

## ارزیابی دقت روش‌های هوشمند و آنالیز حساسیت تبخیر- تعرق گیاه مرجع به پارامترهای هواشناسی در دو اقلیم مختلف

معصومه نجفی<sup>۱</sup>، وحید عظیمی<sup>۲</sup>، محمد شایان‌نژاد<sup>۳\*</sup>

۱. دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه صنعتی اصفهان، اصفهان

۲. دانشجوی سابق مهندسی آب، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز

۳. دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه صنعتی اصفهان، اصفهان

(تاریخ دریافت ۱۳۹۳/۰۱/۳۱ - تاریخ تصویب ۱۳۹۳/۰۶/۲۱)

### چکیده

در این پژوهش برای ارزیابی حساسیت تبخیر- تعرق گیاه مرجع در دو منطقه اصفهان و رشت با اقلیم‌های نیمه‌خشک و معتدل، به کمک دو روش هوشمند، از پارامترهای هواشناسی در طول آماری ۱۹۷۰-۲۰۱۰ استفاده شد. همچنین از شبکه‌های عصبی با ساختار پرسپترون چندلایه (MLP)<sup>۱</sup> و برنامه‌ریزی بیان ژن (GEP)<sup>۲</sup> برای آنالیز حساسیت تبخیر- تعرق گیاه مرجع به پارامترهای هواشناسی استفاده شد. در مورد همبستگی پارامترها، نتایج نشان داد در اصفهان و رشت، کمینه دما و بیشینه دما با ضریب همبستگی ۰/۹۶۸ و ۰/۹۲۶ در مقابل دیگر پارامترها، بیشترین همبستگی را دارند و در منطقه اصفهان سرعت باد با بیشینه دما با ضریب ۰/۰۶۷ و در رشت سرعت باد با کمینه رطوبت با ضریب ۰/۰۰۱ کمترین ارتباط را دارند. همچنین نتایج حاصل از این بررسی نشان داد در منطقه اصفهان با کاربرد مدل MLP و با ورودی‌های بیشینه و کمینه دما، رطوبت، سرعت باد و تعداد ساعات آفتابی، با جذر میانگین مربعات خطا (RMSE)<sup>۳</sup> برابر با ۰/۴۱۸ میلی‌متر در روز بهترین نتیجه را جهت تخمین تبخیر- تعرق مرجع ارائه داد. همچنین در منطقه رشت با کاربرد مدل MLP و با ورودی‌های کمینه و بیشینه دما، بیشینه رطوبت و تعداد ساعات آفتابی دارای ضریب همبستگی بیشتر و خطای کمتر است و مقادیر تبخیر- تعرق گیاه مرجع را نسبت به واقعیت بهتر پیش‌بینی می‌کند. در ارتباط با همبستگی پارامترها با نتایج تبخیر- تعرق گیاه مرجع، نتایج نشان داد، در هر دو منطقه اصفهان و رشت سرعت باد با تبخیر- تعرق با ضرایب ۰/۳ و ۰/۰۶۱ کمترین تأثیر را بر هم دارند.

