

# ارزیابی کارایی شبکه‌های عصبی مصنوعی در آورد تبخیر و تعرق پتانسیل به عنوان عاملی موثر در تشدید فرسایش بادی (مطالعه موردی منطقه مروست استان یزد)

محمد تقی دستورانی<sup>۱</sup>، فرزانه یقینی<sup>۲</sup>، محمد اخوان قالیباف<sup>۳</sup>

۱- دانشیار دانشکده منابع طبیعی، دانشگاه یزد

۲- دانشجوی کارشناسی ارشد مدیریت مناطق بیابانی، دانشگاه یزد

۳- استادیار دانشکده منابع طبیعی، دانشگاه یزد

mdastorani@yazduni.ac.ir

## چکیده:

تبخیر و تعرق گیاه یکی از اجزای اصلی چرخه هیدرولوژیکی بوده و تخمین دقیق آن اهمیت بسیار زیادی در طراحی و مدیریت شبکه های آبیاری، برنامه‌ریزی‌های منابع آب و مدیریت مصرف آب در مزرعه دارد. در چند دهه اخیر سیستم های هوش مصنوعی کاربردهای بسیاری در مسائل مختلف مهندسی آب که رابطه و الگوی مشخصی بین عوامل موثر بر وقوع یک پدیده وجود ندارد، پیدا کرده است. به دلیل تاثیر متقابل پارامترهای هواشناسی در محاسبه تبخیر و تعرق، تخمین دقیق آن کاری پیچیده و دارای روابط غیر خطی می باشد. بدین منظور از شبکه عصبی مصنوعی (ANN) به منظور تخمین تبخیر و تعرق پتانسیل در منطقه مروست طی سالهای ۲۰۰۴ تا ۲۰۰۶ استفاده گردید. نتایج به دست آمده با توجه به نوع و تعداد عوامل ورودی متفاوت بوده ولی به طور کلی دارای دقت مناسبی می باشد و نشان می دهد که این تکنیک می تواند ابزار مناسبی در برآورد تبخیر و تعرق پتانسیل باشد. تبخیر و تعرق پتانسیل با کاهش رطوبت خاک و از بین بردن چسبندگی ذرات خاک نقش قابل توجهی را در تشدید فرایند فرسایش بادی خصوصا در مناطق خشک بازی میکند.

واژه‌های کلیدی: تبخیر و تعرق، شبکه‌های عصبی مصنوعی، مروست

## ۱. مقدمه

در سیستم آب، خاک، گیاه و اتمسفر، آب مستقیما از سطح خاک یا توسط گیاه به داخل اتمسفر وارد می شود. انتقال آب از سطح خاک به هوا را تبخیر (evaporation) و خارج شدن آن از گیاه را تعرق (transpiration) گویند. این دو پدیده هر دو ماهیت تبخیری داشته و چون تفکیک آنها از یکدیگر امکان پذیر نمی باشد، مجموعا به نام تبخیر و تعرق (evapotranspiration) در نظر گرفته شده و با علامت ET نشان داده می شود. روش هایی که برای تخمین تبخیر - تعرق به کار برده می شود، در دو گروه اصلی قرار می گیرند که عبارتند از:

- ✓ روش های مستقیم
- ✓ روش های غیر مستقیم یا محاسبه ای

در روش های مستقیم بخش کوچک و کنترل شده ای از مزرعه را مجزا کرده و مقدار تبخیر و تعرق در یک دوره زمانی معین اندازه گیری می شود. معمول ترین روش مستقیم برای تعیین تبخیر و تعرق استفاده از معادله بیلان آب در یک حجم کنترل شده از خاک است. ساده ترین وسیله برای تعیین

تبخیر و تعرق در مقیاس کوچک، لایسی متر (laysimeter) است. لایسی متر یک تانک با ابعاد مشخص است که در داخل خاک تعبیه شده و مقادیر آب ورودی و خروجی از آن اندازه‌گیری می‌گردد و با توجه به مشخص بودن مقادیر ورودی و خروجی مقدار تبخیر و تعرق محاسبه می‌شود.

در روش‌های غیرمستقیم یا محاسبه‌ای از عوامل مختلف اقلیمی و گیاهی که بر نیاز آبی مؤثرند استفاده شده و از روی ارتباط آنها با تبخیر و تعرق و معادله‌هایی که قبلاً با روش‌های مستقیم واسنجی شده‌اند، میزان تبخیر و تعرق پوشش گیاهی مورد نظر تخمین زده می‌شود. روش‌هایی که برای محاسبه  $ET_0$  پیشنهاد شده است هر کدام از نظر داده‌های مورد لزوم نیازهای متفاوتی دارند. تعدادی از روش‌ها اساس فیزیکی دارند ولی تعدادی از آنها فقط از روی تجربه به دست آمده‌اند. این روش‌ها را می‌توان به طور کلی به ۴ گروه تقسیم کرد که عبارتند از (۱):

