

مقاله پژوهشی

## بررسی و تحلیل حساسیت روش‌های مبتنی بر شبکه‌های عصبی مصنوعی در برآورد تبخیر و تعرق گیاه مرجع

سالومه سپهری صادقیان<sup>۱\*</sup>، فریبرز عباسی<sup>۲</sup>، قاسم زارعی<sup>۳</sup>، محمد مهدی نجخوانی مقدم<sup>۴</sup>

تاریخ دریافت: ۱۳۹۹/۶/۴ تاریخ پذیرش: ۱۳۹۹/۸/۱۷

### چکیده

تبخیر و تعرق از اثرگذارترین پارامترها در چرخه آب در طبیعت و نیز طراحی صحیح سامانه‌های آبیاری بوده و برآورد دقیق آن منجر به کاهش تلفات آب و برنامه‌ریزی بهتر آبیاری می‌گردد. با توجه به توانمندی شبکه‌های عصبی مصنوعی در تحلیل محاسباتی فرآیندهای پیچیده، این پژوهش با هدف کاربرد این تکنیک برای تحلیل داده‌های مؤثر در برآورد تبخیر و تعرق گیاه مرجع (ETO) و مقایسه آن با نتایج حاصل از نرم‌افزار ETO-calculator صورت گرفت. ETO با استفاده از داده‌های هواشناسی (آمار ۱۰ ساله روزانه ۱۲ ایستگاه هواشناسی استان تهران) و با کاربرد نرم‌افزار ETO-calculator محاسبه شد. برای مدل‌سازی ETO، مجموعه ورودی‌ها به شبکه‌های عصبی مصنوعی شامل مقادیر دمای حداقل و حداکثر، رطوبت نسبی حداقل و حداکثر، سرعت باد و تعداد ساعات آفتابی در شبانه روز در نظر گرفته شدند. پس از نگاشت داده‌ها و با بهینه‌سازی تعداد لایه‌های پنهان و الگوریتم‌های شبکه، مقادیر خروجی برآورد شدند. نتایج نشان داد که شبکه عصبی مصنوعی تکنیک بسیار مناسبی برای تحلیل ETO است ( $R^2 \cong 98\%$ ). شیوه آموزش پرسپترون چند لایه‌ای با دو لایه میانی، توابع انتقال تانژانت خطی و تانژانت برای لایه‌های پنهان و خروجی، قانون آموزش لوبزبرگ مارکوات برای هر دو لایه پنهان و خروجی و ساختار ۱-۱۴-۱۱-۶ به عنوان بهترین شبکه برای برآورد ETO پیشنهاد می‌شود. نتایج تحلیل حساسیت نشان داد که شبکه منتخب و نرم‌افزار ETO-calculator روند مشابهی داشته و پارامترهای دمای حداکثر و تعداد ساعات آفتابی در شبانه روز، به ترتیب مؤثرترین و کم‌اثرترین پارامترها در برآورد ETO هستند. همچنین بر مبنای نتایج حاصل از تحلیل مؤلفه‌های اصلی، سناریوی استفاده از چهار پارامتر دمای حداقل و حداکثر، رطوبت نسبی حداکثر و سرعت باد به عنوان تنها ورودی‌ها به شبکه عصبی مصنوعی منتخب، می‌تواند با دقت قابل قبولی تبخیر و تعرق گیاه مرجع را برآورد کند ( $R^2 \cong 94\%$ ).

**واژه‌های کلیدی:** بهینه‌سازی، پارامترهای هواشناسی، فائو پنمن مانیتث، هوش مصنوعی، تحلیل مؤلفه‌های اصلی

### مقدمه

میزان تبخیر و تعرق گیاهان نقش بسزایی در طراحی دقیق‌تر سامانه‌های آبیاری داشته و مدیریت آب در بخش کشاورزی را بهبود می‌بخشد. برای برآورد تبخیر و تعرق گیاه مرجع (ETO) می‌توان از روش‌هایی همچون پنمن فائو، فائو پنمن مانیتث، بلانی کریدل و غیره استفاده نمود. لیکن، اکثر این روش‌ها به خصوص روش فائو پنمن مانیتث، نیازمند پارامترهای زیادی بوده و در اکثر موارد نیاز به فرضیات اولیه‌ای دارند و به سهولت در دسترس نیستند. به‌رغم این مشکل، به‌کارگیری مدل‌هایی که بر اساس استفاده از داده‌های هواشناسی موجود استوار هستند، می‌توانند به عنوان جایگزینی برای اندازه‌گیری‌های مستقیم در نظر گرفته شوند. در دو دهه گذشته در پردازش اطلاعات مسائل پیچیده، سیستم‌های هوشمند به طور فزاینده‌ای مورد توجه واقع شده‌اند، که شبکه‌های عصبی مصنوعی