**کلیدواژگان:** شبکه عصبی، برنامه‌ریزی بیان ژن، تبخیر- تعرق گیاه مرجع، پارامترهای هواشناسی.

## مقدمه

با توجه به کمبود منابع آبی در کشور و افزایش روزافزون جمعیت و به تبع آن افزایش نیاز جهانی به مواد غذایی، مطالعات در زمینه مصرف آب در بخش کشاورزی ضروری به نظر می‌رسد. روابط تجربی متعددی برای محاسبه نیاز آبی گیاه پیشنهاد شده است که می‌توان به روش‌هایی همچون بلانی-کریدل، هارگریوز، پنمن-فائو، پنمن-مانتیث و از این دست اشاره کرد [۱]. انتخاب بهترین مدل‌های برآورد تبخیر-تعرق با توجه به هر منطقه بسیار وقتگیر و هزینه‌بر است [۲]. اما روش ترکیبی تجربی پنمن-مانتیث در سال‌های اخیر مورد قبول اکثر محققان دنیا و کشورمان بوده است [۳، ۴]. در سال‌های اخیر استفاده از مباحث تئوری منطق فازی در شبیه‌سازی و بهینه‌سازی حوضه آبریز جایگاه خود را پیدا کرده و بیشتر محققان، این رشته و این مفاهیم را به عنوان ابزار بسیار قوی در این زمینه معرفی کرده‌اند [۵، ۶]. در راستای این هدف تحقیقات متنوعی صورت گرفته است که هر یک به نوعی به اهمیت مبحث تبخیر و تبخیر-تعرق می‌پردازد. محققان با کاربرد شبکه عصبی در پیش‌بینی مقدار تبخیر روزانه از تشتک در منطقه نیمه‌خشک دهلی‌نو هند با استفاده از داده‌های روزانه شش متغیر دمای حداقل و حداکثر، ساعات آفتابی، سرعت باد و رطوبت نسبی ساعات ۷:۲۱ و ۱۴:۲۱ در طی چهار سال (۲۰۰۴ تا ۲۰۰۷ میلادی)، نشان دادند مدل شبکه عصبی بهترین عملکرد را در تخمین مقدار تبخیر روزانه از تشتک دارد [۷]. همچنین زارع ابیانه و همکاران (۱۳۸۸) در ارزیابی نیاز آبی گیاه سیر و با مقایسه نتایج شبکه عصبی مصنوعی با مقادیر لایسیمتری نشان دادند دقت شبکه عصبی مصنوعی در حد قابل قبولی است و مدل مطلوب شبکه عصبی در حالت تغییرات افزایشی نسبت به دمای حداکثر هوا دارای بیشترین حساسیت است و نسبت به پارامتر حداقل رطوبت نسبی کمترین حساسیت را دارد [۸]. دهقانی و همکاران نشان دادند پارامتر دما و سرعت باد به ترتیب بیشترین و کمترین تأثیر را در تخمین مقدار تبخیر از تشتک دارند و شبکه عصبی دقت زیادی برای تخمین تبخیر روزانه نسبت به روش‌های تجربی موجود دارد [۹]. شایان‌نژاد با استفاده از اطلاعات اقلیمی و لایسیمتری در منطقه اکباتان و به کمک شبکه عصبی، نشان داد برای مبحث تبخیر-تعرق پتانسیل، مقدار خطای RMSE به دست آمده از معادله پنمن-مانتیث، ۱/۲

میلی‌متر در روز و از شبکه عصبی خطا ۰/۷ میلی‌متر در روز است، بنابراین روش شبکه عصبی بسیار دقیق‌تر از روش پنمن-مانتیث است [۱۰]. همچنین شایان‌نژاد و همکاران تبخیر-تعرق پتانسیل را از روش رگرسیون فازی، شبکه عصبی مصنوعی، و روش پنمن-مانتیث تعیین کردند و نشان دادند بهترین ترکیب ورودی برای شبیه‌سازی، استفاده از داده‌های تبخیر، دما، میانگین رطوبت نسبی، ساعات آفتابی و سرعت باد است. در تحقیقی دیگر که تأثیر متغیرهای مختلف آب‌وهوایی بر تبخیر-تعرق گیاه مرجع بررسی شد، نتایج نشان داد مدل‌هایی که براساس دمای هوا و تابش عمل می‌کنند، نتایج بهتری دارند [۱۱]. زانتی و همکاران از داده‌های ورودی کمتری برای برآورد تبخیر-تعرق گیاه مرجع از طریق شبکه عصبی استفاده کردند و تبخیر-تعرق را تابعی از دمای هوا (حداقل و حداکثر)، تابش خارج از جو و ساعات آفتابی تخمین زدند که رابطه خوبی با داده‌های لایسیمتری و معادله فائو-پنمن-مانتیث داشت [۱۲]. هدف از این تحقیق، بررسی حساسیت تبخیر-تعرق گیاه مرجع در دو اقلیم متفاوت اصفهان و رشت به پارامترهای هواشناسی با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) و برنامه‌ریزی بیان ژن (GEP) و مقایسه نتایج این مدل‌ها با یکدیگر است.

## مواد و روش‌ها

در این مطالعه از داده‌های هواشناسی کمینه و بیشینه دمای هوا، کمینه و بیشینه رطوبت، سرعت باد و تعداد ساعات آفتابی در مقیاس ماهانه در دو ایستگاه اصفهان و رشت با دوره آماری ۴۱ ساله (۱۹۷۰-۲۰۱۰)، استفاده شد. توانگر و همکاران با استفاده از روش تعیین اقلیم تورنت وایت و شاخص بارش مؤثر، اقلیم اصفهان را نیمه‌خشک، و شاطریان اقلیم رشت را معتدل معرفی کردند [۱۳، ۱۴]. مشخصات جغرافیایی و متوسط پارامترهای هواشناسی در طول این دوره آماری در جدول ۱ آورده شده است.