- ۱) روش‌های موسوم به آیرودینامیک مانند معادله دالتون
- ۲) روش‌های موسوم به توازن انرژی مانند نسبت باون
- ۳) روش‌های ترکیبی
- ۴) روش‌های تجربی

امروزه شبکه‌های عصبی کاربردهای بسیاری در مسایل مختلف مهندسی آب که رابطه و الگوی مشخصی بین عوامل مؤثر بر وقوع یک پدیده وجود ندارد، پیدا کرده است. شبکه عصبی مصنوعی از الگوی شبکه عصبی انسان شبیه‌سازی شده است، به گونه‌ای که می‌تواند پس از آموزش، پارامتر خروجی مورد نظر را با اعمال پارامترهای ورودی و توابع مناسب برآورد نماید. به دلیل تاثیر متقابل پارامترهای هواشناسی در محاسبه تبخیر و تعرق، تخمین آن یک کار پیچیده و دارای روابط غیر خطی می‌باشد، بنابراین تهیه یک مدل ریاضی برای آن با در نظر گرفتن تمام فاکتورهای اقلیمی مؤثر در آن، کاری مشکل و در صورت امکان با خطاهای قابل توجهی رو به روست یا نیاز به اطلاعات زیادی دارد که اندازه‌گیری آنها مشکل و وقت گیر است. از این گذشته هر مدل ریاضی برای یک اقلیم خاص تهیه شده و فقط برای آن اقلیم معتبر است. بنابراین با توجه به ماهیت تبخیر و تعرق به نظر می‌رسد که شبکه‌های عصبی مصنوعی ابزار مناسبی برای تخمین آن باشند زیرا این شبکه‌ها نیاز به رابطه ریاضی برای پدیده پیچیده مورد بررسی ندارند. به طور کلی این شبکه‌ها ابزار مؤثری برای مدل کردن سیستم‌های غیر خطی هستند. تبخیر و تعرق نیز یک تابع غیرخطی است و به عواملی مانند: دمای هوا، بارندگی، تشعشعات خورشید، رطوبت نسبی هوا، سرعت وزش باد، فشار هوا و غیره بستگی دارد (۲). البته در این راستا پژوهش‌هایی نیز صورت گرفته که در ادامه به تعدادی از آن‌ها اشاره می‌شود.

شایان نژاد (۱۳۸۵) دقت روش‌های شبکه عصبی مصنوعی در محاسبه تبخیر و تعرق پتانسیل را با روش ترکیبی پنمن-مانتیس مقایسه کرده و به این نتیجه رسیده است که مقدار خطای بدست آمده از روش پنمن-مانتیس ۱/۲ میلی متر در روز و از روش شبکه‌های عصبی مصنوعی ۰/۷ میلی متر در روز می‌باشد. بنابراین روش شبکه‌های عصبی مصنوعی در تعیین تبخیر و تعرق پتانسیل بسیار دقیق تر از روش پنمن-مانتیس است. علاوه بر این اطلاعات مورد نیاز در روش شبکه‌های عصبی مصنوعی کمتر از روش پنمن-مانتیس می‌باشد (۲). کوچک زاده و بهمنی (۱۳۸۴) عملکرد شبکه‌های عصبی مصنوعی در کاهش پارامترهای مورد نیاز، جهت برآورد تبخیر و تعرق مرجع را ارزیابی کردند و به این نتیجه رسیدند که دو پارامتر دما و سرعت باد (در تهران) به عنوان مؤثرترین فاکتورها در دقت برآورد مدل‌های ANN هستند. به طور کلی هرچند با کاهش پارامترهای ورودی از دقت مدل‌های ANN کاسته می‌شود ولی نتایج بدست آمده حاکی از عملکرد مطلوب شبکه‌های عصبی در کنار روش‌هایی همچون فانو-پنمن-مانتیس، بلانی-کریدل، جنسن-هیز اصلاح شده و هارگریوز-سامانی است. از این رو مدل‌های ANN می‌توانند در شرایط فقدان اطلاعات کافی، راهکار مناسبتری نسبت به روش‌های تجربی به شمار روند (۳). پلنگی و همکاران (۱۳۸۵) تبخیر و تعرق پتانسیل گیاه مرجع را با استفاده از شبکه‌های عصبی در اهواز تخمین زدند. نتایج حاصل از این بررسی نشان داد که پس از آموزش و آزمون شبکه و با توجه به میزان خطای استاندارد وزن دار، می‌توان با استفاده از شبکه‌های عصبی، تبخیر و تعرق پتانسیل گیاه مرجع را با درصد بسیار کم خطا پیشبینی نمود. همچنین بهترین آرایش شبکه به صورت ۱-۶-۱ و با تابع محرک سیگموئید بدست آمد (۴). نساجی زواره (۱۳۸۸) با استفاده از داده‌های روزانه دما، رطوبت نسبی، سرعت باد، ساعت آفتابی و تبخیر، تبخیر روزانه را با شبکه عصبی تخمین زده است. مدل مورد استفاده یک شبکه چند لایه‌ای پیشخور با یک لایه پنهان و تابع سیگموئیدی با آرایش ۵-۴-۱ بوده که دارای  $MSE$  ۰/۰۰۷۱۶ و  $R^2$  ۰/۷۲۵۳۹۸ می‌باشد. نتایج بدست آمده نشان دهنده قابلیت مناسب و دقت قابل قبول شبکه‌های عصبی مصنوعی در پیشبینی تبخیر روزانه بوده است (۵). طبری و همکاران (۱۳۸۷) در تحقیق خویش از پارامترهای دمای هوا، رطوبت نسبی، سرعت باد در ارتفاع ۲ متری، فشار هوا و تابش خالص خورشیدی به عنوان ورودی شبکه عصبی مصنوعی و رگرسیون غیرخطی استفاده نمودند. براساس نتایج بهترین شبکه، شبکه‌ای با مدل پرسپترون چند لایه، تابع فعالیت تانزانت هایدربولیک، قانون یادگیری مومنتم و آرایش ۵-۴-۱ برای یک لایه پنهان می‌باشد. همچنین مقادیر تبخیر برآورد شده با شبکه عصبی مصنوعی نسبت به روش رگرسیونی، تطابق بهتری با داده‌های تشت تبخیر دارد (۶). فکورنیا و همکاران