استفاده بهینه از منابع آب و افزایش بهره‌وری در بخش کشاورزی به عنوان بزرگترین بخش مصرف‌کننده منابع محدود آب کشور، از مسائل ضروری برای سازگاری با معضل کم آبی است. برآورد مناسب

۱-استادیار مؤسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران

۲-استاد مؤسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران

۳-دانشیار مؤسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران

۴-استادیار مؤسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران

(Email: s.sepohri@aeri.ir)

(\* نویسنده مسئول)

لایه پنهان و استفاده از قانون آموزش لوبنبرگ- مارکوارت و تابع تانژانت سیگموئید، بهترین مدل در برآورد تبخیر و تعرق است (Deo and Sahin, 2015). نتایج مطالعات حسینی و همکاران (۱۳۹۵) در منطقه شهرکرد نشان داد شبکه عصبی مصنوعی با دو تابع تانژانت سیگموئید و لوگ سیگموئید در لایه پنهان، تابع خطی در لایه خروجی و قاعده آموزش لوبنبرگ مارکوارت با دقت قابل قبولی، تبخیر و تعرق مرجع را برآورد کرده و این پارامتر نسبت به دو شاخص دمای ماکزیمم و سرعت باد، بیشترین حساسیت را دارد. ژانگ و همکاران (۲۰۱۰) نشان دادند که میزان ETo در حوضه رودخانه شیانگ در چین در تابستان به انرژی قابل دسترس حساسیت زیادی دارد. در حالی که در زمستان، به سرعت باد، بیشترین حساسیت را نشان می‌دهد (Zhang et al., 2010). دین‌پژوه و شریفی (۱۳۹۲) گزارش نمودند که در دو ایستگاه سنندج و سبزوار چه در مقیاس سالانه و چه در مقیاس ماهانه، بیشترین حساسیت ETo نسبت به درجه حرارت میانگین هوا بود. نتایج تحقیقات محمدرضاپور (۱۳۹۶) در استان سیستان و بلوچستان نشان داد که تبخیر و تعرق پتانسیل ماهانه در این منطقه نسبت به شاخص‌های متوسط دمای هوا، رطوبت نسبی و سرعت باد، بیشترین حساسیت را دارد. نتایج مطالعات زمین‌العابدینی رضایاد و همکاران (۲۰۲۰) نشان داد که پارامترهای دمای متوسط، سرعت باد در ارتفاع دو متری و کمبود فشار بخار، بیشترین تأثیر را در برآورد مناسب تبخیر و تعرق مرجع روزانه در منطقه کرمان دارند (Zeinolabedini-Rezaabad et al., 2020). همچنین بر اساس مطالعات وانگ و همکاران در چین، تبخیر و تعرق مرجع بیشتر تحت تأثیر پارامترهای تعداد ساعات آفتابی، دمای متوسط، رطوبت نسبی متوسط و سرعت باد در ارتفاع دو متری است (Wang et al., 2019).

اغلب مطالعات انجام شده در خصوص مدلسازی و تحلیل حساسیت مدل‌ها برای برآورد تبخیر و تعرق گیاه مرجع با استفاده از داده‌های هواشناسی، معمولاً در یک ایستگاه خاص و یا با تعداد محدود سال‌های آماری انجام شده‌اند. از طرفی، امروزه پرکاربردترین ابزار برای برآورد تبخیر و تعرق گیاه مرجع، نرم‌افزار استاندارد معرفی شده توسط فائو تحت عنوان ETo-calculator می‌باشد. لکن تا کنون مطالعه‌ای در خصوص مقایسه کارایی این نرم‌افزار در شرایط کمبود داده‌های هواشناسی با شبکه‌های عصبی مصنوعی در ایران انجام نشده است. هدف از پژوهش حاضر تعیین یک مدل شبکه عصبی مصنوعی بهینه برای مدل‌سازی ETo و تحلیل حساسیت آن و مقایسه کارایی مدل منتخب با نرم‌افزار ETo-calculator (V.5) در شرایط کمبود داده‌های هواشناسی می‌باشد. به‌عنوان یک مطالعه موردی، استان تهران با ۱۲ ایستگاه هواشناسی ورامین، شهریار، فرودگاه امام خمینی (ره)، تهران، شمیران، فیروزکوه، امین‌آباد فیروزکوه (GAW)، مهرآباد، دماوند، چیتگر، ابعلی و دوشان‌تپه