## محاسبه تبخیر-تعرق گیاه مرجع

پس از مرتب‌سازی داده‌ها، مقادیر تبخیر-تعرق گیاه مرجع در دو ایستگاه به روش پنمن-مانتیث فائو ۵۶ با نرم‌افزار اکسل محاسبه شد. این روش توسط کمیسیون بین‌المللی آبیاری و زهکشی<sup>۱</sup> و سازمان خواربار جهانی (FAO)<sup>۲</sup>،

1. International Commission on Irrigation and Drainage  
2. Food and Agriculture Organization

که در آن  $R_n$  تابش خالص در سطح پوشش گیاهی ( $MJ.m^{-2}.d^{-1}$ )؛  $T$  متوسط دمای هوا در ارتفاع ۲ متری از سطح زمین ( $^{\circ}C$ )؛  $U_2$  سرعت باد در ارتفاع ۲ متری از سطح زمین ( $m.s^{-1}$ )؛  $(e_a - e_d)$  کمبود فشار بخار در ارتفاع ۲ متری ( $KPa. ^{\circ}C^{-1}$ )؛  $\Delta$  شیب منحنی فشار بخار ( $KPa. ^{\circ}C^{-1}$ )؛  $\gamma$  ضریب رطوبتی ( $KPa. ^{\circ}C^{-1}$ )؛ و  $G$  شار گرمایی به داخل خاک ( $MJ.m^{-2}.d^{-1}$ ) است.

روشی استاندارد برای محاسبه تبخیر-تعرق پتانسیل معرفی شده است و فرض می‌شود که کل سطح پوشش گیاهی یک برگ بزرگ با روزنه‌های موجود در آن است، به همین دلیل این روش پنمن-مانتیت را روش برگ بزرگ می‌گویند [۱۵]. معادله آن به صورت زیر است:

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \left[ \frac{890}{T + 273} \right] U_2 (e_a - e_s)}{\Delta + \gamma(1 + 0.34U_2)} \quad (1)$$

جدول ۱. مشخصات جغرافیایی و هواشناسی ایستگاه‌های اصفهان و رشت در طول دوره آماری (۲۰۱۰-۱۹۷۰)

ایستگاه	طول جغرافیایی (درجه)	عرض جغرافیایی (درجه)	ارتفاع از سطح دریا (متر)		دمای کمینه	دمای بیشینه	رطوبت کمینه	رطوبت بیشینه	تعداد ساعات آفتابی	سرعت باد (متر در ثانیه)
			سطح	دریا						
اصفهان	۵۱/۶۶	۳۲/۶۱	۱۵۵۰/۴	۹/۵۰	۲۳/۴۶	۲۲/۲۱	۵۶/۱۰	۹/۰۹	۱/۷۴	
رشت	۴۹/۶۰	۳۷/۲۵	-۶/۹	۱۱/۶۴	۲۰/۵۶	۶۶/۴۱	۹۶/۰۶	۴/۵۲	۱/۲۱	

ورودی در خلال شبکه و در مسیری روبه‌جلو به‌صورت لایه‌به‌لایه منتشر می‌شود. این نوع شبکه‌های عصبی به‌طور معمول پرسپترون چندلایه (MLP) نامیده می‌شوند [۱۸]. این نوع شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و نورون‌ها، یک نگاشت غیرخطی را با دقت دلخواه انجام دهند. پارامترهای قابل تنظیم در این نوع شبکه‌ها، وزن اتصالات بین لایه‌ها، و فرایند آموزش به‌معنای یافتن مقادیر مناسب برای وزن‌های اتصالات بین نورون‌ها است. در این نوع شبکه، داده‌ها به‌صورت پیوسته و بدون هرگونه بازخوردی به‌سمت خروجی انتقال می‌یابد. از مهم‌ترین قسمت‌های تعیین ساختار بهینه این نوع شبکه، تعیین تعداد لایه‌های پنهان و تعداد نورون‌های هر لایه پنهان برای دستیابی به کمترین خطا است و مفهومی در تئوری‌های مربوط به شبکه عصبی مصنوعی وجود دارد که اثبات می‌کند یک لایه پنهان با تعداد نورون کافی، قادر به تخمین هر رابطه غیرخطی است [۱۹].

#### مدل برنامه‌ریزی بیان ژن (GEP)

برنامه‌ریزی ژنتیک مدلی شبیه الگوریتم ژنتیک است [۲۰]. با این تفاوت که در سیستم جست‌وجوی جواب خود از مدل درختی استفاده می‌کند. اولین بار کزا<sup>۴</sup> براساس تئوری داروین، برنامه‌ریزی ژنتیک را ارائه کرد [۲۱]. این روش تکنیکی برای برنامه‌ریزی خودکار به‌منظور حل مسئله

#### شبکه عصبی مصنوعی (ANN)<sup>۲</sup>

شبکه‌های عصبی مصنوعی، مدل‌های محاسباتی هستند که قادرند ارتباط میان ورودی‌ها و خروجی‌های یک سیستم فیزیکی را توسط شبکه‌ای از گره‌ها که همگی به هم متصل‌اند، تعیین کنند [۱۶]. با این رویکرد، شبکه‌های عصبی مصنوعی همانند ساختار زیست‌شناسی مغز انسان با ترکیب ویژگی‌هایی همچون قدرت یادگیری، تعمیم‌دهی، پردازش موازی و تصمیم‌گیری، قابلیت حل کامل مسائلی پیچیده با ماهیتی خطی یا غیرخطی را خواهند داشت [۱۷]. در استفاده از این شبکه‌ها برای اصلاح وزن‌ها و رساندن مجموع مربع خطا (SSE)<sup>۳</sup> به حداقل مقدار خود، داده‌های مجموعه آموزش متشکل از زوج ورودی-خروجی که شامل اطلاعات آماری از وقایع مورد نظر است آزمایش می‌شود. همچنین برای بررسی دقت شبکه آموزش‌یافته، آزمون شبکه هم صورت می‌گیرد که این کار با دادن زوج داده‌های مجموعه آزمون به شبکه و محاسبه مقدار خطای شبکه انجام می‌پذیرد.