(۱۳۸۷) قابلیت شبکه های عصبی مصنوعی را در برآورد تبخیر و تعرق پتانسیل بررسی نمودند. برای این تحقیق از آمار روزانه هواشناسی منطقه ارومیه (دمای بیشینه و کمینه، رطوبت نسبی بیشینه و کمینه، سرعت باد و ساعات آفتابی) در بازه زمانی ۱۳۸۵-۱۳۸۰ استفاده شده است. در این پژوهش از شبکه های عصبی مصنوعی با تعداد نرون های مختلف در یک یا دو لایه مخفی برای برآورد  $ET_0$  با استفاده از پارامترهای هواشناسی جهت آموزش و تست شبکه استفاده شده است. برای مقایسه از روش پنمن-مانتیث که روشی دقیق و معتبر است بهره گرفته شده است. در نهایت مناسبترین ساختارها برای برآورد تبخیر و تعرق شبکه ای با یک لایه پنهان، آرایش ۱-۸-۶ و ضریب همبستگی ۰/۹۵۵ برای آموزش و ۰/۹۴۷ برای تست و همچنین شبکه ای با دو لایه پنهان، آرایش ۱-۳-۶ و ضریب همبستگی ۰/۹۹۹ برای آموزش و ۰/۹۸۳ برای تست بوده است (۷). مقدم نیا وهمکاران (۲۰۰۹) دریافتند که برای تخمین تبخیر و تعرق سیستم های شبکه عصبی و استنتاج فازی بهتر از فرمول های تجربی هستند. ضمناً در این تحقیق ذکر شد که از بین سیستم شبکه عصبی و استنتاج فازی، شبکه عصبی اندکی بهتر است اگرچه تفاوت کمی دارند و البته فرآیند انتخاب داده های ورودی کمی پیچیده است. در این تحقیق از تست گاما برای تعیین بهترین داده های ورودی و تعداد داده های نقطه ای که باید برای کالیبراسیون مدل استفاده شوند استفاده شده است (۸). سادر و همکاران (۲۰۰۳) توانایی مدل های شبکه های عصبی در برآورد تبخیر و تعرق روزانه با استفاده از داده های هواشناسی محدود برای مزرعه برنج را مورد بررسی قرار دادند و اعلام کردند که برای تقویت نتایج بدست آمده از این تحقیق گیاهان بیشتری باید مورد بررسی قرار بگیرند. مقایسه نتایج بدست آمده با مقادیر اندازه گیری شده از لایسیمتر به وضوح مهارت این مدل ها را در برآورد تبخیر و تعرق نشان می دهد (۹).

هدف از تحقیق حاضر ارزیابی توانایی شبکه های عصبی در برآورد تبخیر و تعرق پتانسیل با استفاده از داده های اقلیمی موجود در منطقه خشک مروست واقع در استان یزد می باشد. لازم به ذکر است که وابستگی تبخیر به دیگر عوامل اقلیمی بسیار زیاد بوده و نتایج مدل ها در برآورد این پدیده از منطقه ای به منطقه دیگر بسیار متفاوت خواهد بود.

