی بر شبکه‌های عصبی به‌خوبی توانسته‌اند تبخیر تعرق گیاه مرجع را در این مناطق تخمین بزنند. بالاترین دقت در برآورد تبخیر و تعرق با روش‌های شبکه عصبی زمانی حاصل شد که از پارامترهای درجه حرارت حداقل و حداکثر، رطوبت نسبی حداقل و حداکثر، ساعات آفتابی، سرعت باد به‌عنوان ورودی به این مدل‌ها استفاده شد (NN۱).

سپس به ترتیب ورودی‌ها به مدل کاهش یافت و با ورودی‌های کمتر مدل‌ها اجرا شدند نتایج نشان داد زمانی که ورودی سرعت باد در مدل حذف می‌شود (NN۳) از مدلی که ساعات آفتابی حذف شده (NN۲) مدل در برآورد تبخیر و تعرق دارای دقت کمتری می‌باشد. افزایش سرعت باد به مدل در ایستگاه تربت جام باعث افزایش ۵/۱ درصد، در ایستگاه مشهد ۵/۱۵ درصد و در ایستگاه سبزوار ۱۱/۳ درصد در ضریب نکویی برآزش شد؛ اما حذف ساعات آفتابی در ایستگاه تربت جام و سبزوار تنها باعث کاهش ۰/۶۰ درصدی و در ایستگاه مشهد باعث کاهش ۱/۱ درصدی در ضریب تعیین گردید.

در ساختار NN۴ که تنها پارامترهای درجه حرارت و رطوبت نسبی وارد مدل شدند هر دو مدل شبکه عصبی در ایستگاه تربت جام با ضرایب نکویی برآزش (۰/۹۳۲ و ۰/۹۲۷) برآورد دقیق‌تری از تبخیر و تعرق نسبت به روش لیناگر داشتند میزان خطا هم در این مدل‌ها نسبت به روش لیناگر کمتر بود. در ایستگاه مشهد هر دو مدل شبکه عصبی با ضرایب نکویی برآزش (۰/۹۲۲ و ۰/۹۱۹) و در ایستگاه سبزوار با ضرایب نکویی برآزش (۰/۸۶۸ و ۰/۸۶۶) برآورد دقیق‌تری از تبخیر و تعرق نسبت به روش‌ها گریوز سامانی داشتند، میزان خطا هم در این مدل‌ها نسبت به روش‌ها گریوز سامانی کمتر بود. پس می‌توان چنین استنباط کرد که روش‌های شبکه عصبی در مناطق مورد مطالعه نسبت به روش‌های تجربی کارایی بهتری در برآورد تبخیر و تعرق دارند.

به‌طوری‌که حتی با ساختار یک ورودی درجه حرارت متوسط (NN۱۲) کارایی این دو روش با مقایسه آنالیزهای آماری در ایستگاه‌های تربت جام و مشهد اندکی بهتر از این روش‌ها بود؛ اما با حذف پارامتر درجه حرارت کارایی مدل‌های شبکه عصبی فقط با ورودی سرعت باد (NN۱۳) و ورودی ساعات آفتابی (NN۱۴) به‌شدت پایین می‌آید، به طوری که در مدل MLP ضریب تعیین در ایستگاه تربت جام به

ترتیب به میزان ۴۷/۵۸ درصد و ۳۲/۴۹ درصد، در ایستگاه مشهد به ترتیب به میزان ۶۲/۱۲ درصد و ۳۱/۴۱ درصد و در ایستگاه سبزوار به ترتیب به میزان ۵۲/۴۱ درصد و ۴۸/۳۸ درصد کاهش یافت. اما در مدل RBF ضریب تعیین در ایستگاه تربت جام به ترتیب به میزان ۴۷/۳۸ درصد و ۳۵/۱۱ درصد، در ایستگاه مشهد به ترتیب به میزان ۶۲/۷۲ درصد و ۳۲/۴۲ درصد و در ایستگاه سبزوار به ترتیب به میزان ۵۲/۲۱ درصد و ۵۰/۱۰ درصد کاهش یافت؛ بنابراین می‌توان نتیجه گرفت چنانچه داده‌های ورودی در منطقه مورد مطالعه کم باشد و تنها پارامتر درجه حرارت در دسترس باشد می‌توان از شبکه‌های عصبی در برآورد تبخیر و تعرق در این منطقه در مقیاس روزانه با دقت قابل قبولی استفاده کرد. Traore و همکاران (۲۰۱۰) کارایی روش‌های شبکه عصبی را بهتر از روش‌ها گریوز سامانی در منطقه سودانو-ساحلی گزارش نمودند.