#### مدل پرسپترون چندلایه (MLP)

شبکه‌های چندلایه پیشخور یکی از مهم‌ترین و رایج‌ترین ساختارهای شبکه عصبی مصنوعی است که سیگنال‌های

1. Big Leaf  
2. Artificial Neural Networks  
3. Sum of Square Error

که در معادلات بالا،  $P_i$  مقدار برآوردشده خروجی مدل؛  $O_i$  مقدار اندازه‌گیری‌شده پارامتر خروجی؛  $\bar{O}_i$  میانگین مقادیر اندازه‌گیری‌شده پارامتر خروجی؛ و  $n$  تعداد مشاهدات است.

### نتایج و بحث

در این تحقیق ابتدا ضرایب همبستگی بین هر یک از پارامترهای هواشناسی و با تبخیر- تعرق گیاه مرجع محاسبه شد که نتایج به تفکیک ایستگاه‌ها در جدول ۲ آورده شده است.

در مورد ارتباط پارامترها با یکدیگر، نتایج نشان داد در دو ایستگاه اصفهان و رشت، دمای کمینه و بیشینه در مقایسه با دیگر پارامترها بیشترین همبستگی را با هم دارند، ولی پارامترهای سرعت باد با دمای بیشینه با ضریب همبستگی ۰/۰۶۷ در اصفهان و پارامتر سرعت باد با کمینه رطوبت با ضریب همبستگی ۰/۰۰۱ در رشت، کمترین تأثیر متقابل را بر هم خواهند داشت. همچنین در زمينه تأثیر پارامترها بر مقدار تبخیر- تعرق گیاه مرجع، نتایج نشان داد در ایستگاه‌های اصفهان و رشت، پارامتر سرعت باد با ضریب همبستگی ۰/۰۳ و ۰/۰۶۱ کمترین تأثیر را بر مقدار تبخیر- تعرق گیاه مرجع داشت.

سپس با توجه به بررسی کارایی مدل‌های شبکه عصبی در برآورد تبخیر- تعرق و آنالیز حساسیت آن نسبت به پارامترهای هواشناسی، شش سناریو با ورودی‌های مختلف تعریف شد (جدول ۳). پس از آموزش شبکه، ارزیابی نتایج با آزمون‌های آماری برای مدل‌ها و به تفکیک ایستگاه‌ها در جدول‌های ۴ تا ۷ آورده شده است.

با توجه به جدول‌های بالا می‌توان نتیجه گرفت برای ایستگاه رشت، مدل GEP در مقایسه با مدل MLP دارای ضریب همبستگی کمتر و خطای بیشتر است و نتایج حاصل از سناریوی ۴ با ورودی‌های بیشینه و کمینه دما و بیشینه رطوبت و تعداد ساعات آفتابی، مقادیر تبخیر- تعرق گیاه مرجع نسبت به واقعیت پیش‌بینی بهتری خواهد داشت. برای ایستگاه اصفهان نیز مدل MLP نسبت به مدل GEP، خطای کمتر و همبستگی بیشتری دارد و در مورد سناریوها نیز نتایج نشان داد که با دخیل کردن تمام پارامترهای هواشناسی شامل کمینه و بیشینه دما و رطوبت، سرعت باد و تعداد ساعات آفتابی، مقادیر تبخیر- تعرق گیاه مرجع بهتر پیش‌بینی می‌شود.

به صورت برنامه کامپیوتری ارائه می‌کند و قابلیت بهینه‌سازی ساختار مدل و مؤلفه‌های آن را دارد. در برنامه‌ریزی ژنتیک از ساختار درختی استفاده می‌شود، ولی الگوریتم ژنتیک بر پایه سیستم دودویی است که تفاوت اساسی ساختاری این دو سیستم محسوب می‌شود. برنامه‌ریزی ژنتیک در مسائلی که روش‌های معمول ریاضی محاسباتی قادر به حل آنها نباشند یا از روابط مابین متغیرهای مسئله، شناخت دقیقی در دسترس نباشد، کاربرد دارد [۲۲، ۲۳].