(ANNs) <sup>۱</sup> از این مجموعه هستند. این شبکه‌ها ابزارهایی قوی در یادگیری رابطه ناشناخته و پیچیده بین یک فضای ورودی با فضای خروجی هستند که در زمینه‌های مختلف علمی به کار برده می‌شوند (Laaboudi et al., 2012). وزن‌های شبکه‌های عصبی بر مبنای مقایسه بین خروجی شبکه و داده‌های واقعی به روزرسانی می‌شوند و این کار تا زمانی که خروجی شبکه با داده‌های واقعی که به عنوان هدف در نظر گرفته شده تطبیق پیدا کند، ادامه می‌یابد. برای آموزش شبکه‌های عصبی از بخشی از داده‌های واقعی استفاده می‌شود و پس از آموزش شبکه می‌توان آن را به‌صورت تابعی جعبه سیاه برای برآوردهای غیرخطی با عنوان نگاشت‌های غیرخطی قابل تنظیم معرفی کرد. از روش‌های آموزش می‌توان به روش ویدروهاف و پرسپترون چند لایه‌ای <sup>۲</sup>، و ... اشاره کرد (یزدانی و همکاران، ۱۳۹۰). طی سالیان اخیر، تحقیقات متعددی در خصوص برآورد و تحلیل حساسیت تبخیر و تعرق گیاه مرجع (ETo) نسبت به داده‌های هواشناسی در نقاط مختلف دنیا انجام شده است (Zhang et al., 2010; Liu et al., 2010). چائوهان و شریواستاوا (۲۰۰۸) با کاهش تعداد نرون‌های ورودی شبکه عصبی به دو نرون حداقل و حداکثر دمای هوا در کشور هند، دریافتند که شبکه عصبی مصنوعی کمترین اختلاف را با نتایج فائو پنمن مانیتث در مقایسه با روش‌های تشعشی فائو، پنمن اصلاحی و تشت تبخیر کلاس A دارد (Chauhan and Shrivastava, 2008). نورانی و سیاح فرد (۱۳۹۲) طی مطالعه‌ای کاربرد شبکه‌های عصبی مصنوعی، رگرسیون خطی چند متغیره و سه روش تجربی تعادل انرژی، آیرودینامیکی و ترکیبی پنمن را برای برآورد مقادیر تبخیر روزانه تشتک برای دو شهر تبریز و ارومیه مورد ارزیابی قرار دادند. نتایج به‌دست آمده بیانگر برتری شبکه‌های عصبی در برآورد تبخیر روزانه نسبت به سایر مدل‌ها بود. نتایج تحقیقات لابودی و همکاران (۲۰۱۲) در یک منطقه خشک از آفریقا و همچنین هو و همکاران (۲۰۱۲) در شمال غربی چین نشان دادند که در نواحی خشک و نیمه‌خشک، شبکه عصبی دقت بالاتری در برآورد تبخیر و تعرق نسبت به مدل‌های تجربی دارد (Laaboudi et al., 2012; Huo et al., 2012). آنتونوپولوس و همکاران (۲۰۱۷) تبخیر و تعرق روزانه گیاه مرجع را با استفاده از شبکه عصبی مصنوعی مدل کرده و عنوان کردند که مدلی با ساختار نهایی ۱-۶-۴ با دقت بالایی قادر به تخمین ETo است (Antonopoulos and Antonopoulos, 2017). دئو و شاهین (۲۰۱۵) طی تحقیقی به بررسی کارایی شبکه‌های عصبی مصنوعی برای برآورد تبخیر و تعرق با استفاده از پارامترهای هواشناسی و اقلیمی مربوط به هشت ایستگاه در منطقه شرق استرالیا پرداختند. آنها گزارش کردند مدل شبکه عصبی با یک