همچنین مشخص شد روش‌های یادگیری ماشین مبتنی بر شبکه‌های عصبی به‌خوبی توانسته‌اند تبخیر تعرق گیاه مرجع را تخمین بزنند. با مقایسه نتایج مشخص شد که روش پرسپترون چندلایه (MLP) در مقایسه با روش پایه شعاعی (RBF) تبخیر و تعرق را در منطقه مورد مطالعه و در مقیاس روزانه اندکی بهتر برآورد می‌کند. در تمام مدل‌های اجرا شده با پارامترهای ورودی مختلف مقدار ضریب نکویی برآزش در روش MLP کمی بیشتر از روش RBF بود و مقادیر ریشه میانگین مربعات خطا و میانگین خطای مطلق در روش MLP اندکی کمتر از روش RBF بود. صیادی و همکاران (۱۳۸۸) در مطالعه خود در مورد تبخیر و تعرق ماهانه ایستگاه تبریز هم نتایج مشابه به دست آوردند.

نتیجه‌گیری و پیشنهادها

هدف اصلی این پژوهش، بررسی کارایی مدل‌های شبکه عصبی مصنوعی در برآورد تبخیر و تعرق مرجع (ETO) در شرایط اقلیمی استان خراسان رضوی و مقایسه آن با روش‌های تجربی متداول نظیر لیناگر وها گریوز-سامانی بود. باتوجه به اینکه تبخیر و تعرق گیاه مرجع یکی از پارامترهای کلیدی در مدیریت منابع آب کشاورزی به شمار می‌رود، برآورد دقیق آن می‌تواند نقش مهمی در برنامه‌ریزی، تخصیص و بهره‌برداری بهینه از منابع آبی ایفا نماید. مدل فیزیکی فائو-پنمن-مانتیت به عنوان مرجع جهانی معتبر، نیازمند داده‌های هواشناسی متنوعی از جمله رطوبت نسبی، ساعات آفتابی و سرعت باد است که در بسیاری از ایستگاه‌های هواشناسی کشورهای در

جدول ۴ - رتبه‌بندی مدل‌ها در سناریوهای مختلف در مناطق مورد مطالعه

مدل شبکه عصبی با تابع پایه شعاعی			مدل شبکه عصبی پرسپترون چندلایه			ساختار داده‌های ورودی
مشهد	سبزوار	ترتت جام	مشهد	سبزوار	ترتت جام	
۱	۱	۱	۱	۱	۱	NN1
۲	۲	۲	۲	۲	۲	NN2
۳	۳	۳	۳	۳	۳	NN3
۴	۴	۴	۴	۴	۴	NN4
۷	۸	۸	۷	۷	۷	NN5
۱۴	۱۳	۱۳	۱۴	۱۳	۱۳	NN6
۶	۶	۶	۶	۶	۶	NN7
۵	۵	۵	۵	۵	۵	NN8
۱۰	۱۲	۷	۱۰	۱۲	۷	NN9
۱۱	۱۰	۱۰	۱۱	۹	۹	NN10
۱۲	۷	۱۲	۱۲	۸	۱۱	NN11
۸	۱۱	۹	۸	۱۱	۸	NN12
۱۵	۱۵	۱۵	۱۵	۱۴	۱۴	NN13
۱۳	۱۴	۱۴	۱۳	۱۴	۱۳	NN14
۹	۹	۱۰	۹	۱۰	۱۰	NN15

شبکه عصبی بر پایه داده‌های دمایی، می‌تواند ابزاری سریع، دقیق و کاربردی برای برآورد تبخیر و تعرق مرجع در استان خراسان رضوی باشد. برآورد دقیق ETO در این منطقه امکان اجرای مدل‌های شبیه‌سازی بیلان آب را فراهم کرده و می‌تواند به تصمیم‌گیری‌های مدیریتی و برنامه‌ریزی پایدار منابع آب کشاورزی کمک نماید.

تقدیر و تشکر

این مقاله مستخرج از نتایج طرح پژوهشی اجرا شده از محل اعتبارات معاونت پژوهشی مجتمع آموزش عالی کشاورزی و دامپروری ترتت جام می‌باشد. به این وسیله از حمایت مالی این مجتمع تقدیر و تشکر می‌شود.

حال توسعه در دسترس نیست.