برنامه‌ریزی بیان ژن را فریبا ابداع کرد. برنامه‌ریزی بیان ژن از نخبه‌گزینی ساده استفاده می‌کند و بهترین افراد یک نسل را برای نسل بعد نگه می‌دارد. برنامه‌ریزی بیان ژن برخلاف الگوریتم ژنتیک و برنامه‌ریزی ژنتیک، چندین عملگر ژنتیکی برای تکثیر افراد با اصلاحات دارد. بیان درختی، تحت فرایندی به نام ترجمه از کروموزوم‌ها استنتاج می‌شود و نمایش درختی آن در محیط، برآزش آن و کروموزوم‌های متناظرش را تعیین می‌کند، درحالی‌که این کروموزوم تحت انتخاب و فعالیت عملگرهای ژنتیکی قرار می‌گیرد [۲۴].

سپس به پیش‌بینی مقادیر تبخیر- تعرق گیاه مرجع با ورودی‌های مختلف از پارامترهای هواشناسی با استفاده از مدل‌های شبکه عصبی پرداخته شد. برای استفاده از شبکه عصبی، داده‌ها به دو دسته آموزش<sup>۱</sup> با ۷۵ درصد داده‌ها (از ابتدای ژانویه سال ۱۹۷۰ تا ژوئن ۲۰۰۱) و آزمون<sup>۲</sup> با ۲۵ درصد داده‌ها (از ابتدای جولای ۲۰۰۱ تا دسامبر ۲۰۱۰)، تقسیم شد. پس از پردازش، به منظور ارزیابی مدل‌های مورد نظر از شاخص‌های آماری  $RMSE$ ،  $MBE$ ،  $MAE$  و  $R^2$  استفاده شد که به کمک روابط زیر محاسبه می‌شود:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (2)$$

$$MBE = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (P_i - \bar{O}_i)^2} \quad (5)$$

1. Training
2. Test
3. Mean Bias Error
4. Mean Absolute Error

جدول ۲. مقادیر ضریب همبستگی بین پارامترهای هواشناسی و مقادیر تبخیر تعرق گیاه مرجع در اصفهان و رشت

نام ایستگاه	متغیرها	بیشینه دما	کمینه دما	بیشینه رطوبت	کمینه رطوبت	سرعت باد	ساعات آفتابی	تبخیر- تعرق
اصفهان	بیشینه دما	۱						
	کمینه دما	۰/۹۶۸	۱					
	بیشینه رطوبت	۰/۸۶۴	۰/۷۹۵	۱				
	کمینه رطوبت	۰/۷۱۸	۰/۶۲۱	۰/۸۳۴	۱			
	سرعت باد	۰/۰۶۷	۰/۰۹۵	۰/۰۹۱	۰/۱۱۲	۱		
	ساعات آفتابی	۰/۷۷۷	۰/۷۱۱	۰/۷۶۸	۰/۶۷	۰/۰۸۲	۱	
رشت	تبخیر- تعرق	۰/۸۳۴	۰/۸۶۵	۰/۷۵	۰/۶۱۲	۰/۰۳	۰/۷۱۲	۱
	بیشینه دما	۱						
	کمینه دما	۰/۹۲۶	۱					
	بیشینه رطوبت	۰/۱۲۱	۰/۰۶۲	۱				
	کمینه رطوبت	۰/۳۵۵	۰/۲۱۳	۰/۳۸۴	۱			
	سرعت باد	۰/۱۱۸	۰/۱۳۸	۰/۰۵	۰/۰۰۱	۱		
رشت	ساعات آفتابی	۰/۶۰۹	۰/۴۹۸	۰/۱۵۷	۰/۵۷۳	۰/۰۷۲	۱	
	تبخیر- تعرق	۰/۸۲۵	۰/۷۷۴	۰/۲۰۷	۰/۴۶۱	۰/۰۶۱	۰/۷۴۵	۱

جدول ۳. بردارهای ورودی مورد نیاز در مدل‌های شبکه عصبی

سناریو	ورودی
۱	دمای بیشینه و کمینه
۲	دمای بیشینه و کمینه و ساعات آفتابی
۳	دمای بیشینه و کمینه ، رطوبت کمینه ، ساعات آفتابی
۴	دمای بیشینه و کمینه ، رطوبت بیشینه و ساعات آفتابی
۵	دمای بیشینه و کمینه ، رطوبت بیشینه و کمینه و ساعات آفتابی
۶	دمای بیشینه و کمینه ، رطوبت بیشینه و کمینه ، سرعت باد و ساعات آفتابی

جدول ۴. شاخص‌های آماری مربوط به صحت سنجی بخش آموزش و آزمون مدل MLP در ایستگاه اصفهان

