بررسی عملکرد شبکه‌های عصبی در برآورد تبخیر و تعرق گیاه مرجع (مطالعه موردی: ایستگاه سینوپتیک اهواز)

مریم قربانی[1*]
ساناز شکری[2]
سعید برومند نسب[3]

۱. مدرس دانشگاه پیام نور ایران، تهران، ایران
۲. دانش‌آموخته کارشناسی ارشد آبیاری و زهکشی دانشگاه شهید چمران اهواز، اهواز، ایران
۳. استاد دانشکده مهندسی علوم آب دانشگاه شهید چمران اهواز، اهواز، ایران

***نویسنده مسئول مکاتبات:**
Maryamghorbani688@yahoo.com

کد مقاله: ۱۳۹۵۰۲۰۲۸۲
تاریخ دریافت:۱۳۹۴/۰۵/۲۱
تاریخ پذیرش: ۱۳۹۴/۰۲/۰۱
این مقاله برگرفته از پایان‌نامه کارشناسی ارشد است.

چکیده

تبخیر و تعرق یکی از پارامترهای مؤثر بر بیلان آبی حوضه‌های آبریز و از اجزای اصلی چرخه هیدرولوژیکی محسوب می‌شود. به علت نیاز به برگ خریدهای اقلیمی مختلف و اثر متقابل این برگ خریدها برهم دیگر تبخیر و تعرق یک پدیده غیرخطی و پیچیده می‌باشد. یکی از مراحل پیچیده در مدل‌سازی سیستم‌های غیرخطی، پیش پردازش پارامترهای ورودی جهت انتخاب ترکیبی مناسب است. در این پژوهش امکان استفاده از شبکه‌های MLP,MNN و FF برای تخمین تبخیر و تعرق گیاه مرجع مورد مطالعه قرار گرفته است و در این راستا از نرم‌افزار MATLAB کمک گرفته شد. با استفاده از سری داده‌های هواشناسی سال‌های ۹۳ – ۱۳۷۷ ایستگاه اهواز، ابتدا مقادیر متوسط تبخیر و تعرق روزانه گیاه مرجع از روش استاندارد فائوپنمن‌مانتیث محاسبه شد، سپس با استفاده از این مقادیر به‌عنوان خروجی‌های هدف، شبکه‌های مختلفی با ساختارهای متعارف تعریف و آموزش داده شد. درنهایت قابلیت شبکه برای تخمین تبخیر و تعرق با استفاده از قسمتی از داده‌ها که در طراحی و یا آموزش شبکه استفاده‌نشده است، موردبررسی قرار گرفت. با بررسی‌ها انجام‌گرفته مشخص شد که تنها با استفاده از پارامتر دمای متوسط روزانه به‌عنوان ورودی، می‌توان میزان تبخیر و تعرق گیاه مرجع را با استفاده از سه نوع شبکه با دقت قابل قبولی تخمین زد. هم‌چنین با مقایسه نتایج حاصل از سه شبکه با آزمون‌های آماری مشخص شد که شبکه‌هایFF وMLP با R^2بیش‌تر نسبت به MNN در تعیین تبخیر و تعرق گیاه مرجع از دقت بیش‌تری برخوردار می‌باشند.

واژگان کلیدی: تبخیر و تعرق، فائو پنمن مانتیث، شبکه عصبی، ایستگاه سینوپتیک اهواز.

مقدمه

یکی از راه‌های سازگاری با کم‌آبی استفاده بهینه از منابع آب و افزایش بهره‌وری آب است. از راه‌های مدیریت بهینه منابع آب، شناخت پدیده تبخیر و تعرق و متغیرهای مؤثر بر آن می‌باشد. تخمین دقیق میزان منابع و مصرف آب در یک حوضه، به دلیل وجود عوامل مؤثر متعدد، بسیار مشکل می‌باشد. اکثر این عوامل گنگ، نادقیق و نامشخص بوده که با مباحث ریاضی کلاسیک معمول قابل‌بررسی نیست؛ بنابراین در سال‌های اخیر استفاده از مباحث تئوری منطق فازی در شبیه‌سازی و بهینه‌سازی حوضه‌ها جایگاه خود را پیداکرده است و اکثر محققین این رشته این مفاهیم را به‌عنوان ابزار بسیار قوی در این زمینه معرفی کرده‌اند (Li and *et al*., 2001). قدم اول در این زمینه انتخاب یک روش مناسب با توجه به شرایط منطقه موردمطالعه می‌باشد. به‌منظور مطالعه تبخیر و تعرق گیاه که از اجزای نیاز آبی گیاه می‌باشد، می‌توان از روش‌هایی

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]

همچون پنمن فائو، فائوپنمن‌مانتیث، بلانی‌کریدل و غیره استفاده نمود (زند پارسا و سپاس‌خواه، ۱۳۷۵). از طرفی اکثر این روش‌ها به‌خصوص روش فائوپنمن‌مانتیث که در سال‌های اخیر نظر محققین را به خود معطوف کرده است، دارای پارامترهای زیادی است که در اکثر موارد نیاز به فرضیات اولیه‌ای دارد که درنهایت نتایج این مدل‌ها را نامطمئن می‌سازد. تئوری مجموعه فازی یک چارچوب را در مدل‌سازی شرایط گنگ و نامشخص ایجاد می‌کند و شبکه‌های عصبی دارای قابلیت آموزش این‌چنین پیچیدگی‌های تولید اطلاعات و کلاس‌بندی ورودی‌ها می‌باشند (پیرمرادیان و ابول‌پور، ۱۳۸۹).

