

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

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 فائوپنمن-مانتیت محاسبه شد، سپس با استفاده از این مقادیر به عنوان خروجی‌های هدف، شبکه‌های مختلفی با ساختارهای متعارف تعریف و آموزش داده شد. در نهایت قابلیت شبکه برای تخمین تبخیر و تعرق با استفاده از قسمتی از داده‌ها که در طراحی و یا آموزش شبکه استفاده نشده است، موردبررسی قرار گرفت. با بررسی‌ها انجام‌گرفته مشخص شد که تنها با استفاده از پارامتر دمای متوسط روزانه به عنوان 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 شبکه‌های FF و MLP با R^2 بیش‌تر نسبت به MNN در تعیین تبخیر و تعرق گیاه مرجع از دقت بیش‌تری برخوردار می‌باشند.

واژگان کلیدی: تبخیر و تعرق، فائوپنمن-مانتیت، شبکه عصبی، ایستگاه سینوپتیک

اهواز.

مریم قربانی^{۱*}

ساناز شکری^۲

سعید برومند نسب^۳

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.

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 پیدا کرده است و اکثر محققین این رشته این مفاهیم را به عنوان 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 مورد مطالعه می‌باشد. به منظور مطالعه تبخیر و تعرق گیاه که از اجزای نیاز آبی گیاه می‌باشد، می‌توان از روش‌هایی



همچون پنمن فائو، فائوپنمن‌مانتیت، بلانی‌کریدل و غیره استفاده نمود (زند پارسا و سپاس‌خواه، ۱۳۷۵). از طرفی اکثر این روش‌ها به‌خصوص روش فائوپنمن‌مانتیت 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 در نهایت 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 این چنین پیچیدگی‌های تولید اطلاعات و کلاس‌بندی ورودی‌ها می‌باشند (پیرمردیان و ابول‌پور، ۱۳۸۹).

در طی سالیان اخیر تحقیقات متعددی در ارتباط با تخمین تبخیر و تعرق از روی داده‌های هواشناسی با استفاده از روش هوشمند در نقاط مختلف دنیا انجام گرفته 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), Sudheer, 2008) 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 فائوپنمن‌مانتیت از سیستم استنتاج عصبی فازی (ANFIS) استفاده نمودند. سلطانی و مرید (۱۳۸۴)، برای برآورد مقادیر تابش خورشیدی که یکی از مؤلفه‌های موردنیاز روش پنمن‌مانتیت می‌باشد، از شبکه‌های عصبی مصنوعی استفاده نمودند و نتایج را با مقادیر حاصل از روش هارگریوز سامانی مقایسه کردند و نتیجه گرفتند که شبکه‌های عصبی عملکرد بهتری نسبت به روش هارگریوز سامانی در برآورد تابش نشان می‌دهند. صیادی و همکاران (۱۳۸۸)، به مقایسه عملکرد شبکه‌های عصبی MLP و RBF 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 پنمن‌مانتیت 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 کهریر ارومیه مقایسه کردند و بهترین مدل را مدل تورک بیان کردند.

در تحقیق حاضر با استفاده از شبکه‌های عصبی از سه مدل MLP، MNN و FF مقادیر تبخیر و تعرق روزانه، محاسبه‌شده از روش فائوپنمن‌مانتیت 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 پنمن‌مانتیت 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 مورد استفاده قرار گرفته 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 واقع شده است. میانگین حداکثر و

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 مورد مطالعه.

به دلیل عدم دسترسی به داده‌های لایسی متری، از روش فائوپنمن مانتیث برای تخمین تبخیر و تعرق گیاه مرجع استفاده شده است. روش فائوپنمن مانتیث در میان روش‌های مختلف تخمین تبخیر و تعرق گیاه مرجع همواره بیشترین دقت را دارا بوده است از این رو مقادیر محاسبه شده از روش فائوپنمن مانتیث به عنوان مقادیر استاندارد برای آموزش و صحت سنجی ساختارهای متفاوت شبکه عصبی مورد استفاده قرار گرفته است. در سال ۱۹۹۸ میلادی، Alen و همکاران در نشریه شماره ۵۶ سازمان فائو رابطه ۱ را که به نام رابطه فائو پمن مانتیث معروف است، به عنوان دقیق‌ترین روش برای برآورد نیاز آبی گیاه ارائه نموده‌اند:

$$ET_o = \frac{0.408 \times \Delta \times (Rn - G) + \gamma \times \left(\frac{900}{Tm + 273} \right) \times U_2 \times (e_s - e_a)}{\Delta + \gamma(1 + 0.34U_2)} \quad \text{رابطه ۱}$$