مدل	سناریو	آموزش				آزمون			
		R <sup>2</sup>	MAE	MBE	RMS E	R <sup>2</sup>	MAE	MBE	R <sup>2</sup>
MLP	۱	۰/۹۰۶	۰/۶۹۶	۰/۰۰۱	۰/۸۸۷	۰/۸۸۷	۰/۰۰۱	۰/۸۸۷	۰/۸۴۴
	۲	۰/۸۲۷	۰/۶۲۰	-۰/۰۰۰۲	۰/۹۰۶	۰/۹۰۶	-۰/۰۰۰۲	۰/۸۴۷	۰/۸۴۷
	۳	۰/۸۲۷	۰/۶۰۸	-۰/۰۰۰۳	۰/۹۰۶	۰/۹۰۶	-۰/۰۰۰۳	۰/۸۹۳	۰/۸۹۳
	۴	۰/۸۲۷	۰/۶۱۵	-۰/۰۰۰۴	۰/۹۰۶	۰/۹۰۶	-۰/۰۰۰۴	۰/۸۹۰	۰/۸۹۰
	۵	۰/۸۲۶	۰/۶۲۰	۰/۰۰۰۷	۰/۹۰۶	۰/۹۰۶	۰/۰۰۰۷	۰/۸۸۲	۰/۸۸۲
	۶	۰/۶۲۵	۰/۴۳۷	-۰/۰۰۸۳	۰/۹۴۷	۰/۹۴۷	-۰/۰۰۸۳	۰/۹۲۵	۰/۹۲۵

جدول ۵. شاخص‌های آماری مربوط به صحت سنجی بخش آموزش و آزمون مدل MLP در ایستگاه رشت

مدل	سناریو	آموزش				آزمون			
		R <sup>2</sup>	MAE	MBE	RMSE	R <sup>2</sup>	MAE	MBE	RMSE
MLP	۱	۰/۵۸۴	۰/۵۰۴	-۰/۰۰۱	۰/۸۷۲	۰/۸۷۲	-۰/۰۰۱	۰/۴۰۷	۰/۸۲۴
	۲	۰/۴۶۲	۰/۳۸۲	-۰/۰۰۱	۰/۹۲۰	۰/۹۲۰	-۰/۰۰۱	۰/۳۱۰	۰/۸۹۹
	۳	۰/۴۱۰	۰/۳۲۹	-۰/۰۰۱	۰/۹۳۷	۰/۹۳۷	-۰/۰۰۱	۰/۳۱۵	۰/۸۹۹

## ادامه جدول ۵.

۰/۹۰۴	۰/۰۱۵	۰/۱۴۵	۰/۳۰۲	۰/۹۳	۰/۰۰۷	۰/۳۵۸	۰/۴۳۱	۴
۰/۹۰۰	۰/۰۱۰	۰/۱۴۱	۰/۳۰۵	۰/۹۳۱	-۰/۰۱۰	۰/۳۳۹	۰/۴۲۹	۵
۰/۹۰۰	۰/۰۰۶	۰/۱۴۷	۰/۳۰۵	۰/۹۳۴	۰/۰۰۵	۰/۳۴۹	۰/۴۲۱	۶

## جدول ۶. شاخص‌های آماری مربوط به صحت سنجی بخش آموزش و آزمون مدل GEP در ایستگاه اصفهان

مدل	سناریو	آموزش				آزمون			
		R <sup>2</sup>	MAE	MBE	RMSE	R <sup>2</sup>	MAE	MBE	RMSE
GEP	۱	۰/۹۴۳	۰/۷۴۱	-۰/۰۰۲	۰/۸۷۹	۰/۶۲۲	۰/۲۹۷	۰/۰۱۱	۰/۸۳۱
	۲	۰/۸۹۵	۰/۷۱۰	-۰/۰۱۹	۰/۸۹۰	۰/۵۶۳	۰/۲۷۱	۰/۰۲۵	۰/۸۶۲
	۳	۰/۹۰۴	۰/۷۱۲	۰/۰۲۵	۰/۸۸۸	۰/۵۸۳	۰/۲۷۸	۰/۰۳۹	۰/۸۵۳
	۴	۰/۸۸۴	۰/۶۸۰	-۰/۰۲۷	۰/۸۹۳	۰/۵۵۷	۰/۲۶۵	-۰/۰۱۸	۰/۸۶۴
	۵	۰/۸۹۶	۰/۷۰۰	-۰/۰۱۰	۰/۸۹۰	۰/۵۶۹	۰/۲۶۸	۰/۰۳۹	۰/۸۶۰
	۶	۰/۵۴۱	۰/۳۷۲	-۰/۰۱۳	۰/۹۶۰	۰/۳۳۲	۰/۱۴۴	۰/۰۱۳	۰/۹۵۲