در طی سالیان اخیر تحقیقات متعددی در ارتباط با تخمین تبخیر و تعرق از روی‌داده‌های هواشناسی با استفاده از روش هوشمند در نقاط مختلف دنیا انجام‌گرفته است. Odhiambo و همکاران (۲۰۰۱) Kumar و همکاران (۲۰۰۲)، Silva (۲۰۰۲) و Trajkovic و همکاران (۲۰۰۳) از داده‌های هواشناسی یکسانی در تحقیقات خود استفاده نمودند و طی تحقیقات خود نشان دادند که نتایج حاصل از تخمین تبخیر و تعرق با استفاده از شبکه‌های عصبی مصنوعی دارای دقت بالاتری نسبت به روش‌های رایج تبخیر و تعرق می‌باشد (Rahimi Khoob(a), 2008). Sudheer و همکاران (۲۰۰۳)، برای محاسبه تبخیر و تعرق از داده‌های ساده‌شده مانند دمای هوا، تابش برون زمینی و ساعات آفتابی استفاده نمودند. Kisi و Ozturk (۲۰۰۷)، جهت تخمین مقدار تبخیر و تعرق به روش فائوپنمن‌مانتیث از سیستم استنتاج عصبی فازی (ANFIS) استفاده نمودند. سلطانی و مرید (۱۳۸۴)، برای برآورد مقادیر تابش خورشیدی که یکی از مؤلفه‌های موردنیاز روش پنمن مانتیث می‌باشد، از شبکه‌های عصبی مصنوعی استفاده نمودند و نتایج را با مقادیر حاصل از روش هارگریوز سامانی مقایسه کردند و نتیجه گرفتندکه شبکه‌های عصبی عملکرد بهتری نسبت به روش هارگریوز سامانی در برآورد تابش نشان می‌دهند. صیادی و همکاران (۱۳۸۸)، به مقایسه عملکرد شبکه‌های عصبی RBF و MLP در برآورد تبخیر و تعرق گیاه مرجع در ایستگاه تبریز پرداختند، نتایج آن‌ها نشان داد که شبکه‌های MLP نسبت به RBF در تخمین تبخیر و تعرق گیاه مرجع از دقت نسبتاً بیشتری برخوردارند و تنها مزیت شبکه‌های RBF را زمان کمتر موردنیاز برای آموزش بیان کردند. ستاری و همکاران (۱۳۹۲)، به پیش‌بینی تبخیر و تعرق مرجع روزانه با استفاده از مدل شبکه عصبی مصنوعی و مدل درختی M5 در ایستگاه بناب استان آذربایجان شرقی پرداختند نتایج آن‌ها بر دقت بیش‌تر شبکه عصبی مصنوعی در مقایسه با روش درختی M5 در پیش‌بینی تبخیر و تعرق گیاه مرجع بیان شد. ملکی نژاد و همکاران (۱۳۹۳)، با استفاده از فن‌های هوش محاسباتی و هم‌چنین روش‌های آماری چندمتغیره، تحلیل حساسیت عوامل مؤثر بر تبخیر و تعرق مرجع بر پایه روش فائو پنمن مانتیث در مناطق غرب و شمال غرب ایران پرداختند. نتایج آن‌ها نشان داد روش شبکه عصبی نسبت به روش‌های درختی تصمیم و تحلیل عاملی برای تعیین مهم‌ترین پارامترهای تبخیر و تعرق کارایی بهتری دارد. هژبر و همکاران (۱۳۹۳) به برآورد تبخیر و تعرق گیاه مرجع با استفاده از شبکه عصبی مصنوعی پرداختند و در این راستا از نرم‌افزار مطلب کمک گرفتند و نتایج خود را باداده‌های لایسی‌متری در ایستگاه کهریز ارومیه مقایسه کردند و بهترین مدل را مدل تورک بیان کردند.

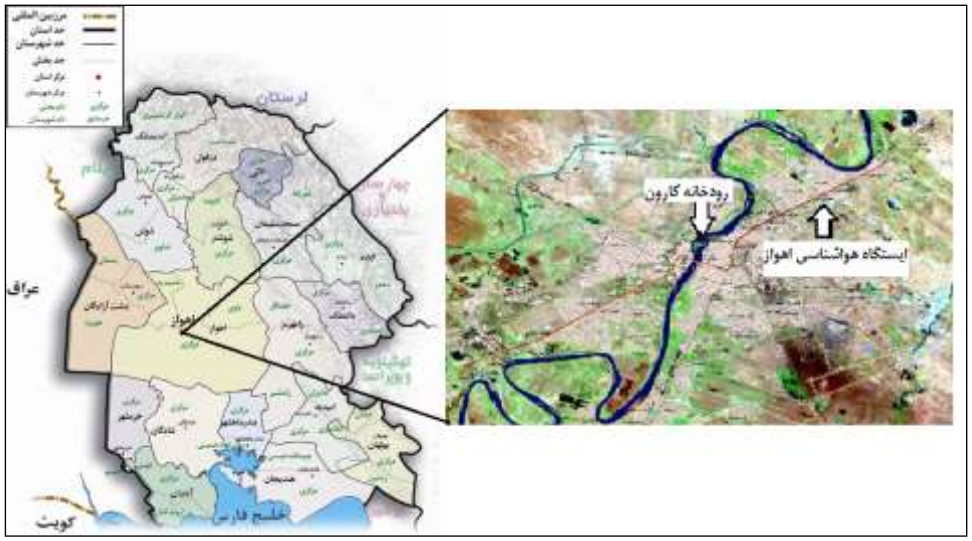
در تحقیق حاضر با استفاده از شبکه‌های عصبی از سه مدل MLP، MNN وFF مقادیر تبخیر و تعرق روزانه، محاسبه‌شده از روش فائوپنمن‌مانتیث با استفاده از داده‌های هواشناسی روزانه مربوط به ایستگاه سینوپتیک اهواز مدل‌سازی شده است. نتایج این سه مدل با مقادیر محاسبه شده از روش فائو پنمن‌مانتیث مقایسه شده است.

مواد و روش‌ها

برای مطالعه حاضر از داده‌های اقلیمی حداکثر و حداقل دما، رطوبت نسبی، سرعت باد و تابش خورشیدی مربوط به ایستگاه سینوپتیک اهواز مربوط به دوره‌ی آماری ۱۳۷۷ تا ۱۳۹۳ برای محاسبه تبخیر و تعرق روزانه گیاه مرجع مورداستفاده قرارگرفته است. این ایستگاه در ۳۱ درجه و ۲۰ دقیقه عرض جغرافیایی و ۴۸ درجه و ۴۰ دقیقه طول جغرافیایی و در ارتفاع ۲۲/۵ متری از سطح دریا واقع‌شده است. میانگین حداکثر و

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]

حداقل دما در ایستگاه به ترتیب ۳۳/۳ و ۱۹/۴ و سرعت باد ۱۶۶ کیلومتر بر ساعت می‌باشد. شکل ۱ موقعیت این ایستگاه در اهواز را نشان می‌دهد.



شکل ۱: موقعیت منطقه موردمطالعه.

به دلیل عدم دسترسی به داده‌های لایسی‌متری، از روش فائوپنمن‌مانتیث برای تخمین تبخیر و تعرق گیاه مرجع استفاده‌شده است. روش فائوپنمن‌مانتیث در میان روش‌های مختلف تخمین تبخیر و تعرق گیاه مرجع همواره بیشترین دقت را دارا بوده است ازاین‌رو مقادیر محاسبه‌شده از روش فائوپنمن‌مانتیث به‌عنوان مقادیر استاندارد برای آموزش و صحت سنجی ساختارهای متفاوت شبکه عصبی مورداستفاده قرارگرفته است.