از این‌رو، بهره‌گیری از مدل‌های هوش مصنوعی که تنها بر پایه دما (حداکثر و حداقل) عمل می‌کنند، می‌تواند راهکاری مؤثر برای مناطق با محدودیت داده‌های هواشناسی باشد. نتایج این پژوهش نشان داد مدل‌های شبکه عصبی مصنوعی در تمامی شاخص‌های آماری مورد استفاده (MAE و R^2 ، $RMSE$) عملکرد بهتری نسبت به روش‌های تجربی داشتند. همچنین مقایسه بین دو ساختار شبکه عصبی مورد بررسی بیانگر آن بود که شبکه پرسپترون چندلایه (MLP) دقت بالاتری در برآورد تبخیر و تعرق مرجع در مقایسه با شبکه تابع پایه شعاعی (RBF) ارائه داد. به طور کلی، یافته‌ها تأیید می‌کند که استفاده از مدل‌های

- Abrishami, N., Sepaskhah, A. R., & Shahrokhnia, M. H. (2019). Estimating wheat and maize daily evapotranspiration using artificial neural network. *Theoretical and Applied Climatology*, 135(3), 945–958.
<https://doi.org/10.1007/s00704-018-2418-4>
- Adnan, R. M., Malik, A., Kumar, A., Parmar, K. S., & Kisi, O. (2019). Pan evaporation modeling by three different neuro-fuzzy intelligent systems using climatic inputs. *Arabian Journal of Geosciences*, 12(19), 606.
<https://doi.org/10.1007/s12517-019-4781-6>
- Allen, R. G., Clemmens, A. J., Burt, C. M., Solomon, K., & O'Halloran, T. (2005). Prediction Accuracy for Projectwide Evapotranspiration Using Crop Coefficients and Reference Evapotranspiration. *Journal of Irrigation and Drainage Engineering*, 131(1), 24–36.
doi: [10.1061/\(ASCE\)0733-9437\(2005\)131:1\(24\)](https://doi.org/10.1061/(ASCE)0733-9437(2005)131:1(24))
- Amani, S., & Shafizadeh-Moghadam, H. (2023). A review of machine learning models and influential factors for estimating evapotranspiration using remote sensing and ground-based data. *Agricultural Water Management*, 284, 108324.
<https://doi.org/10.1016/j.agwat.2023.108324>
- Amiri, M., & Pourghasemi, H. R. (2019). Comparing Different Methods of Potential Evapotranspiration and Studying Temporal and Spatial Changes in the Mahalou Watershed using GIS. *Jwmr*, 10(19), 22–35.
<https://doi.org/10.29252/jwmr.10.19.22>
- Anderson, M. C., Norman, J. M., Mecikalski, J. R., Otkin, J. A., & Kustas, W. P. (2007). A climatological study of evapotranspiration and moisture stress across the continental United States based on thermal remote sensing: 2. Surface moisture climatology. *Journal of Geophysical Research: Atmospheres*, 112(D11).
<https://doi.org/10.1029/2006JD007507>
- Antonopoulos, V. Z., & Antonopoulos, A. V. (2017). Daily reference evapotranspiration estimates by artificial neural networks technique and empirical equations using limited input climate variables. *Computers and Electronics in Agriculture*, 132, 86–96.
<https://doi.org/10.1016/j.compag.2016.11.011>
- Bishop, C. M. (1996). *Neural Networks for Pattern Recognition*. Oxford, Oxford University Press. Oxford, England.
<https://doi.org/10.1093/oso/9780198538493.001.0001>
- Bruton, J. M., McClendon, R. W., & Hoogenboom, G. (2000). Estimating daily pan evaporation with artificial neural networks. *Transactions of the ASAE*, 43(2), 491–496. <https://doi.org/10.13031/2013.2730>
- Dehbozorgi, F., & Sepaskhah, A. R. (2012). Comparison of artificial neural networks and prediction models for reference evapotranspiration estimation in a semi-arid region. *Archives of Agronomy and Soil Science*, 58(5), 477–497.
<https://doi.org/10.1080/03650340.2010.530255>
- احمدزاده قره گويز، کاوه، میرلطیفی، سید مجید، و محمدی، کوروش. (۱۳۸۹). مقایسه سیستم‌های هوش مصنوعی (ANN) و ANFIS در تخمین میزان تبخیر-تعرق گیاه مرجع در مناطق بسیار خشک ایران. نشریه آب و خاک، ۴(۲۴)، ۶۷۹-۶۸۹.
doi: [10.22067/jsw.v0i0.3887](https://doi.org/10.22067/jsw.v0i0.3887)
- صیادی، حبیب، اولاد غفاری، ابوالفتح، فعالیان، احد، و صدرالدینی، علی اشرف. (۱۳۸۸). مقایسه عملکرد شبکه‌های عصبی RBF و MLP در برآورد تبخیر و تعرق گیاه مرجع. دانش آب و خاک، ۱۹(۱)، ۱-۱۲.