## ۲. مواد و روشها

### مشخصات ایستگاه و داده های هواشناسی مورد استفاده:

اطلاعات مورد نیاز برای این تحقیق از ایستگاه هواشناسی سینوپتیک شهرستان مروست واقع در استان یزد دارای طول جغرافیایی ۵۴ درجه و ۱۵ دقیقه و عرض ۳۰ درجه و ۳۰ دقیقه و ارتفاع ۱۵۴۷ متر از سطح دریا تهیه شده است. داده ها به صورت روزانه و در بازه زمانی ۲۰۰۶-۲۰۰۴ بوده و شامل دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت نسبی، سرعت باد، ساعات آفتابی، بارندگی، فشار هوا (QFE, QFF, vapour) و دمای خاک می باشد. البته بدلیل عدم وجود آمار مناسب ثبت شده، ماههای آبان، آذر، دی، بهمن، اسفند از مجموعه داده ها حذف گردیده اند. در ابتدا داده ها استاندارد شده و به دو قسمت جهت آموزش (۸۰٪) و تست (۲۰٪) تقسیم شده اند. سپس شبکه هایی با ساختارهای مختلف برای تخمین به کار گرفته شد. مدل شبکه عصبی مصنوعی مورد استفاده ساختار پرسپترون چند لایه (MLP) متشکل از سه لایه ورودی، پنهان و خروجی می باشد. با توجه به بررسی های صورت گرفته مشخص شد که تعداد یک یا دو لایه پنهان، تفاوت چندانی برای پیش بینی مقدار  $ET_0$  ندارد و هر دو آنها قابلیت تقریباً یکسانی برای پیش بینی رابطه غیرخطی بین پارامترهای هواشناسی و  $ET_0$  متناظر با آنها را دارا می باشند. بنابراین، استفاده از یک لایه پنهان علاوه بر دارا بودن دقت بالا، دارای طراحی راحت تری بوده و نیاز به صرف زمان کمتری دارد. لذا در این تحقیق از یک لایه پنهان استفاده شده است. در هر لایه یک یا چند نرون وجود دارد. در یک ساختار شبکه عصبی، مجموعه ای از نرونها دخالت دارند که هر نرون با همه نرونهای لایه بعدی مرتبط است. در بیشتر مواقع تعداد نرونهای لایه ورودی برابر تعداد متغیرهای مستقل سیستم مورد نظر می باشد اما در این تحقیق، پس از انجام آزمون های مختلف از ۱۰ نرون استفاده شده است. هر یک از نرونهای لایه ورودی در وزنی ضرب میشوند، مقدار این وزن همانند تقاطعات سیناپتیک در نرونهای زیستی، تعیین کننده تأثیر هر متغیر بر میزان عملکرد لایه ورودی است. هر نرون از دو بخش تشکیل شده است، در بخش نخست، مجموع وزنی مقادیر ورودی محاسبه می شود و در بخش دوم خروجی بخش نخست در یک تابع ریاضی قرار گرفته و خروجی نرون (تبخیر و تعرق پتانسیل) را محاسبه می نماید. بین هر دو لایه مقداری معادل واحد تحت عنوان بایاس در نظر گرفته می شود که آن نیز در وزن مربوط به خود در ارتباط با لایه بعد ضرب شده و با مجموع حاصل ضرب جمع می گردد. این تابع ریاضی، تابع محرک یا آستانه نامیده می شود و دارای انواع مختلفی نظیر توابع تانژانت هیپربولیک، سیگموئید، خطی، باینری و گوسی می باشد. همه این توابع پیوسته و مشتق پذیرند و خروجی آنها در یک محدوده عددی خاصی (عموماً بین صفر و یک یا بین یک و منهای یک) قرار می گیرند. مرسوم ترین و پر کاربردترین توابع در این زمینه، توابع سیگموئیدی هستند که در این تحقیق نیز از تابع تانژانت سیگموئید استفاده شده است. تابع مربوط به لایه خروجی نیز تابع محرک خطی (pure line) می باشد.

## آموزش شبکه عصبی مورد استفاده

بطور کلی آموزش شبکه های عصبی به دو طریق صورت می‌گیرد، آموزش تحت نظارت (سرپرستی) که در آن خروجی مشخصی به هر ورودی اختصاص داده می‌شود (همانند آرایش مورد استفاده در این پژوهش) و آموزش بدون نظارت (بدون سرپرستی) که خروجی از قبل تعیین شده ای ندارد. منظور از آموزش شبکه عصبی مصنوعی محاسبه وزن اتصالات مختلف است. برای آموزش شبکه های عصبی از الگوریتمهای یادگیری متفاوتی مانند الگوریتم پس انتشار خطا، الگوریتم پس انتشار گرادیان مزدوج و الگوریتم مارکوات لونبرگ استفاده می‌شود. انتخاب هر الگوریتم بر سرعت یادگیری و دقت شبکه موثر است. لیست کامل و توضیح مختصری از توابع آموزش مورد استفاده در جعبه ابزار شبکه عصبی متلب در جدول زیر آورده شده است. در تحقیق حاضر تمامی توابع آموزش درج شده در جدول (۱) مورد استفاده و ارزیابی قرار گرفت و توابع مناسبتر انتخاب شد.