در سال ۱۹۹۸ میلادی،Alen و همکاران در نشریه شماره ۵۶ سازمان فائو رابطه ۱ را که به نام رابطه فائو پنمن‌مانتیث معروف است، به عنوان دقیق‌ترین روش برای برآورد نیاز آبی گیاه ارائه نموده‌اند:

رابطه ۱:

$$ET_O = \frac{0.408\times\Delta\times(Rn-G)+\gamma\times(\frac{900}{Tm+273})\times U_2\times(e_s-e_a)}{\Delta+\gamma(1+0.34U_2)}$$

که درآن:

ET_O: تبخیر تعرق پتانسیل گیاه مرجع حسب میلی متر در روز، Rn: تشعشع خالص دریافتی در سطح گیاه برحسب مگاژول بر مترمربع در روز، Tm: میانگین روزانه دمای هوا در ارتفاع ۲ متری از سطح زمین حسب درجه سانتی‌گراد، G: شارژ گرمایی خاک حسب مگا ژول بر متر در روز، e_s: فشار بخار اشباع حسب کیلو پاسکال، e_a: فشار بخار واقعی حسب کیلو پاسکال، U_2: میانگین روزانه سرعت باد در ارتفاع ۲ متری از سطح زمین حسب متر بر ثانیه، Δ: شیب منحنی بین فشار بخار اشباع و دما بر حسب کیلو پاسکال بر درجه سانتی گراد و γ: ثابت سایکرومتری برحسب کیلو پاسکال بر درجه سانتی‌گراد می‌باشد.

شبکه عصبی مصنوعی یک سامانه پردازش داده‌ها است که از مغز انسان ایده گرفته و پردازش داده‌ها را به عهده پردازنده‌های کوچکی به نام درون سپرده که به‌صورت شبکه‌ای به‌هم‌پیوسته و موازی با یکدیگر رفتار می‌کنند تا یک مسئله را حل نمایند. شبکه مصنوعی از سه لایه به نام لایه ورودی، لایه مخفی و لایه خروجی تشکیل‌شده است که در هر لایه یک یا چند عنصر پردازشگر وجود دارد که با تمام نرون‌های لایه

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]

بعدی مرتبط می‌باشند (منهاج، ۱۳۸۱). جهت کار با شبکه‌های عصبی مصنوعی، نرم افزارهای متعددی وجود دارد، بسته به قابلیت‌های هر نرم‌افزار می‌توان یکی از آن‌ها را انتخاب کرد. برای انجام این تحقیق از نرم افزار MATLAB استفاده شد.

قبل از هر چیزی باید داده‌ها در بازه (۰ و ۱) نرمال شوند، برای این کار می‌توان به دو روش زیر عمل نمود. روش اول در رابطه ۲ نشان داده شده است:

رابطه ۲:

$$D_N = \frac{D-D_{Min}}{D_{Max}-D_{Min}}$$

D_N: داده‌های نرمال شده، D: داده واقعی، D_{Min}: کوچک‌ترین داده واقعی، D_{Max}: بزرگ‌ترین داده واقعی.

روش دوم: استفاده از دستور mapminmax در برنامه مطلب می‌باشد که رابطه ۳ این دستور را نشان می‌دهد.

رابطه ۳:

```
[pn,ps]=mapminmax(p,0,1)
```

Pn: ماتریس نرمال شده، Ps: ساختار مربوط به پارامترهای تنظیمی جهت برگرداندن داده‌های شبیه‌سازی شده به داده‌های حقیقی،P : ماتریس داده‌های حقیقی.

در این تحقیق از رابطه ۳ استفاده شده است، بعد از نرمال کردن داده‌های ورودی و خروجی، باید آن‌ها را در دو آرایه ردیف به ردیف قرارداد، مرحله بعدی کد نویسی در قسمت M-File است و بعدازاین مرحله، شبکه آماده RUN می‌باشد.

پس از تهیه داده‌های مورد نیاز، شبکه باید طراحی گردد، به این منظور ۱۲ سناریو برای تبخیر و تعرق گیاه مرجع تعریف شد که در جدول ۱ ارائه‌شده است.

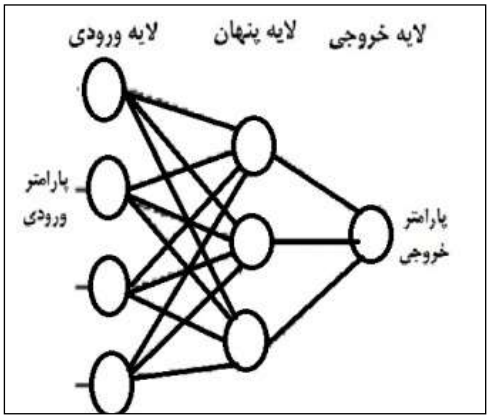
جدول ۱: سناریوهای تبخیر و تعرق.

سناریو	پارامترهای ورودی
۱	رطوبت نسبی، ساعات آفتابی، سرعت باد، حداکثر دما و حداقل دما.
۲	رطوبت نسبی، ساعات آفتابی، سرعت باد و متوسط دما
۳	رطوبت نسبی، ساعات آفتابی، سرعت باد و حداقل دما
۴	رطوبت نسبی، ساعات آفتابی، سرعت باد و حداکثر دما
۵	ساعات آفتابی، سرعت باد و متوسط دما
۶	رطوبت نسبی، سرعت باد و متوسط دما
۷	رطوبت نسبی و ساعات آفتابی
۸	سرعت باد و حداقل دما
۹	رطوبت نسبی و حداکثر دما
۱۰	رطوبت نسبی
۱۱	ساعات آفتابی
۱۲	متوسط دما

شبکه‌های چندلایه پیش‌خور یکی از مهم‌ترین ساختارهای شبکه‌های عصبی مصنوعی می‌باشند. به‌طورمعمول این شبکه‌ها شامل مجموعه‌ای از واحدهای حسی (نرون‌های پایه) می‌باشند که تشکیل‌دهنده لایه ورودی، یک یا چندلایه پنهان و یک‌لایه خروجی می‌باشند.

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]

سیگنال ورودی در خلال شبکه و در مسیری روبه‌جلو به‌صورت لایه به لایه منتشر می‌شود. این نوع شبکه معمولاً بانوان پرسپترون چند لایه (MLP) نامیده می‌شود (Haykin, 1999). شکل ۲ تصویر شماتیک این نوع شبکه عصبی را نشان می‌دهد.



شکل ۲: تصویر شماتیک شبکه پرسپترون چند لایه.

طی چند دهه اخیر، تلاش‌های فراوانی برای مدل کردن یک نورون طبیعی که قادر به توصیف خصوصیات یک سیستم بیولوژیک باشد و شبکه‌های عصبی زیستی را همانندسازی کند، صورت گرفته است. شبکه‌های مدل شده بانام الگوهای ۴ شبکه عصبی شناخته‌شده و گسترش یافتند. مشخصات اساسی شبکه عصبی را می‌توان توسط ساختار آن‌ها و خصوصیات عملیاتی و دینامیکی آن شناسایی کرد. شبکه عصبی پرسپترون با یک‌لایه ورودی آغاز می‌شوند و شار اطلاعات را به سمت لایه خروجی هدایت می‌نمایند. میان این دولایه نیز ممکن است چندین لایه مخفی وجود داشته باشد. لازم به ذکر است تعداد این لایه‌ها و هم‌چنین تعداد گره‌ها در هر لایه مخفی معمولاً به‌روش آزمون‌وخطا تعیین می‌گردد. ساختار شبکه الگوریتم پس انتشار خطا، وزن‌های شبکه و مقادیر بایاس را در جهتی تغییر می‌دهد که تابع عملکرد با سرعت بیش‌تری کاهش یابد. الگوریتم پس انتشار خطا را می‌توان به شکل رابطه ۴ نشان داد (علیایی و همکاران، ۱۳۸۹):

رابطه ۴:
$$x_{k+1} = x_k - \alpha_k g_k$$

که در آن: x_k بردار وزن‌ها و بایاس در تکرار kام، α_k نرخ آموزش در تکرار kام، g_k گرادیان در تکرار k ام می‌باشد.