- 1- Artificial Neural Networks (ANNs)
- 2- Multi-Layer Perceptron (MLP)

حداکثر و حداقل هوا (RHmax, RHmin)، سرعت باد در ارتفاع ۲ متری ( $U_2$ (m/s)) و تعداد ساعات آفتابی در شبانه‌روز (n) و خروجی نیز ETo محاسبه شده بر اساس داده‌های تشت تبخیر ایستگاه‌های هواشناسی ذکر شده، در نظر گرفته شدند (رابطه ۱).

$$E_{T_o} = K_{pan} \times E_p \quad (1)$$

که در آن  $K_{pan}$  ضریب تشتک و  $E_p$  مقادیر تبخیر از تشتک (mm/d) است.

برای محاسبه ضریب تشتک در ایستگاه‌های هواشناسی ذکر شده از روابط مربوطه بر پایه تشت تبخیر استفاده شد. به این منظور، اقلیم ایستگاه‌های هواشناسی بر اساس روش دومارتن تعیین شده (رابطه ۲) و از رابطه تجربی مربوط به هر اقلیم برای تعیین ضریب تشتک استفاده شد. بر اساس روش دومارتن، ۱۲ ایستگاه مورد مطالعه، مطابق جدول ۱، در چهار دسته اقلیمی طبقه‌بندی شدند.

$$I = \frac{P}{T+10} \quad (2)$$

که در آن:  $P$  متوسط بارش سالانه (میلی‌متر)،  $T$  متوسط دمای سالانه (سانتی‌گراد) و  $I$  ضریب خشکی دومارتن هستند. برای تعیین ضریب تشتک در اقلیم‌های خشک، نیمه‌خشک، نیمه مرطوب و مرطوب به ترتیب از روش‌های Snyder (1992) (رابطه ۳)، Raghuvanshi & Wallender (1998) (رابطه ۴)، Mohamed et al. (2008) (رابطه ۵) و Pereira (1995) (رابطه ۶) استفاده شدند (قمرنیا و سلطانی، ۱۳۹۷).

$$K_{pan} = 0.482 + [0.024 \times \ln(F)] - (0.000376 \times U_2) + (0.0045 \times RH) \quad (3)$$

$$K_{pan} = 0.5944 + (0.0242 \times X_1) - (0.0583 \times X_2) - (0.1333 \times X_3) - (0.2083 \times X_4) + (0.0812 \times X_5) + (0.1344 \times X_6) \quad X_1 = \ln(F); X_2, X_3, X_4 = 0 \text{ if } U_2 < 175; X_2 = 1 \text{ if } 175 \leq U_2 < 425; X_3 = 1 \text{ if } 425 \leq U_2 < 700; X_4 = 1 \text{ if } U_2 \geq 700; X_5, X_6 = 0 \text{ if } RH < 40\%; X_5 = 1 \text{ if } 40\% \leq RH < 70\%; X_6 = 1 \text{ if } RH \geq 70\% \quad (4)$$

$$K_{pan} = 0.62407 - (0.0266 \times (\ln(F))) - (0.0028 \times U_2) + (0.0026 \times (RH)) \quad (5)$$

$$K_{pan} = 0.85 \times (\Delta + \gamma) / [(\Delta + \gamma) \times (1 + 0.33 \times U_2)] \quad (6)$$

در این معادلات  $U_2$  = سرعت باد در ارتفاع ۲ متری از سطح زمین ( $Km/day$ )،  $RH$  = رطوبت نسبی متوسط روزانه (%،  $F$ ) = فاصله از پوشش گیاهی (m)،  $\Delta$  = شیب منحنی فشار بخار در مقابل دما ( $kPa/^\circ C$ ) و  $\gamma$  = ضریب رطوبت ( $kPa/^\circ C$ ) است.