- Diamantopoulou, M., Georgiou, P. E., & Papamichail, D. M. (2011). Performance evaluation of artificial neural networks in estimating reference evapotranspiration with minimal meteorological data. *Global Nest Journal*, 13(1), 18-27. <https://doi.org/10.30955/gnj.000758>
- Feng, Y., Cui, N., Zhao, L., Hu, X., & Gong, D. (2016). Comparison of ELM, GANN, WNN and empirical models for estimating reference evapotranspiration in humid region of Southwest China. *Journal of Hydrology*, 536, 376-383. <https://doi.org/10.1016/j.jhydrol.2016.02.053>
- Ghahreman, N., & Sameti, M. (2014). Comparison of M5 Model Tree and Artificial Neural Network for Estimating Potential Evapotranspiration in Semi-arid Climates. *Desert*, 19(1), 75-81. doi: [10.22059/jdesert.2014.51056](https://doi.org/10.22059/jdesert.2014.51056)
- Hargreaves, G. H., Samani, Y. A., George H. Hargreaves, & Zohrab A. Samani. (1985). Reference Crop Evapotranspiration from Temperature. *Applied Engineering in Agriculture*, 1(2), 96-99. <https://doi.org/10.13031/2013.26773>
- Jang, J. -C., Sohn, E. -H., Park, K. -H., & Lee, S. (2021). Estimation of Daily Potential Evapotranspiration in Real-Time from GK2A/AMI Data Using Artificial Neural Network for the Korean Peninsula. *Hydrology*, 8(3). <https://doi.org/10.3390/hydrology8030129>
- Khoshhal, J., & Mokarram, M. (2012). Model for prediction of evapotranspiration using MLP neural network. *International Journal of Environmental Sciences*, 3(3), 1000-1009.
- Kisi, O. (2008). The potential of different ANN techniques in evapotranspiration modelling. *Hydrological Processes*, 22(14), 2449-2460. <https://doi.org/10.1002/hyp.6837>
- Kumar, M., Raghuwanshi, N. S., & Singh, R. (2011). Artificial neural networks approach in evapotranspiration modeling: A review. *Irrigation Science*, 29(1), 11-25. <https://doi.org/10.1007/s00271-010-0230-8>
- Kumar, M., Raghuwanshi, N. S., Singh, R., Wallender, W. W., & Pruitt, W. O. (2002). Estimating Evapotranspiration using Artificial Neural Network. *Journal of Irrigation and Drainage Engineering*, 128(4), 224-233. [https://doi.org/10.1061/\(ASCE\)0733-9437\(2002\)128:4\(224\)](https://doi.org/10.1061/(ASCE)0733-9437(2002)128:4(224))
- Laaboudi, A., Mouhouche, B., & Draoui, B. (2012). Neural network approach to reference evapotranspiration modeling from limited climatic data in arid regions. *International Journal of Biometeorology*, 56(5), 831-841. <https://doi.org/10.1007/s00484-011-0485-7>
- Landeras, G., Ortiz-Barredo, A., & López, J. J. (2008). Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). *Agricultural Water Management*, 95(5), 553-565. <https://doi.org/10.1016/j.agwat.2007.12.011>
- Lang, D., Zheng, J., Shi, J., Liao, F., Ma, X., Wang, W., Chen, X., & Zhang, M. (2017). A comparative study of potential evapotranspiration estimation by eight methods with FAO Penman-Monteith method in southwestern China. *Water (Switzerland)*, 9(10), 734. <https://doi.org/10.3390/w9100734>
- Linacre, E. T. (1977). A simple formula for estimating evaporation rates in various climates, using temperature data alone. *Agricultural Meteorology*, 18(6), 409-424. [https://doi.org/10.1016/0002-1571\(77\)90007-3](https://doi.org/10.1016/0002-1571(77)90007-3)
- Liu, Y., Zhang, S., Zhang, J., Tang, L., & Bai, Y. (2021). Assessment and Comparison of Six Machine Learning Models in Estimating Evapotranspiration over Croplands Using Remote Sensing and Meteorological Factors. *Remote Sensing*, 13(19). <https://doi.org/10.3390/rs13193838>
- Maroufpoor, S., Bozorg-Haddad, O., & Maroufpoor, E. (2020). Reference evapotranspiration estimating based on optimal input combination and hybrid artificial intelligent model: Hybridization of artificial neural network with grey wolf optimizer algorithm. *Journal of Hydrology*, 588, 125060. <https://doi.org/10.1016/j.jhydrol.2020.125060>
- Marquina-Araujo, J. J., Cotrina-Teatino, M. A., Mamani-Quispe, J. N., Soto-Juscamayta, L. M., Ccatamayo-Barrios, J. H., Ortiz-Quintanilla, S. M., & Cruz-Galvez, J. A. (2024). Application of Multilayer Perceptron Neural Network in Geological Modeling of Categorical Variables: A Case Study in Peru. *Mathematical Modelling of Engineering Problems*, 11(6), 1463-1472. <https://doi.org/10.18280/mmep.110607>
- Moghaddamnia, A., Ghafari Gousheh, M., Piri, J., Amin, S., & Han, D. (2009). Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*, 32(1), 88-97. <https://doi.org/10.1016/j.advwatres.2008.10.005>
- Mohawesh, O. E. (2013). Artificial neural network for estimating monthly reference evapotranspiration under arid and semi arid environments. *Archives of Agronomy and Soil Science*, 59(1), 105-117. <https://doi.org/10.1080/03650340.2011.603126>
- Odhiambo, L. O., Yoder, R. E., Yoder, D. C., & Hines, J. W. (2001). Optimization of fuzzy evapotranspiration model through neural training with input-output examples. *Transactions of the ASAE*, 44(6), 1625. <https://doi.org/10.13031/2013.7049>
- Orth, R., & Destouni, G. (2018). Drought reduces blue-water fluxes more strongly than green-water fluxes in Europe. *Nature Communications*, 9(1), 3602. <https://doi.org/10.1038/s41467-018-06013-7>
- Rahimi Khoob, A. (2008). Comparative study of Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid

- environment. *Irrigation Science*, 26(3), 253–259.
<https://doi.org/10.1007/s00271-007-0090-z>
- ROSENBLATT, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408.
<https://doi.org/10.1037/h0042519>
 - Shirmohammadi-Aliakbarkhani, Z., Saberali, S. F., & Kouhi, M. (2020). Evaluation of Different Methods of Calculating the Potential Evapotranspiration at the Annual Timescale in the Northeast of Iran. *Jwmr*, 11(22), 199–209.
<https://doi.org/10.52547/jwmr.11.22.199>
 - Slavisa, T., Branimir, T., & Miomir, S. (2003). Forecasting of Reference Evapotranspiration by Artificial Neural Networks. *Journal of Irrigation and Drainage Engineering*, 129(6), 454–457.
[https://doi.org/10.1061/\(ASCE\)0733-9437\(2003\)129:6\(454\)](https://doi.org/10.1061/(ASCE)0733-9437(2003)129:6(454))
 - Teuling, A. J., Hirschi, M., Ohmura, A., Wild, M., Reichstein, M., Ciais, P., Buchmann, N., Ammann, C., Montagnani, L., Richardson, A. D., Wohlfahrt, G., & Seneviratne, S. I. (2009). A regional perspective on trends in continental evaporation. *Geophysical Research Letters*, 36, L02404.
<https://doi.org/10.1029/2008GL036584>
 - Traore, S., Wang, Y. -M., & Kerh, T. (2010). Artificial neural network for modeling reference evapotranspiration complex process in Sudano-Sahelian zone. *Agricultural Water Management*, 97(5), 707–714.
<https://doi.org/10.1016/j.agwat.2010.01.002>
 - Wang, Y. -M., Traore, S., Kerh, T., & Leu, J. -M. (2011). Modelling reference evapotranspiration using feed forward backpropagation algorithm in arid regions of Africa. *Irrigation and Drainage*, 60(3), 404–417.
<https://doi.org/10.1002/ird.589>
 - Zanetti, S., Sousa E, F., Oliveira V, P., Almeida F, T., & Bernardo, S. (2007). Estimating Evapotranspiration Using Artificial Neural Network and Minimum Climatological Data. *Journal of Irrigation and Drainage Engineering*, 133(2), 83–89.
[https://doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:2\(8](https://doi.org/10.1061/(ASCE)0733-9437(2007)133:2(8)