الگوریتم لونبرگ- مارکوارت برای دستیابی به آموزش سریع‌تر شبکه بسط داده‌شده است رابطه ۵ معادله آن را نشان می‌دهد:

رابطه ۵:
$$x_{k+1} = x_k - \left[J^T J + \mu I\right]^{-1} J^T e$$

که در آن: x_k بردار وزن‌ها و بایاس در تکرار kام، J: ماتریس ژاکوبین شامل اولین مشتقات خطای شبکه با توجه به وزن‌ها و بایاس، e: بردار خطاهای شبکه، I: ماتریس واحد و μ: یک کمیت اسکالر است.

μ پس از هر گام موفق کاهش می‌یابد و در صورتی که یک گام منفرد، تابع عملکرد را افزایش دهد μ نیز افزایش می‌یابد (صیادی و همکاران، ۱۳۸۸). در این تحقیق از مقدار اولیه ۰/۰۰۱ برای μاستفاده و سه مدل شبکه عصبیMLP , FF و MNN برای محاسبه تبخیر و تعرق گیاه مرجع مدل‌سازی شده است.

برای جلوگیری از آموزش بیش‌ازاندازه در شبکه‌ها از روش متوقف سازی زودهنگام آموزش استفاده شد و داده‌ها به‌صورت تصادفی به سه مجموعه ۷۵ درصد داده‌ها برای آموزش، ۱۵ درصد برای صحت سنجی و ۱۰ درصد برای آزمون استفاده شد.

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]

توانایی آموزش یافتن و هم‌چنین تصحیح خطاهای محلی در حین پردازش موازی اطلاعات ورودی از مهم‌ترین ویژگی‌های شبکه‌های عصبی می‌باشد. برای آموزش شبکه عصبی در هر گام مقدار وزن‌ها طوری تغییر می‌یابند که جذر میانگین مربعات خطا، مینیمم شود. مقدار خطای خروجی برابر با اختلاف بین مقدار هدف و خروجی شبکه است. منظور از آموزش شبکه عصبی مصنوعی، محاسبه وزن اتصالات مختلف است. برای آموزش شبکه عصبی از الگوریتم‌های یادگیری متفاوتی استفاده می‌شود، انتخاب هر الگوریتم بر سرعت یادگیری و دقت شبکه مؤثر است (کیا، ۱۳۸۹).

شبکه‌های عصبی مصنوعی باوجود این‌که با سیستم عصبی طبیعی قابل‌مقایسه نیستند، ویژگی‌هایی دارند که آن‌ها را در بعضی از کاربردها مانند تفکیک الگو و یا هر جا که نیاز به یادگیری با یک نگاشت خطی و یا غیرخطی باشد، ممتاز می‌نمایند. از ویژگی‌ها و قابلیت‌های شبکه‌های عصبی مصنوعی به مواردی همچون قابلیت یادگیری و تطبیق‌پذیری با اطلاعات موجود، قابلیت تعمیم دهی، پردازش موازی ورودی‌های شبکه و درنتیجه افزایش سرعت پردازش، تحمل‌پذیری بالای خطاها و غیره می‌توان اشاره کرد (منهاج، ۱۳۸۱). به‌منظور ارزیابی و مقایسه دقت مدل به‌کاربرده شده در شبیه‌سازی تبخیر و تعرق گیاه مرجع از معیارهای میانگین مربعات خطا (MSE)، میانگین مربعات خطای نرمال شده (NMSE) و ضریب تعیین (R^2) استفاده‌شده است. بهترین مقدار برای MSE و NMSE برابر صفر و برای R^2 یک می‌باشد و مقادیر آن‌ها به‌صورت روابط ۶، ۷ و ۸ محاسبه می‌شود.

رابطه ۶:
$$MSE = \frac{1}{n}\sum_{i=1}^{n}(O_i - P_i)^2$$

رابطه ۷:
$$NMSE = \frac{\frac{1}{n}\sum_{i=1}^{n}(O_i - P_i)^2}{V}$$

رابطه ۸:
$$R^2 = \frac{\left[\sum_{i=1}^{n}(O_i - \overline{O})(P_i - \overline{P})\right]^2}{\sum_{i=1}^{n}(O_i - \overline{O})^2 \sum_{i=1}^{n}(P_i - \overline{P})^2}$$

که در این معادلات، O_i و P_i : به ترتیب مقادیر مشاهداتی و شبیه‌سازی‌شده، $\overline{O}$ و $\overline{P}$: به ترتیب مقادیر میانگین داده‌های مشاهداتی و میانگین داده‌های شبیه‌سازی‌شده، n تعداد داده‌ها و V واریانس خروجی موردنظر می‌باشد (Najah *et al.*, 2011).

نتایج

با استفاده از ابزارهای شبکه عصبی در نرم‌افزار مطلب و تعریف ۱۲ سناریو برای پارامترهای مؤثر، شبکه‌های متعددی با ساختارها و پارامترهای ورودی متفاوت برای تخمین تبخیر و تعرق گیاه مرجع در اهواز تعریف شد. تعداد نرون‌های لایه پنهان و نرخ آموزش درشبکه‌های MLP, MNN و FF با استفاده از آزمون‌وخطا تعیین گردید. جدول ۲ نتایج کالیبراسیون را نشان می‌دهد.

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]

جدول ۲: نتایج حاصل از کالیبراسیون هر یک از مدل‌های MLP، MNN، FF.

مدل	تکرار آموزش	الگوریتم آموزش	تابع انتقال	
			لایه میانی	لایه خروجی
MLP	۱۷۵۰	مومنتم	تانژانت هیپربولیک آکسون	تانژانت هیپربولیک آکسون
MNN	۱۷۰۰	مومنتم	تانژانت هیپربولیک آکسون	تانژانت هیپربولیک آکسون
FF	۱۵۰۰	مومنتم	تانژانت هیپربولیک آکسون	تانژانت هیپربولیک آکسون

درنهایت پس از انتخاب ساختار بهینه برای هر سناریو و محاسبه مقادیر توابع عملکرد، این سناریوها با در نظر گرفتن میزان معیارهای میانگین مربعات خطا (MSE)، میانگین مربعات خطای نرمال شده (NMSE) و ضریب تعیین (R^2) رتبه‌بندی شدند. جدول‌های ۳ تا ۵ نتایج کلی آموزش و صحت‌سنجی شبکه‌های MLP، MNN و FF را برای محاسبه تبخیر و تعرق گیاه مرجع در شرایط اقلیمی اهواز را نشان می‌دهند.