## جدول ۷. شاخص‌های آماری مربوط به صحت سنجی بخش آموزش و آزمون مدل GEP در ایستگاه رشت

مدل	سناریو	آموزش				آزمون			
		R <sup>2</sup>	MAE	MBE	RMSE	R <sup>2</sup>	MAE	MBE	RMSE
GEP	۱	۰/۶۱۳	۰/۵۲۶	-۰/۰۱۵	۰/۸۶۱	۰/۴۱۶	۰/۲۰۴	-۰/۰۲۰	۰/۸۱۷
	۲	۰/۵۱۰	۰/۴۱۵	-۰/۰۱۲	۰/۹۰۳	۰/۳۵۲	۰/۱۶۱	۰/۰۷۰	۰/۸۹۲
	۳	۰/۴۳۷	۰/۳۶۶	-۰/۰۱۷	۰/۹۲۹	۰/۳۵۰	۰/۱۶۵	۰/۰۷۰	۰/۸۹۰
	۴	۰/۵۴۹	۰/۴۴۲	-۰/۰۲۹	۰/۸۸۷	۰/۳۴۴	۰/۱۶۱	۰/۰۴۲	۰/۸۸۱
	۵	۰/۴۷۱	۰/۳۹۱	۰/۰۲۰	۰/۹۱۷	۰/۳۲۴	۰/۱۵۴	۰/۰۳۲	۰/۸۹۴
	۶	۰/۴۳۳	۰/۳۷۳	۰/۰۱۳	۰/۹۳۰	۰/۳۲۹	۰/۱۶۴	۰/۰۳۳	۰/۸۹۱

## نتیجه‌گیری

تبخیر- تعرق پتانسیل یکی از مهم‌ترین مؤلفه‌ها در راستای بهینه‌سازی مصرف آب در بخش کشاورزی است. برآورد و پیش‌بینی دقیق تبخیر- تعرق و بررسی شدت حساسیت آن به پارامترهای هواشناسی، در تعیین مقدار آبیاری و برنامه‌زمان‌بندی مؤثر است. در زمینه همبستگی پارامترها با نتایج تبخیر- تعرق گیاه مرجع، نتایج این تحقیق نشان داد، در منطقه اصفهان و رشت سرعت باد با تبخیر- تعرق گیاه مرجع با ضرایب همبستگی ۰/۳ و ۰/۰۶۱ کمترین تأثیر را بر هم دارند. همچنین در زمینه همبستگی پارامترها با همدیگر، نتایج نشان داد در اصفهان و رشت، کمینه دما و بیشینه دما با ضرایب همبستگی ۰/۹۶۸ و ۰/۹۲۶ در مقابل با دیگر پارامترها، بیشترین همبستگی را دارند و در منطقه اصفهان سرعت باد با بیشینه دما، و در رشت سرعت باد با کمینه رطوبت به ترتیب با ضرایب ۰/۰۶۷ و ۰/۰۰۱ کمترین ارتباط را دارند. در زمینه کاربرد مدل‌ها در پیش‌بینی

تبخیر- تعرق گیاه مرجع نیز نتایج نشان داد در منطقه اصفهان با کاربرد مدل MLP و با ورودی‌های بیشینه و کمینه دما، رطوبت، سرعت باد و تعداد ساعات آفتابی نتیجه بهتری را برای تخمین تبخیر- تعرق گیاه مرجع ارائه می‌دهد که در این مدل مقدار RMSE برابر با ۰/۴۱۸ است. در منطقه رشت نیز نتایج مدل GEP در مقایسه با مدل MLP دارای ضریب همبستگی کمتر و خطای بیشتر بود و نتایج حاصل از سناریوی ۴ یعنی با ورودی‌های بیشینه و کمینه دما و رطوبت بیشینه و تعداد ساعات آفتابی و با مقدار RMSE برابر با ۰/۳۰۲، تبخیر- تعرق گیاه مرجع را نسبت به واقعیت بهتر پیش‌بینی کرد.