به منظور افزایش سرعت و دقت شبکه و ممانعت از وزن‌دهی نامتعارف به ورودی‌های شبکه به علت پراکندگی داده‌ها، از رابطه زیر برای نرمال‌سازی مقادیر ورودی استفاده شد (Tayfur and Singh, 2005). در نهایت می‌توان خروجی‌های شبکه را با معکوس نمودن الگوریتم استانداردسازی، به حالت اولیه برگرداند.

$$x_n = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (7)$$

انتخاب شد. ایستگاه‌های مورد مطالعه از سه نوع ایستگاه‌های هواشناسی سینوپتیک اصلی، تکمیلی و فرودگاهی می‌باشند. پس از انتخاب شبکه عصبی مناسب، اقدام به تحلیل حساسیت شبکه و همچنین نرم‌افزار ETo-calculator (V.5) نسبت به پارامترهای هواشناسی شده و سپس عوامل مؤثر در برآورد تبخیر و تعرق گیاه مرجع رتبه‌بندی شدند. در نهایت نیز با بررسی همه سناریوهای ممکن در چینش پارامترهای هواشناسی مورد استفاده با استفاده از روش تحلیل مؤلفه‌های اصلی ( $PCA^1$ )، بهترین سناریو انتخاب و معرفی شد.

## مواد و روش‌ها

### موقعیت منطقه مورد مطالعه

استان تهران از لحاظ موقعیت جغرافیایی بین ۳۵ درجه و ۳۴ دقیقه تا ۳۵ درجه و ۵۱ دقیقه عرض شمالی و ۵۱ درجه و ۶ دقیقه تا ۵۱ درجه و ۳۸ دقیقه طول شرقی قرار گرفته است. ارتفاع آن از سطح آب‌های آزاد بین ۱۸۰۰ متر در شمال تا ۱۲۰۰ متر در مرکز و ۱۰۵۰ متر در جنوب متغیر است. در شکل ۱ موقعیت شهرستان‌های استان تهران و ایستگاه‌های هواشناسی مورد مطالعه نشان داده شده است.

### تعیین ETo با استفاده از ETo-calculator و مدل‌سازی با بهره‌گیری از شبکه عصبی مصنوعی

در مطالعه حاضر ابتدا با استفاده از نرم‌افزار (Raes, V.5) ETo-calculator (2012)، متوسط روزانه مقادیر تبخیر-تعرق گیاه مرجع (ETo) با استفاده از معادله استاندارد فائو پنمن مانیتث در ۱۲ ایستگاه هواشناسی استان تهران شامل؛ ایستگاه‌های ورامین، شهریار، فرودگاه امام خمینی(ره)، تهران، شمیران، فیروزکوه، امین‌آباد فیروزکوه (GAW)، مهرآباد، دماوند، چیتگر، آبعلی و دوشان‌تپه در یک دوره آماری ۱۰ ساله برآورد گردید. نرم‌افزار ETo-calculator توسط بخش آب و خاک سازمان جهانی فائو برای محاسبه تبخیر و تعرق گیاه مرجع ارائه شده است. داده‌های هواشناسی مورد استفاده در این نرم‌افزار شامل؛ مقادیر درجه حرارت حداکثر و حداقل هوا، درصد رطوبت نسبی حداکثر و حداقل هوا، سرعت باد در ارتفاع ۲ متری (متر بر ثانیه) و تعداد ساعات آفتابی است.

مدل‌سازی ETo از طریق شبکه عصبی مصنوعی با استفاده از داده‌های هواشناسی (آمار ۱۰ ساله روزانه) ۱۲ ایستگاه هواشناسی استان تهران انجام گرفت. ورودی‌های مورد استفاده در تعیین شبکه عصبی مصنوعی مناسب عبارتند از: متوسط روزانه مقادیر درجه حرارت حداکثر و حداقل هوا ( $T_{max}, T_{min}$  ( $^\circ C$ ))، درصد رطوبت نسبی

$$MSE = \frac{\sum_1^n (exp-cat)^2}{N}$$

۸ تعیین شد.  
(۸)

در این رابطه،  $X_n$  مقدار نرمال شده،  $X_i$  متغیر مورد نظر،  $X_{min}$  و  $X_{max}$  نیز به ترتیب مقادیر حداقل و حداکثر هستند. در پایان برای بررسی و آزمون اعتبار شبکه‌ها، از دو پارامتر  $R^2$  و MSE استفاده شد. میانگین مربعات خطا (MSE) با استفاده از رابطه