جدول ۳: نتایج کلی آموزش و صحت‌سنجی شبکه‌های MLP.

رتبه	شماره سناریو	R^2 (آموزش)	R^2 (صحت‌سنجی)	MSE	NMSE
۱	۴	۰/۹۹۹	۰/۹۹۹	۰/۰۰۷	۰/۰۰۱۸
۲	۱	۰/۹۹۸	۰/۹۹۹	۰/۰۰۸۳	۰/۰۰۲۳
۳	۲	۰/۹۹۸	۰/۹۹۹	۰/۰۰۰۹	۰/۰۰۲۵
۴	۳	۰/۹۹۸	۰/۹۹۶	۰/۰۰۱۴	۰/۰۰۳۷
۵	۵	۰/۹۹۷	۰/۹۹۷	۰/۰۰۱۷	۰/۰۰۴۷
۶	۹	۰/۹۹۵	۰/۹۹۵	۰/۰۰۳۴	۰/۰۰۸۹
۷	۶	۰/۹۹۵	۰/۹۹۳	۰/۰۰۳۳	۰/۰۰۹
۸	۷	۰/۹۹	۰/۹۸۳	۰/۰۰۶۳	۰/۰۱۶
۹	۱۲	۰/۹۸۹	۰/۹۹۱	۰/۰۰۷۴	۰/۰۲
۱۰	۸	۰/۹۸۶	۰/۹۸۸	۰/۰۰۸۸	۰/۰۱
۱۱	۱۰	۰/۹۷۱	۰/۹۶۷	۰/۰۲۱	۰/۰۵
۱۲	۱۱	۰/۹۶۲	۰/۹۲۹	۰/۰۲۷	۰/۰۷۴

جدول ۴: نتایج کلی آموزش و صحت‌سنجی شبکه‌های MNN.

رتبه	شماره سناریو	R^2 (آموزش)	R^2 (صحت‌سنجی)	MSE	NMSE
۱	۱	۰/۹۹۶	۰/۹۹۶	۰/۰۰۲۸	۰/۰۰۸
۲	۴	۰/۹۹۴	۰/۹۹۵	۰/۰۰۴۴	۰/۰۱۱
۳	۲	۰/۹۹۳	۰/۹۹۵	۰/۰۰۵۱	۰/۰۴۱
۴	۳	۰/۹۹۳	۰/۹۹۴	۰/۰۰۵	۰/۰۱۳
۵	۵	۰/۹۹۲	۰/۹۹۳	۰/۰۰۵	۰/۰۱۵

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]

۶	۹	۰/۹۹	۰/۹۹	۰/۰۰۷	۰/۰۱۸
۷	۶	۰/۹۸۹	۰/۹۹	۰/۰۰۷۵	۰/۲
۸	۱۲	۰/۹۸۷	۰/۹۹	۰/۰۰۹۷	۰/۰۲۸
۹	۷	۰/۹۸۷	۰/۹۷۴	۰/۰۰۹۸	۰/۲۵۱
۱۰	۸	۰/۹۸۴	۰/۹۸۴	۰/۰۱۱	۰/۰۳۱
۱۱	۱۰	۰/۹۷	۰/۹۶۷	۰/۰۲۱	۰/۰۵۹
۱۲	۱۱	۰/۹۶۱	۰/۹۲۷	۰/۰۲۸	۰/۰۵۱

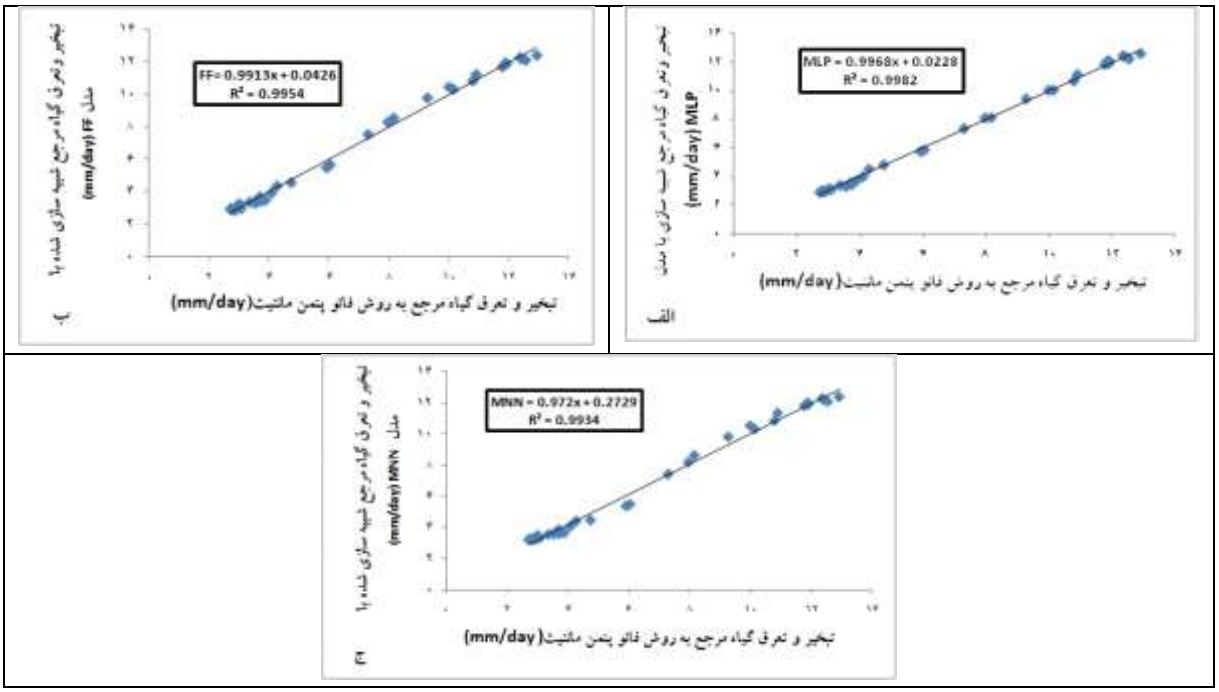
جدول ۵: نتایج کلی آموزش و صحت‌سنجی شبکه‌های FF.