جدول ۱. توابع آموزشی مورد استفاده در مدل شبکه عصبی این تحقیق

تایع آموزش	خصوصیات	توضیح
trainb	Batch training with weight and bias learning rules.	از آموزش دسته ای با استفاده از به هنگام کردن بایاس و وزن ها استفاده می کند (استفاده از قوانین یادگیری وزن و بایاس).
trainc	Cyclical order incremental training with learning functions	آموزش دسته ای، وزن ها و بایاس به صورت نموی بعد از معرفی هر ورودی به هنگام می شوند. داده های ورودی به صورت چرخشی مرتب می شوند.
trainr	Random order incremental training with learning functions.	آموزش دسته ای، وزن ها و بایاس به صورت نموی بعد از معرفی هر ورودی به هنگام می شوند. داده های ورودی به صورت تصادفی مرتب می شوند.
trains	Sequential order incremental training w/learning functions	آموزش دسته ای، وزن ها و بایاس به صورت متوالی و ترتیبی بعد از معرفی هر ورودی به هنگام می شوند ترتیب ورودی ها بعد از هر گام زمانی تصحیح و به هنگام می شود.
trainbfg	BFGS quasi-Newton backpropagation	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از روش پس انتشار <b>BFGS</b> کوسی - نیوتون (quasi-Newton) به هنگام می شوند.
trainbr	Bayesian regularization backpropagation	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از روش بهینه سازی <b>Levenberg-Marquardt</b> به هنگام می شوند. در این روش ترکیب وزن ها و مربع خطا مینیمم می شود و سپس ترکیب صحیح به عنوان نتیجه شبکه ای که به خوبی ساخته شده است، محاسبه می شود.
traincgb	Conjugate gradient backpropagation with Powell-Beale restarts	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از ترکیب روش پس انتشار شیب و شروع مجدد پاول - بیل (Powell-Beale) بهینه می شوند.
traincgf	Conjugate gradient backpropagation with Fletcher-Reeves updates	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از ترکیب روش پس انتشار شیب و روش بهینه سازی فلچر - ریوز (Fletcher-Reeves) بهینه می شوند.
traincgp	Conjugate gradient backpropagation with Polak-Ribiere updates	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از ترکیب روش پس انتشار شیب و روش بهینه سازی پولاک - ریبیر (Polak-Ribiere) بهینه می شوند.
traingd	Gradient descent backpropagation	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از روش کاهش شیب بهینه می شوند.
traingda	Gradient descent with adaptive learning rate backpropagation	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از روش کاهش شیب با روش یادگیری تطبیقی بهینه می شوند.
traingdm	Gradient descent with momentum backpropagation	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از روش کاهش شیب با قاعده مومنتوم (Momentum) بهینه می شوند.
traingdx	Gradient descent with momentum and adaptive learning rate backpropagation	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از روش کاهش شیب با قاعده مومنتوم (Momentum) و یادگیری تطبیقی بهینه می شوند.
trainlm	Levenberg-Marquardt backpropagation	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از قانون بهینه سازی لونبرگ - مارکوات (Levenberg-Marquardt) بهنگام می شوند.
trainoss	One step secant backpropagation	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از روش <b>One step secant</b> بهنگام می شوند.
trainrp	Resilient backpropagation	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از الگوریتم پس انتشار پس جهنده (Resilient) بهنگام می شوند.
trainscg	Scaled conjugate gradient backpropagation	آموزش دسته ای و گام به گام، وزن ها و بایاس با استفاده از الگوریتم شیب درجه بندی شده بهنگام می شوند.

### ۳. نتایج و بحث

همانطور که قبلاً ذکر شد در این تحقیق کلیه توابع درج شده در جدول (۱) مورد آزمون قرار گرفت و از میان آن‌ها ۵ تابع، نتایج بهتری را نشان دادند که نتایج مربوط به شبکه عصبی در استفاده از هر یک از این توابع در جدول (۲) ارائه شده است:

جدول ۲. نتایج شبکه عصبی مصنوعی در تخمین میزان تبخیر و تعرق پتانسیل بر اساس توابع آموزشی مختلف

ردیف	تابع	RMSE آموزش	$R^2$ آموزش	RMSE تست	$R^2$ تست	زمان آموزش
۱	traincgp	۱/۳۴	۰/۷۹۵۸	۱/۱۹	۰/۸۶	۱۰ ثانیه
۲	traincgf	۱/۳۶	۰/۷۸۹۵	۱/۲۱	۰/۸۵۳	۹ ثانیه
۳	trainoss	۱/۳۲	۰/۸۰۲	۱/۲۲	۰/۸۵	۶ ثانیه
۴	traincgb	۱/۳۱	۰/۸۰۴۶	۱/۲۶	۰/۸۳۷	۱۰ ثانیه
۵	trainbr	۱/۲۶	۰/۸۲۰۵	۱/۲۸	۰/۸۳۲	۶ ثانیه