که در آن:

ET_o : تبخیر تعرق پتانسیل گیاه مرجع حسب میلی متر در روز، Rn : تشعشع خالص دریافتی در سطح گیاه بر حسب 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 سانتی‌گراد و γ : ثابت سایکرومتری بر حسب 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 به صورت شبکه‌ای بهم پیوسته 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 تشکیل شده است که در هر لایه یک یا چند عنصر پردازشگر وجود دارد که با تمام نرون‌های لایه

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:

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

رابطه ۲:

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.

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

رابطه ۳:

P_n : ماتریس نرمال شده، P_s : 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 بعد از این 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 ارائه شده 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 یک لایه خروجی می‌باشند.

سیگنال ورودی در خلال شبکه و در مسیری روبه جلو به صورت لایه به لایه منتشر می شود. این نوع شبکه معمولاً بانوان پرسپترون چند لایه (MLP) نامیده می شود (Haykin, 1999). شکل ۲ تصویر شماتیک این نوع شبکه عصبی را نشان می دهد.



شکل ۲: تصویر شماتیک شبکه پرسپترون چند لایه.

طی چند دهه اخیر، تلاش های فراوانی برای مدل کردن یک نورون طبیعی که قادر به توصیف خصوصیات یک سیستم بیولوژیک باشد و شبکه های عصبی زیستی را همانندسازی کند، صورت گرفته است. شبکه های مدل شده بانام الگوهای ۴ شبکه عصبی شناخته شده و گسترش یافتند. مشخصات اساسی شبکه عصبی را می توان توسط ساختار آن ها و خصوصیات عملیاتی و دینامیکی آن شناسایی کرد. شبکه عصبی پرسپترون با یک لایه ورودی آغاز می شوند و شار اطلاعات را به سمت لایه خروجی هدایت می نمایند. میان این دو لایه نیز ممکن است چندین لایه مخفی وجود داشته باشد. لازم به ذکر است تعداد این لایه ها و همچنین تعداد گره ها در هر لایه مخفی معمولاً به روش آزمون و خطا تعیین می گردد. ساختار شبکه الگوریتم پس انتشار خطا، وزن های شبکه و مقادیر بایاس را در جهتی تغییر می دهد که تابع عملکرد با سرعت بیش تری کاهش یابد. الگوریتم پس انتشار خطا را می توان به شکل رابطه ۴ نشان داد (علیایی و همکاران، ۱۳۸۹):

$$X_{k+1} = X_k - \alpha_k g_k \quad \text{رابطه ۴}$$

که در آن: X_k بردار وزن ها و بایاس در تکرار k ام، α_k نرخ آموزش در تکرار k ام، g_k گرادیان در تکرار k ام می باشد. الگوریتم لونیبرگ- مارکوارت برای دستیابی به آموزش سریع تر شبکه بسط داده شده است رابطه ۵ معادله آن را نشان می دهد:

$$X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T e \quad \text{رابطه ۵}$$

که در آن: X_k بردار وزن ها و بایاس در تکرار k ام، J : ماتریس ژاکوبین شامل اولین مشتقات خطای شبکه با توجه به وزن ها و بایاس، e : بردار خطاهای شبکه، I : ماتریس واحد و μ : یک کمیت اسکالر است.

μ پس از هر گام موفق کاهش می یابد و در صورتی که یک گام منفرد، تابع عملکرد را افزایش دهد μ نیز افزایش می یابد (صیادی و همکاران، ۱۳۸۸). در این تحقیق از مقدار اولیه ۰/۰۱ برای μ استفاده و سه مدل شبکه عصبی MLP، FF و MNN برای محاسبه تبخیر و تعرق گیاه مرجع مدل سازی شده است.

برای جلوگیری از آموزش بیش از اندازه در شبکه ها از روش متوقف سازی زود هنگام آموزش استفاده شد و داده ها به صورت تصادفی به سه مجموعه ۷۵ درصد داده ها برای آموزش، ۱۵ درصد برای صحت سنجی و ۱۰ درصد برای آزمون استفاده شد.