رتبه	شماره سناریو	R^2 (آموزش)	R^2 (صحت‌سنجی)	MSE	NMSE
۱	۴	۰/۹۹۷	۰/۹۹۷	۰/۰۰۱۹	۰/۰۰۵۳
۲	۱	۰/۹۹۷	۰/۹۹۷	۰/۰۰۲۱	۰/۰۰۶
۳	۲	۰/۹۹۶	۰/۹۹۸	۰/۰۰۲۲	۰/۰۰۶۱
۴	۳	۰/۹۹۶	۰/۹۹۵	۰/۰۰۲۲۳	۰/۰۱۱
۵	۵	۰/۹۹۴	۰/۹۹۴	۰/۰۰۴۱	۰/۰۱۱
۶	۶	۰/۹۹۱	۰/۹۹	۰/۰۰۶۱	۰/۰۱۶
۷	۹	۰/۹۸۹	۰/۹۸۹	۰/۰۰۷	۰/۰۲۳
۸	۱۲	۰/۹۸۸	۰/۹۹۱	۰/۰۰۸۵	۰/۰۲۳
۹	۷	۰/۹۸۷	۰/۹۷۳	۰/۰۰۹	۰/۰۲۴
۱۰	۸	۰/۹۸۵	۰/۹۸۷	۰/۰۱۱	۰/۰۲۹
۱۱	۱۰	۰/۹۶۹	۰/۹۴۷	۰/۰۲	۰/۰۵۹
۱۲	۱۱	۰/۹۶۱	۰/۹۲۸	۰/۰۲۸	۰/۰۷۴

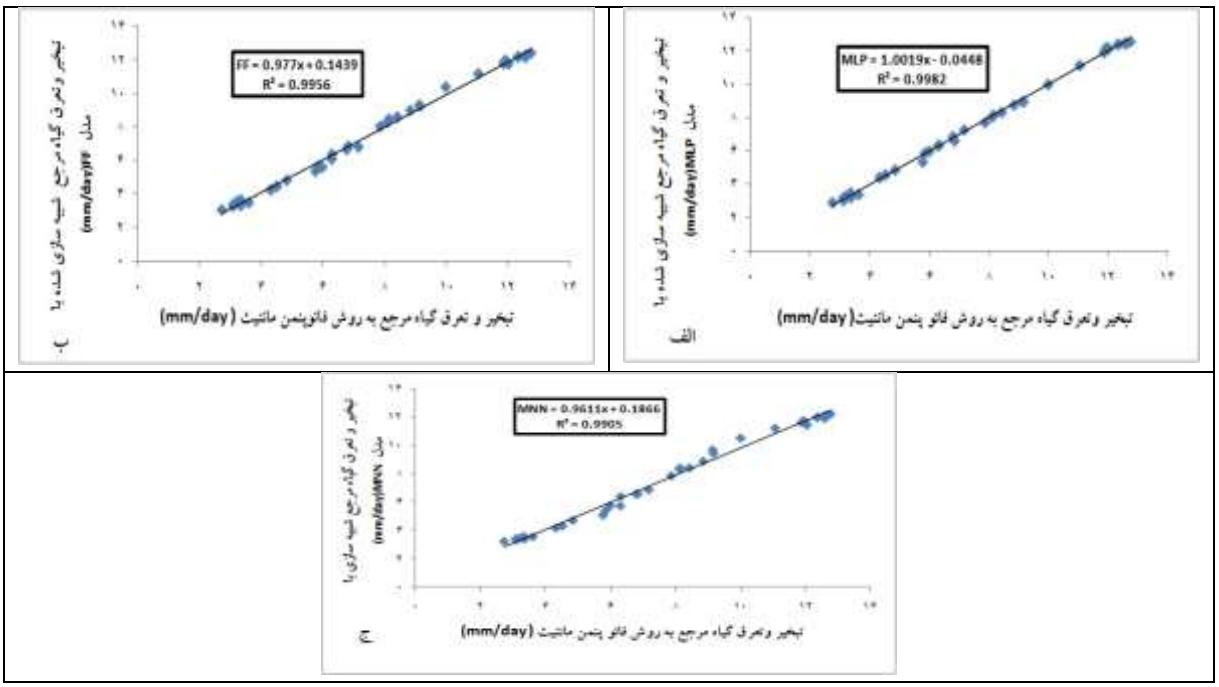
چنانچه در جدول‌ها مشخص است تمام سناریوهای پیشنهادی دقت قابل قبولی در برآورد تبخیر و تعرق گیاه مرجع دارند. سناریو شماره ۴ با داشتن پارامترهای رطوبت نسبی، ساعات آفتابی، سرعت باد و حداکثر دما برای برآورد تبخیر و تعرق گیاه مرجع با داشتن کمترین خطا در دو شبکه MLP و FF رتبه یک و در شبکه MNN رتبه دوم رتبه دست آورده است و سناریو شماره ۱ با دخیل بودن تمام پارامترها در شبکه MLP و FF رتبه دوم و در شبکه MNN رتبه اول را به دست آورده است. بااین‌وجود با مقایسه نتایج مشخص شد که سناریو ۱۲ که تنها از پارامتر دمای متوسط برای تخمین تبخیر و تعرق گیاه مرجع استفاده می‌کند، در هر سه شبکه می‌تواند به‌عنوان بهینه‌ترین سناریو انتخاب گردید، زیرا باوجود این‌که این سناریو از یک پارامتر به‌عنوان ورودی شبکه استفاده می‌نماید ولی دقت آن قابل‌مقایسه با سناریوهای دارای تعداد پارامتر ورودی بیشتر می‌باشد. صیادی و همکاران (۱۳۸۸) با مقایسه عملکرد دو شبکه عصبی MLP و RBF در برآورد تبخیر و تعرق گیاه مرجع در تبریز پرداختند و بهترین سناریو را با پارامترهای ورودی دمای میانگین ماهانه و سرعت باد در این منطقه معرفی کردند که علت این اختلاف را در این دو ایستگاه می‌توان شرایط مختلف اقلیمی و میزان سرعت وزش باد متفاوت بیان کرد.

اشکال ۳، ۴ و ۵ نمونه‌ای از سناریوهای انجام‌شده (سناریو ۱، ۴ و ۱۲) برای مقایسه تبخیر و تعرق گیاه مرجع از سه شبکه عصبی با روش فائوپنمن‌مانتیث در اهواز را نشان می‌دهند.

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]