همانگونه که در جدول (۲) مشاهده می‌شود با توجه به مقادیر  $R^2$  و RMSE مربوطه تابع traincgp نتیجه بهتری داشته و لذا برای ادامه کار انتخاب شد و بقیه تغییرات بر روی شبکه با ساختار ذکر شده صورت گرفت. بعد از انتخاب بهترین تابع عوامل ورودی با توجه به همبستگی آن‌ها با متغیر خروجی به ترتیب از مجموع ورودی‌ها حذف شدند که نتایج به دست آمده بر اساس متغیرهای ورودی مختلف در جدول (۳) مشاهده می‌شود.

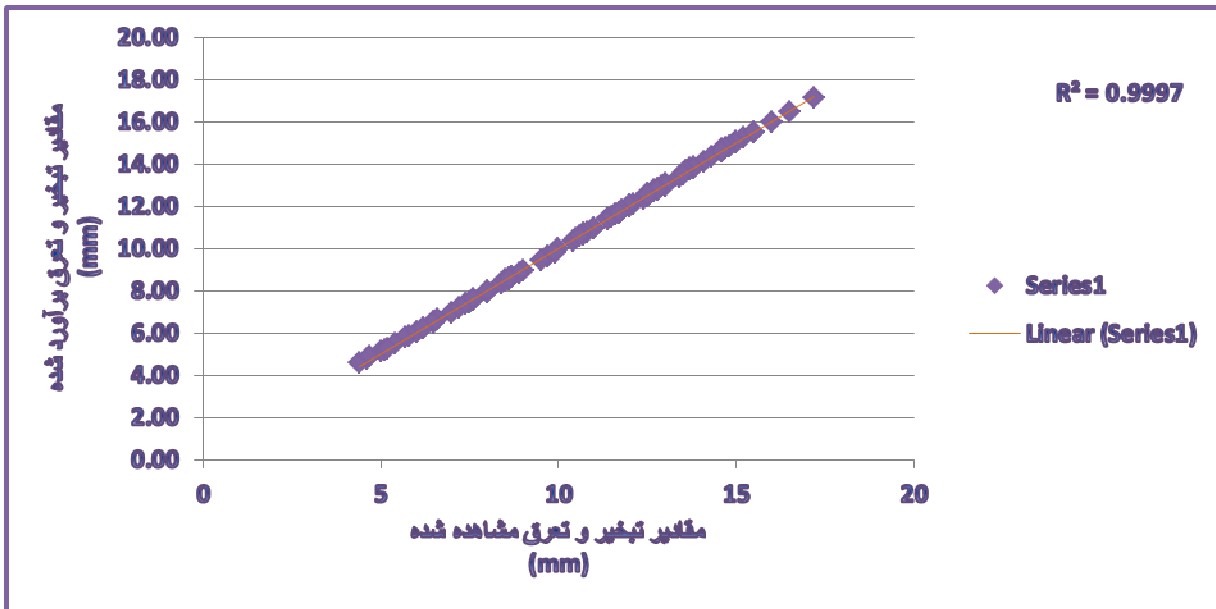
جدول ۳. دقت نتایج مربوط به تبخیر و تعرق برآورد شده توسط شبکه عصبی با استفاده از ورودی‌های مختلف