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 در نتیجه 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) استفاده شده 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.

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

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

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

که در این معادلات، O_i و P_i : به ترتیب مقادیر مشاهداتی و شبیه‌سازی شده، $\bar{O}$ و $\bar{P}$: به ترتیب مقادیر میانگین داده‌های مشاهداتی و میانگین داده‌های شبیه‌سازی شده، 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 در شبکه‌های MLP, MN و FF با استفاده از آزمون و خطا تعیین گردید. جدول ۲ نتایج کالیبراسیون را نشان می‌دهد.

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

مدل	تکرار آموزش	الگوریتم آموزش	تابع انتقال	
			لایه خروجی	لایه میانی
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

در نهایت 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	۰/۰۰۰۹
۸	۷	۰/۹۹	۰/۹۸۳	۰/۰۰۶۳	۰/۰۰۱۶
۹	۱۲	۰/۹۸۹	۰/۹۹۱	۰/۰۰۷۴	۰/۰۰۲
۱۰	۸	۰/۹۸۶	۰/۹۸۸	۰/۰۰۸۸	۰/۰۰۱
۱۱	۱۰	۰/۹۷۱	۰/۹۶۷	۰/۰۰۲۱	۰/۰۰۵
۱۲	۱۱	۰/۹۶۲	۰/۹۲۹	۰/۰۰۲۷	۰/۰۰۷۴

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	۰/۰۰۰۸
۲	۴	۰/۹۹۴	۰/۹۹۵	۰/۰۰۴۴	۰/۰۰۱۱
۳	۲	۰/۹۹۳	۰/۹۹۵	۰/۰۰۵۱	۰/۰۰۴۱
۴	۳	۰/۹۹۳	۰/۹۹۴	۰/۰۰۰۵	۰/۰۰۱۳
۵	۵	۰/۹۹۲	۰/۹۹۳	۰/۰۰۰۵	۰/۰۰۱۵



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


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. با این وجود 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 به عنوان بهینه‌ترین سناریو انتخاب گردید، زیرا با وجود این که این سناریو از یک پارامتر به عنوان ورودی شبکه استفاده می‌نماید ولی دقت آن قابل مقایسه 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 انجام شده (سناریو ۱، ۴ و ۱۲) برای مقایسه تبخیر و تعرق گیاه مرجع از سه شبکه عصبی با روش فائونپنمن-مانتیت در اهواز را نشان می‌دهند.





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

مقدار NMSE در تخمین تبخیر و تعرق روزانه برای شبکه MLP به‌طور میانگین برابر 0.0332 ، برای شبکه FF برابر 0.0339 و برای شبکه MNN برابر 0.0616 به دست آمد. در مجموع 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 0.987 تا 0.989 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 مورد مطالعه 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 مدل‌سازی باشد.

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

روش فائوپنمن-مانتیت با عنوان هدف در آموزش شبکه عصبی قرار گرفت و شبکه‌های متفاوتی با ۱۲ سناریو ایجاد و عملکرد آن‌ها مورد بررسی قرار گرفت؛ و بهترین سناریو، سناریو دوازدهم با تنها یک پارامتر ورودی (دمای متوسط) و دقت بالا شناخته شد. باوجود این که 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 مورد نیاز، این شبکه‌ها می‌توانند راهکار مناسب‌تری نسبت به کاربرد روش‌های تجربی در شرایط عدم وجود اطلاعات کافی باشند.

به‌طور کلی نتایج به‌دست‌آمده از این تحقیق و تحقیقات متعددی از جمله 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.
- پیرمردیان، 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 درختی M5 (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 آب‌و خاک، 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 رودخانه دره مراد بیک همدان. مجله دانش آب‌و خاک، جلد ۲۰، شماره ۳. صفحات ۲۱۰-۱۹۹.
- قبائی سوق، م.، مساعدی، ا.، حسام، م. و هزار 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 آب‌و خاک، 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.، پورشرعیاتی، 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 پروفیسور حسابی.

- 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. Estimating evapotranspiration 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 climatological data. . Journal Irrigation and Drainage Engineering, ASCE 133 (2): 83-89.