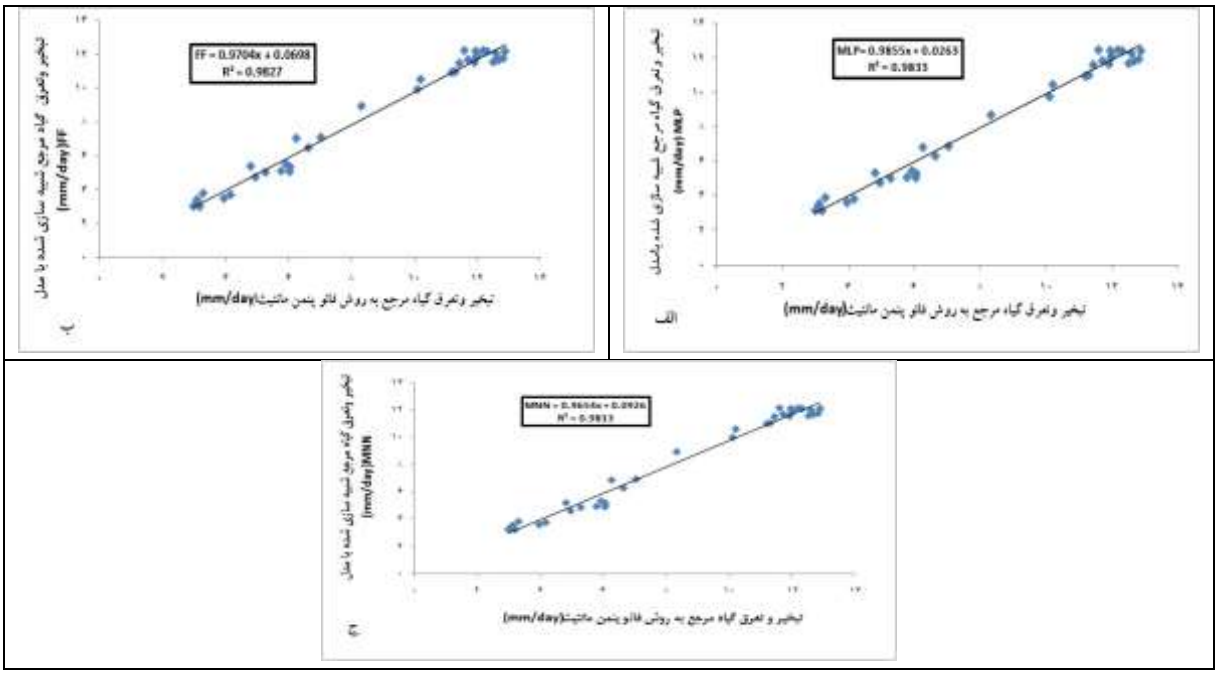


شکل ۳: مقایسه تبخیر و تعرق گیاه مرجع محاسبه‌شده با روش فائوپنمن‌مانتیث با سه شبکه MLP (الف)، FF (ب) و MNN (ج) در سناریو یکم.



شکل ۴: مقایسه تبخیر و تعرق گیاه مرجع محاسبه‌شده با روش فائوپنمن‌مانتیث با سه شبکه MLP (الف)، FF (ب) و MNN (ج) در سناریو چهارم.

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]



شکل ۵: مقایسه تبخیر و تعرق گیاه مرجع محاسبه‌شده با روش فائوپنمن‌مانتیث با سه شبکهMLP (الف)، FF (ب) و MNN (ج) در سناریو دوازدهم.

مقدار NMSE درتخمین تبخیر و تعرق روزانه برای شبکه MLP به‌طور میانگین برابر ۰/۰۳۳۲، برای شبکه FF برابر ۰/۰۲۳۹ و برای شبکه MNN برابر با ۰/۰۶۱۶ به دست آمد. درمجموع با توجه به نتایج حاصل مشخص شد که شبکه MLP که متداول‌ترین نوع شبکه‌های عصبی در مدل‌سازی دستگاه‌های مختلف می‌باشد و شبکه FF، در مدل‌سازی و تخمین تبخیر و تعرق روزانه گیاه مرجع عملکرد بهتری نسبت به شبکه MNN دارد.

Kumar و همکاران (۲۰۰۲) به محاسبه تبخیر و تعرق گیاه مرجع به‌صورت روزانه با استفاده از شبکه MLP پرداختند و ضریب تعیین را در محدوده ۰/۹۸۷ تا ۰/۹۸۹ برای کل داده‌ها به دست آوردند.

Zanetti و همکاران (۲۰۰۷) در برآورد تبخیر و تعرق گیاه مرجع به‌وسیله شبکه‌های عصبی دریافتند که شبکه عصبی مدل MLP در برآورد تبخیر و تعرق میانگین ماهانه نسبت به تبخیر و تعرق روزانه از دقت بیشتری برخوردار است. همچنین نتایج آن‌ها در منطقه موردمطالعه نشان‌دار که با دو پارامتر حداکثر و حداقل دما می‌توان مقدار تبخیر و تعرق گیاه مرجع را با دقت بالاتری تخمین زد.

بحث و نتیجه‌گیری

بررسی و مدل‌سازی رفتار هر پدیده فیزیکی مشخص، ساده و امکان‌پذیر است. به دلیل عوامل نامشخص، مدل‌سازی رفتار هر متغیر در تبخیر و تعرق گیاه ساده نبود و نیاز به روش‌های خاص دارد. در سال‌های اخیر شبکه عصبی مصنوعی توانسته راه گشای خوبی در مباحث مدل-سازی باشد.

در این پژوهش از سه نوع شبکه عصبی مصنوعی برای تخمین تبخیر و تعرق گیاه مرجع در اهواز مورداستفاده قرار گرفت. در این بررسی برای نخستین بار از شبکه‌های عصبی MNN و FF برای تخمین تبخیر و تعرق گیاه مرجع مورداستفاده قرار گرفت. مقادیر محاسبه‌شده از

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]

روش فائوپنمن‌مانتیث با عنوان هدف در آموزش شبکه عصبی قرار گرفت و شبکه‌های متفاوتی با ۱۲ سناریو ایجاد و عملکرد آن‌ها موردبررسی قرار گرفت؛ و بهترین سناریو، سناریو دوازدهم با تنها یک پارامتر ورودی (دمای متوسط) و دقت بالا شناخته شد. باوجود این‌که هر سه شبکه MLP,MNN و FF قادر هستند مقادیر تبخیر و تعرق گیاه مرجع را برای این حوضه با دقت مناسبی تخمین بزنند، ولی دو شبکه MLP و FF در برآورد تبخیر و تعرق دقت بالاتری دارند.

هم‌چنین اگرچه با کاهش پارامترهای ورودی از دقت برآورد مدل‌ها کاسته می‌شود اما توجه به عدم دسترسی به آمار موردنیاز، این شبکه‌ها می‌توانند راهکار مناسب‌تری نسبت به کاربرد روش‌های تجربی در شرایط عدم وجود اطلاعات کافی باشند.

به‌طورکلی نتایج به‌دست‌آمده از این تحقیق و تحقیقات متعددی ازجمله ستاری و همکاران (۱۳۹۲)، ملکی‌نژاد و همکاران (۱۳۹۳) و هژبر و همکاران (۱۳۹۳) حاکی از عملکرد مطلوب شبکه‌های عصبی مصنوعی در برآورد تبخیر و تعرق گیاه مرجع می‌باشد.

پیشنهاد می‌شود سایر روش‌های برآورد تبخیر و تعرق گیاه مرجع نیز با شبکه عصبی مصنوعی در مناطق مختلف برازش داده شود.

منابع

البرزی، م.، ۱۳۸۰. آشنایی با شبکه‌های عصبی. چاپ اول، مؤسسه انتشارات دانشگاه صنعتی شریف، ۱۳۷ ص.

پیرمرادیان، ن. و ابول‌پور، ب.، ۱۳۸۹. تخمین تبخیر-تعرق بالقوه گیاه مرجع با استفاده از منطق فازی و شبکه عصبی مصنوعی. مجله علوم زیستی واحد لاهیجان، سال چهارم، شماره سوم، پاییز ۱۳۸۹. صفحات ۳۴-۲۱.