ردیف	پارامترهای ورودی	RMSE آموزش	$R^2$ آموزش	RMSE تست	$R^2$ تست	زمان آموزش
۱	P, S, W <sub>s</sub> , RH, Tmean, Tmin, Tmax, T <sub>s</sub> , QFE, QFF	۱/۳۳	۰/۷۹۸۹	۱/۱۶	۰/۸۶۸	۵ ثانیه
۲	QFF, S, W <sub>s</sub> , RH, Tmean, Tmin, Tmax, T <sub>s</sub> , V <sub>p</sub> , QFE	۰/۱۰۶	۰/۹۹۸۷	۰/۱۰	۰/۹۹۹	۵ ثانیه
۳	QFF, P, S, RH, Tmean, Tmin, Tmax, T <sub>s</sub> , V <sub>p</sub> , QFE	۰/۱۲۶	۰/۹۹۸۲	۰/۰۹	۰/۹۹۹	۳ ثانیه
۴	P, W <sub>s</sub> , RH, Tmean, Tmin, Tmax, T <sub>s</sub> , V <sub>p</sub> , QFE, QFF	۰/۰۷۹	۰/۹۹۹۳	۰/۰۸	۰/۹۹۹	۵ ثانیه
۵	QFF, P, S, W <sub>s</sub> , Tmean, Tmin, Tmax, T <sub>s</sub> , V <sub>p</sub> , QFE	۰/۰۵۵	۰/۹۹۹۷	۰/۰۵	۰/۹۹۹	۵ ثانیه
۶	P, S, W <sub>s</sub> , RH, Tmean, Tmin, Tmax, T <sub>s</sub> , V <sub>p</sub> , QFF	۰/۱۰۷	۰/۹۹۸۷	۰/۰۹	۰/۹۹۹	۴ ثانیه
۷	QFF, P, S, W <sub>s</sub> , RH, Tmean, Tmin, T <sub>s</sub> , V <sub>p</sub> , QFE	۰/۱۳۲	۰/۹۹۸۰	۰/۱۹	۰/۹۹۶	۴ ثانیه
۸	QFF, P, S, W <sub>s</sub> , RH, Tmean, Tmax, T <sub>s</sub> , V <sub>p</sub> , QFE	۰/۱۲۱	۰/۹۹۸۳	۰/۱۱	۰/۹۹۸	۴ ثانیه
۹	QFF, P, S, W <sub>s</sub> , RH, Tmin, Tmax, T <sub>s</sub> , V <sub>p</sub> , QFE	۰/۱۵۰	۰/۹۹۷۴	۰/۱۱	۰/۹۹۸	۴ ثانیه
۱۰	P, S, W <sub>s</sub> , RH, Tmean, Tmin, Tmax, V <sub>p</sub> , QFE, QFF	۰/۱۸۵	۰/۹۹۶۱	۰/۱۹	۰/۹۹۶	۵ ثانیه
۱۱	P, S, W <sub>s</sub> , RH, Tmean, Tmin, Tmax, T <sub>s</sub> , V <sub>p</sub> , QFE	۰/۱۳۲	۰/۹۹۸۰	۰/۱۲	۰/۹۹۸	۴ ثانیه

T<sub>s</sub>, V<sub>p</sub>, QFE, QFF, P, S, W<sub>s</sub>, RH, Tmean, Tmin, Tmax به ترتیب دمای حداکثر، دمای حداقل، دمای میانگین، رطوبت

نسبی، سرعت باد، ساعات آفتابی، بارندگی، فشار در سطح دریا، فشار هوا، فشار بخار و دمای هوا می‌باشد.

شکل ۱. نمودار همبستگی بین نتایج حاصل از شبکه عصبی و مقادیر اندازه‌گیری شده



در تست‌های بعدی دو، سه، چهار و پنج عامل که از اهمیت کمتری برخوردار بودند حذف گردیده و نتایج مربوط به شبیه‌سازی‌ها با تعداد و نوع ورودی‌های مختلف در جدول (۴) مشاهده می‌شود.

جدول ۴. دقت نتایج مربوط به شبکه عصبی در برآورد تبخیر و تعرق پتانسیل بر اساس تعداد و نوع ورودی‌های مختلف

ردیف	پارامترهای ورودی	RMSE آموزش	TR <sup>2</sup> آموزش	RMSE تست	R <sup>2</sup> تست	زمان آموزش
۱	، RH، Tmean، Tmin، Tmax T <sub>s</sub> ، QFE، QFF، S، W <sub>s</sub>	۱/۳۰۴	۰/۸۰۷۵	۱/۲۲	۰/۸۴۸	۱۱ ثانیه
۲	، RH، Tmean، Tmin، Tmax T <sub>s</sub> ، QFE، QFF، S	۱/۴۹۳	۰/۷۴۷۵	۱/۲۲	۰/۸۴۴	۲ ثانیه
۳	، RH، Tmean، Tmin، Tmax T <sub>s</sub> ، QFE، QFF	۱/۴۹۱	۰/۷۴۸۱	۱/۳۹	۰/۸۰۶	۶ ثانیه
۴	QFF، Tmean، Tmin، Tmax T <sub>s</sub> ، QFE،	۱/۶۳۸	۰/۶۹۶۰	۱/۴۶	۰/۷۹۵	۲ ثانیه

همانگونه که از جدول (۳) پیداست خطای برآوردها بسیار پایین بوده و به عبارت دیگر مدل شبکه عصبی استفاده شده بخوبی قادر است تبخیر و تعرق را برآورد نماید. این مسئله در شکل (۱) نیز بخوبی مشخص بوده و نشان می‌دهد که مقادیر برآورد شده توسط مدل کاملاً به مقادیر اندازه‌گیری شده نزدیک می‌باشد. از نظر تعداد و نوع پارامترهای ورودی به مدل نیز همانگونه که جداول ۳ و ۴ نشان می‌دهد دقت نتایج بر اساس تعداد و نوع پارامترهای ورودی تا حدی متفاوت است و با کم شدن تعداد آن‌ها دقت نتایج نیز کاهش می‌یابد (جدول ۴). البته حذف یکی از پارامترها (بجز فشار بخار هوا) تاثیر چندانی در دقت مدل نداشته ولی با حذف تعداد بیشتری از آن‌ها از مدل دقت نتایج با روند مشخص کاهش می‌یابد. از بین ساختارهای مختلف شبکه عصبی، مدل پس انتشار خطا با یک لایه میانی و تعداد ۱۰ نرون در آن بهترین نتایج را در این تحقیق ارائه داده است. از میان توابع مختلف آموزشی