شکل ۱- موقعیت شهرستان‌های استان تهران و ایستگاه‌های هواشناسی مورد مطالعه

جدول ۱- مقادیر ضریب خشکی دو مارتن و اقلیم ایستگاه‌های مورد مطالعه

ایستگاه هواشناسی	(I) ضریب خشکی دو مارتن	ایستگاه هواشناسی	اقلیم	(I) ضریب خشکی دو مارتن	اقلیم
ورامین	۵/۴	تهران	خشک	۱۱	نیمه خشک
فرودگاه امام خمینی	۵/۶	فیروزکوه	خشک	۱۳/۷	نیمه خشک
شهریار	۷	دماوند	خشک	۱۶/۱	نیمه خشک
مهرآباد	۸/۴	شمیران	خشک	۱۶/۵	نیمه خشک
چیتگر	۹	امین‌آباد فیروزکوه	خشک	۲۶/۳	نیمه مرطوب
دوشان تپه	۹/۴	آبعلی	خشک	۲۸/۳	مرطوب

تحلیل مؤلفه‌های اصلی (PCA) جهت پیش‌پردازش داده‌های ورودی به مدل استفاده شد. به منظور پیش‌پردازش ورودی‌ها، می‌توان دو رویکرد انتخاب ویژگی یا استخراج ویژگی را در نظر گرفت. در رویکرد انتخاب ویژگی، زیرمجموعه‌های مختلف از ورودی‌ها یک به یک مورد ارزیابی قرار گرفته و بهترین زیرمجموعه به عنوان ویژگی‌های منتخب معرفی می‌شود. در رویکرد استخراج ویژگی، با روش‌های جبر خطی، ویژگی‌ها به یک فضای دیگر تبدیل شده و تعدادی ویژگی جدید ایجاد می‌شود. یکی از روش‌های مرسوم رویکرد استخراج ویژگی روش تحلیل مؤلفه‌های اصلی (PCA) می‌باشد. این روش که مبتنی بر نتایج کاربرد جبر خطی است، به شکل خیلی ساده، بصورت ناپارامتریک و غیرنظارتی بر روی مجموعه داده‌های ورودی اعمال می‌گردد. در روش تحلیل مؤلفه‌های اصلی، متغیرهای موجود در یک فضای چند حالتی همبسته به یک مجموعه از مؤلفه‌های غیرهمبسته تبدیل می‌شوند که هر کدام از آنها ترکیب خطی از متغیرهای اولیه ورودی می‌باشند. مؤلفه‌های غیرهمبسته حاصل، مؤلفه‌های اصلی نامیده می‌شوند. این مؤلفه‌ها را می‌توان با استفاده از مجموعه‌ی داده‌های اصلی، ماتریس کوواریانس یا ماتریس همبستگی محاسبه

در این رابطه،  $N =$  تعداد داده‌ها،  $exp$ : داده‌های مشاهداتی و  $cal$ : داده‌های محاسباتی متناظر با  $exp$  هستند.

در این تحقیق، مجموع ۴۳۸۰ داده مربوط به تبخیر و تعرق گیاه مرجع، به سه دسته برای آموزش (۶۰٪)، برازش متقابل (۱۵٪) و صحت‌سنجی شبکه عصبی مصنوعی (۲۵٪)، تقسیم شدند. بهینه‌سازی شبکه با استفاده از روش سعی و خطا و با کاربرد نرم‌افزار NeuroSolutions (V.5) انجام شد. برای بهینه‌سازی گام به گام شبکه عصبی مصنوعی مطابق چارت ارائه شده در شکل ۲، گام‌ها به صورت متوالی دنبال شدند.

### تحلیل حساسیت و تعیین سناریوی مناسب

برای ارزیابی حساسیت مدل شبکه عصبی انتخاب‌شده و ETO-calculator به پارامترهای ورودی، تکنیک حذف داده ورودی با استفاده از نرم‌افزار NeuroSolutions Infinity (V 1.1.1.0) به کار گرفته شد (Yesilnacar et al. 2008). این پروسه به جهت حذف ورودی‌های کم‌اثر و نیز برای بهبود عملکرد شبکه کاربرد دارد. همچنین به منظور تعیین سناریوی مناسب در برآورد ETO، از تکنیک

کرد. به عبارت دیگر مؤلفه‌های اصلی PCA، مجموعه متغیرهای اولیه را به مجموعه ای از ترکیب خطی متعامد با حداکثر مقدار واریانس تبدیل می‌کند. کاربردهای روش PCA شامل کاهش تعداد متغیر ورودی و یافتن ساختار ارتباطی بین متغیرها به منظور افزایش دقت می‌باشد (Adnan et al., 2017).