زند پارسا، ش. و سپاس‌خواه، ع.، ۱۳۷۵. تعیین تبخیر تعرق پتانسیل گیاه مرجع بر اساس برخی عوامل قابل‌اندازه‌گیری در ایستگاه‌های هواشناسی ایران. ششمین سمینار سراسری آبیاری و کاهش تبخیر، ۱۰ و ۱۱ شهریور کربال-ایران. صفحات ۲۹-۱۸.

ستاری، م.، نهرین، ف. و عظیمی، و.، ۱۳۹۲. پیش‌بینی تبخیر- تعرق مرجع روزانه با استفاده از مدل شبکه عصبی مصنوعی و مدل درختیM5 (مطالعه موردی: ایستگاه بناب). نشریه آبیاری و زهکشی ایران، جلد ۷، شماره ۱. صفحات ۱۱۳-۱۰۴.

سلطانی، س. و مرید، س.، ۱۳۸۴. مقایسه برآورد تابش خورشید با استفاده از روش‌های هارگریوز- سامانی و شبکه‌های عصبی مصنوعی. مجله دانش کشاورزی، جلد ۱۵، شماره ۱. صفحات ۷۸-۶۹.

صیادی، ح.، اولاد غفاری، ع.، فعالیان، ا. و صدرالدینی، ع، ا.، ۱۳۸۸. مقایسه عملکرد شبکه‌های عصبی MLP و RBF در برآورد تبخیر و تعرق گیاه مرجع. مجله دانش آب‌وخاک، جلد ۱۹ شماره ۱. صفحات ۱۲-۲.

علیایی، ا.، با نژاد، ح.، صمدی، م، ت.، رحمانی، ع، ر. و ساقی، م، ح.، ۱۳۸۹. ارزیابی کارایی شبکه عصبی مصنوعی در پیش‌بینی شاخصه‌ای کیفی (BOD)و (DO) آب رودخانهٔ دره مراد بیک همدان. مجله دانش آب‌وخاک. جلد ۲۰، شماره ۳. صفحات ۲۱۰-۱۹۹.

قبائی سوق، م.، مساعدی، ا.، حسام، م. وهزار جریبی، ا.، ۱۳۸۹. ارزیابی تأثیر پیش‌پردازش پارامترهای ورودی به شبکه عصبی مصنوعی با استفاده از روش‌های رگرسیون گام‌به‌گام و گاما آزمودن به‌منظور تخمین سریع‌تر تبخیر و تعرق روزانه. نشریه آب‌وخاک، جلد ۲۴. شماره ۳. صفحات ۶۲۴-۶۱۰.

کردوانی، پ. و قلعه‌ای، م.ح.، ۱۳۹۲. تخمین مقادیر تبخیر و تعرق مرجع با استفاده از مدل فائو –پنمن ۵۶ در حوضه رودخانه آید و غموش. فصل‌نامه علمی و پژوهشی اکوبیولوژی تالاب، سال پنجم، شماره ۱۵. صفحات ۲۲-۱۵.

کوچک‌زاده، م. و بهمنی، ع.، ۱۳۸۴. ارزیابی عملکرد شبکه‌های عصبی مصنوعی در کاهش پارامترهای مورد نیاز، جهت برآورد تبخیر و تعرق مرجع. مجله علمی و پژوهشی علوم کشاورزی، سال یازدهم. شماره چهارم.

کیا، م.، ۱۳۸۹. محاسبات نرم در MATLAB. انتشارات کیان رایانه سبز. ۶۲۴ ص.

ملکی نژاد، ح.، پورمحمدی، س.، پور شرعیاتی، ر. و محمدی، س.، ۱۳۹۳. سنجش حساسیت تبخیر و تعرق مرجع نسبت به عوامل اقلیمی با استفاده از فن‌های هوش محاسباتی و روش‌های آماری چند متغیره. نشریه پژوهش آب در کشاورزی. جلد ۲۸، شماره ۱.

منهاج، م. ب.، ۱۳۸۱. مبانی شبکه‌های عصبی. مرکز نشر پروفسور حسابی.

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]

هژبر، ح.، معاضد، ه. و شکری کوچک، س.، ۱۳۹۳. برآورد تبخیر و تعرق مرجع با استفاده از مدل‌های تجربی، مدل‌سازی آن با شبکه عصبی مصنوعی و مقایسه آن‌ها با داده‌های لایسی‌متری در ایستگاه کهریز ارومیه. فصل‌نامه علمی و پژوهشی مهندسی آبیاری و آب. سال چهارم. شماره ۱۵.

Allen, R, G., Pereira, L. S., Raes, D. and Smith, M., 1998. Crop evapotranspiration, guideline for computing water requirements. Irrigation Drainage Paper. No. 56. FAO. Rome Italy.

Haykin, S., 1999. Neural networks: A comprehensive foundation. NJ. Prentice-Hall Inc. Englewood Cliffs. **Jain, S. K., Singh, V. P. and van Genuchten, M. T. H., 2004**. Analysis of soil water retention data using artificial neural networks. Journal of Hydraulic Engineering. ASCE. 9(5):415-420.

Kumar, M., Raghuwanshi, N. S., Singh, R., Wallender, W. W. and Pruitt, W. O., 2002. Estimatingevapotranspiration using artificial neural network. Journal Irrigation and Drainage Engineering. ASCE 128 (4): 224-233.

Kisi, O. and Ozturk, O., 2007. Adaptive neuro-fuzzy computing technique for evapotranspiration estimation. Journal Irrigation and Drainage Engineering. ASCE 133 (4): 368–379.

Li, H., Chen, G. L. P. and Huang, H. P., 2001. Fuzzy Neural Intelligent Systems. Mathematical Foundation and the Applications in Engineering, CRC Press, 371pp.

Najah, A., El-Shafie, A., Karim, O. A., Jaafar, O. and Amr, H., 2011. An application of different artificial intelligences techniques for water quality prediction. International Journal of the Physical Sciences. Vol. 6(22): 5298-5308.

Odhiambo, L. O., Yoder, R. E., Yoder, D. C. and Hines, J. W., 2001. Optimization of Fuzzy Evaporation Model Through Neural Training with Input-output Examples, Trans. ASAE. 44(6): 1625-1633.

Rahimi Khoob, A., 2008a. Artificial neural network estimation of reference evapotranspiration from pan evaporation in a semi-arid environment. Irrigation Sciences. 27:35–39.

Rahimi Khoob A., 2008b. Comparative study of Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. Irrigation Science. 26: 253-259.

Sudheer, K. P., Gosain, A. K. and Ramasastri, K. S., 2003. Estimating actual evapotranspiration from limited climatic data using neural computing technique. Journal Irrigation and Drainage Engineering, ASCE, 129: 214–218.

Zanetti, S. S., Sousa, E. F., Oliveira, V. P. S., Almeida, F. T. and Bernardo, S., 2007. Estimating evapotranspiration using artificial neural network and minimum climotological data. . Journal Irrigation and Drainage Engineering, ASCE 133 (2): 83-89.

[Downloaded from jweb.ahvaz.iau.ir on 2026-11-01]