آزمون شده تابع  $traincgp$  مناسب‌ترین تابع برای داده‌های استفاده شده در این تحقیق تشخیص داده شد. تبخیر و تعرق یکی از عوامل اصلی معادله بیلان آبی میباشند که باعث خروج آب از سیستم‌های هیدرولوژیکی و حوزه‌های آبخیز شده و تشدید خشکی و کم آبی را باعث میگردد. تبخیر و تعرق پتانسیل با کاهش رطوبت خاک و از بین بردن چسبندگی ذرات خاک نقش قابل توجهی را در تشدید فرایند فرسایش بادی خصوصا در مناطق خشک بازی میکند. تشدید تبخیر و تعرق علاوه بر این با کاهش رطوبت خاک باعث فقر پوشش گیاهی سطح زمین به عنوان ارزشمندترین و اصلی‌ترین پوشش محافظ سطح زمین نیز میگردد که شرایط را جهت تشدید فرایند برداشت ذرات خاک و تقویت فرآیند فرسایش بادی مهیا میسازد. لذا جهت بررسی وارزیابی میزان اراضی حساسیت به فرسایش بادی، برآورد تبخیر و تعرق پتانسیل و لحاظ آن به عنوان یک عامل تاثیر گذار در محاسبات مربوطه ضرورتیاجتناب ناپذیر است.

#### ۴. مراجع

- ۱- علیزاده. امین، غلامعلی کمالی، ۱۳۸۶ "نیاز آبی گیاهان در ایران" انتشارات دانشگاه امام رضا، چاپ اول
- ۲- شایان نژاد. محمد، ۱۳۸۵ "مقایسه دقت روش های شبکه های عصبی مصنوعی وپنمن-مانتیس در محاسبه تبخیر و تعرق پتانسیل" همایش ملی مدیریت شبکه های آبیاری وزهکشی ، دانشگاه شهید چمران اهواز
- ۳- کوچک زاده. مهدی، عارف بهمنی، ۱۳۸۴ "ارزیابی عملکرد شبکه های عصبی مصنوعی در کاهش پارامترهای مورد نیاز، جهت برآورد تبخیر و تعرق مرجع" مجله علمی-پژوهشی علوم کشاورزی، سال یازدهم (۴)
- ۴ - پلنگی. جمال عباس، هادی معاضد، رضا طارقیان، ۱۳۸۵ "تخمین تبخیر و تعرق پتانسیل گیاه مرجع ( $ET_0$ ) با استفاده از شبکه های عصبی در منطقه اهواز" اولین همایش ملی مدیریت شبکه های آبیاری و زهکشی
- ۵- نساجی زواره. مجتبی، ۱۳۸۸، "برآورد تبخیر روزانه با استفاده از مدل شبکه عصبی مصنوعی (مطالعه موردی ایستگاه هواشناسی زاهدان)" پنجمین همایش ملی علوم و مهندسی آبخیزداری ایران، دانشگاه علوم کشاورزی و منابع طبیعی گرگان
- ۶- طبری. حسین، علی آیینی، علی اکبر سبزی پرور، صفر معروفی، ۱۳۸۷ "مقایسه رگرسیون غیر خطی و شبکه عصبی مصنوعی در برآورد تبخیر روزانه از تشت تبخیر کلاس A در یک منطقه خشک" سومین کنفرانس مدیریت منابع آب ایران، تبریز
- ۷- فکورنیا. زهرا، عیسی جهانگیر، کامران زینال زاده، بهبود مشعوفی، ۱۳۸۷ "سنجش قابلیت شبکه های عصبی مصنوعی در برآورد تبخیر و تعرق پتانسیل (مطالعه موردی منطقه ارومیه)" سومین کنفرانس مدیریت منابع آب ایران، تبریز

8-Moghaddamnia.A, M. Ghafari Gousheh, J. Piri, S. Amin and D.Han (2009), "Evaporation estimation using artificial neural networks and adaptive neuro-fuzzyinference system techniques"/Advance in water resource/volum32 ,Issue1, pages 88-97

9-Sudheer.k.p, A.K.Gosian, K.S.Ramasastri/(2003)"Estimating actual evapotranspiration from limited climatic data using neural computing technique"/ Journal of Irrigation and Drainage Engineering