## منابع

۱. دفتر مطالعات منابع آب، ۱۳۸۱. گزارش آمار ایستگاه‌های هواشناسی حوزه آبریز کر و سیوند. آرشیو سازمان آب منطقه‌ای فارس، ۲۵۰ صفحه.
۲. زندپارسا، ش. و سپاسخواه، ع. ر، ۱۳۷۵. تعیین تبخیرتعرق پتانسیل گیاه مرجع براساس برخی عوامل قابل اندازه‌گیری در ایستگاه‌های هواشناسی در ایران. ششمین سمینار سراسری آبیاری و کاهش تبخیر، ۱۰ و ۱۱ شهریور، کرمان، ایران: ۱۸-۲۹.
۳. سپاسخواه، ع. ر، ۱۳۷۲. رابطه بین تولید محصول و تبخیرتعرق و برنامه‌ریزی آبیاری گندم، چغندرقد، لوبیا و ذرت. معاونت پژوهشی دانشگاه شیراز، گزارش طرح پژوهشی شماره ۴۹. ۲۶۸ صفحه.
۴. پیرمردیان، ن، ۱۳۷۶. تعیین نیاز آبی برنج در منطقه کوشک استان فارس. رساله کارشناسی ارشد، بخش آبیاری، دانشگاه شیراز، ۱۱۱ صفحه.
5. Li, H.; Chen, G.L.P. and Huang, H.P., (2001). Fuzzy Neural Intelligent Systems. Mathematical Foundation and the Applications in Engineering, CRC Press, 371 pp.
6. Odhiambo, L.O.; Yoder, R.E.; Yoder, D.C. and Hines, J.W., (2001). Optimization of Fuzzy Evapotranspiration Model through Neural Training with Input-Output Examples. Trans. ASAE, Vol. 44, No. 6, P. 1625-1633.
7. Stergiou, C., and Siganos, D., (2008), Neural networks, [http://www.doc.ic.ac.uk/nd/surprise\\_96/journal/vol4/cs11/report.html](http://www.doc.ic.ac.uk/nd/surprise_96/journal/vol4/cs11/report.html).
۸. زارع‌ایبانه، ح، قاسمی، ع، بیات‌ورکشی، م، معروفی، ص. ۱۳۸۸. ارزیابی دقت شبکه عصبی مصنوعی در پیش‌بینی تبخیر- تعرق گیاه سیر براساس داده‌های لایسیمتری در منطقه همدان. نشریه آب و خاک. جلد ۲۳، شماره ۳. پاییز ۱۳۸۸: ۱۷۶-۱۸۵.
۹. دهقانی، امیر احمد، پیری، مهدی، حسام، موسی، دهقانی، نوید. ۱۳۸۹. تخمین تبخیر روزانه از تشت تبخیر با استفاده از سه شبکه عصبی پرسپترون چندلایه، تابع پایه شعاعی و المانی، مجله پژوهش‌های حفاظت آب و خاک، جلد ۱۷، شماره ۲.
۱۰. شایان‌نژاد. مهدی، ۱۳۸۵. مقایسه دقت روش‌های شبکه‌های عصبی مصنوعی و پنمن- ماننسیس در
- محاسبه تبخیر- تعرق پتانسیل. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی، دانشگاه شهید چمران اهواز، دانشکده مهندسی آب، ۱۲ الی ۱۴ اردیبهشت.
۱۱. سیدعزیزی، ۱۳۸۱. تخمین تبخیرتعرق بالقوه گیاه مرجع و رسم خطوط هم‌تبخیرتعرق برای ایران. رساله کارشناسی ارشد، بخش آبیاری، دانشگاه شیراز، ۱۷۱ ص.
12. Zanetti, S.S., Sousa, E.F., Oliveira, V.P.S., Almeida, F.T., and Bernard, S. (2007). Estimating evapotranspiration using artificial neural network and minimum climatological data. J. of Irrig. Drain. Eng. ASCE. 133: 2. 83-89.
۱۳. توانگر، ش، یوسفی، ص، میرزایی، س. و اسدلهی، ذ. ۱۳۸۹. پهنه‌بندی استان اصفهان با استفاده از سامانه اطلاعات جغرافیایی GIS، اولین کنفرانس ژئوماتیک نوین در خدمت جامعه. دانشگاه تهران.
۱۴. شاطریان، ر. ۱۳۸۷. اقلیم و معماری ایران. تهران: سیمای دانش.
15. Allen, R.G. Pereira, L.S. Raes, D. and Smith, M. (1998). Crop evapotranspiration Guidelines for computing crop water requirements . FAO Irrig. and Drain. Papr No. 56. Rome.
16. Menhaj, M. (2002). Neural Networks and Artificial Intelligent Basic. First edition. Amir Kabir univ. Press, 350p. (in Persian).
17. Turhan, M., (1995), Neural networks and computation of neural network weights and biases by the generalized delta rule and backpropagation of errors: Rock Solid Images Press.
18. Menhaj, M. B. (2005). Foundations of Neural Networks, Amir Kabir University Of Technology, Tehran.
19. Chio, Jae-ho., Teresa, A., Bahia, M., and Hussain, U. (2004). Pavement Roughness Modeling Using Back-Propagation Neural Networks. Computer-Aided Civil and Infrastructure Engineering ,19:4. 295-303.
20. Goldberg, D. E. (1989), Genetic algorithms in search, optimization, and machine learning. Addison-Wesley Longman Publishing Co., First Ed., Boston, MA, USA.
21. - Koza, J.R. (1994), Genetic programming as a means for programming computers by natural selection. Statistics and Computing, 4(2), 87-112.

22. Ferreira, C. (2001), Gene expression programming: a new adaptive algorithm for solving problems. *Complex Systems*, 13(2), 87-129.
23. Ferreira, C. (2004), Gene Expression Programming and the Evolution of Computer Programs. *Recent Developments in Biologically Inspired Computing*, pages 82-103, Idea Group Publishing.
24. Wilson, G.C. and Banzhaf, W. (2008), A Comparison of Cartesian Genetic Programming and Linear Genetic Programming, *Lecture Notes in Computer Science*, 4971(1), 182-193.