## نتایج و بحث

### محاسبات مربوط به انتخاب شبکه عصبی مصنوعی بهینه

نتایج حاصل از مراحل ۱۰ گانه مدل‌سازی تبخیر و تعرق گیاه مرجع در جدول ۲ نمایش داده شده‌اند. ابتدا برای تعیین الگوریتم آموزش بهینه سه الگوریتم MLP، GFF<sup>۱</sup> و RBF<sup>۲</sup> مورد بررسی قرار گرفته و سایر پارامترهای مؤثر در این مرحله ثابت در نظر گرفته شدند. با توجه به نتایج جدول مشاهده می‌شود که الگوریتم MLP با داشتن مقادیر بیشتر R<sup>2</sup> و مقادیر کمتر MSE، به‌عنوان الگوریتم بهینه جهت انجام ادامه مطالعات در نظر گرفته شد. در گام دوم با به‌کارگیری الگوریتم بهینه انتخاب شده در مرحله قبل (MLP) و ثابت گرفتن سایر پارامترهای شبکه، تعداد نرون در لایه میانی بهینه‌سازی شد. به این منظور، محاسبات از تعداد ۳ نرون در لایه پنهان آغاز شد و تا زمانی که مقدار MSE تغییر قابل توجهی نکند، ادامه یافت. نتایج محاسبات نشان داد که با افزایش تعداد نرون‌ها تا ۲۵، مقدار MSE کاهش قابل ملاحظه‌ای یافت، لیکن بعد از این تعداد با افزایش بیشتر تعداد نرون‌ها کاهش بسیار کمی در MSE مشاهده شد. از این‌رو به جهت جلوگیری از پدیده بیش برآزش شبکه، تعداد ۲۵ نرون در لایه میانی به‌عنوان تعداد نرون بهینه، در نظر گرفته شد. برای بهینه‌سازی تابع انتقال بهینه لایه پنهان از توابع انتقال رایج (تانژانت، سیگموئید، خطی، تانژانت خطی و سیگموئید خطی) استفاده شد. همان‌گونه که در جدول ۲ مشاهده می‌شود، بهترین تابع انتقال شبکه عصبی مربوط به تابع تانژانت خطی است. در راستای تعیین بهترین قانون آموزش لایه پنهان از قوانین (لونبرگ-مارکوارت، مومنتوم و دلتا بار دلتا) استفاده شد. در شبکه مورد بررسی، قانون لونبرگ-مارکوارت با بیشترین مقدار R<sup>2</sup> و کمترین مقدار MSE، برای ادامه مطالعات انتخاب شد (جدول ۲). مشابه بند سوم انتخاب تابع انتقال لایه خروجی با توجه به شرایط بهینه شده در بندهای پیشین انجام شده و در این مرحله با مقایسه توابع انتقال یاد شده، مشاهده شد که کمترین مقدار MSE مربوط به تابع تانژانت بود. در مرحله بعد مشابه بند چهارم، قوانین لونبرگ-مارکوارت، مومنتوم و دلتا بار دلتا برای تعیین قانون آموزش بهینه برای لایه خروجی مقایسه شده و نتایج نشان داد که کمترین مقدار MSE مربوط به قانون لونبرگ-مارکوارت است (جدول ۲). در گام انتخاب تعداد لایه پنهان بهینه، از سایر پارامترهای شبکه که در

مراحل قبل بهینه‌سازی شده بودند، استفاده شد. به این منظور با افزایش تعداد لایه‌ها، مقادیر R<sup>2</sup> و MSE مربوط به هر شبکه بررسی شد. نتایج نشان داد که با افزایش تعداد لایه‌ها به ۲، مقدار MSE کاهش یافت. با افزایش تعداد لایه‌ها به ۳ لایه، مقادیر MSE کمی کمتر شد. لیکن جهت ساده‌سازی شبکه، تعداد ۲ لایه به‌عنوان مقدار بهینه در نظر گرفته شد. با توجه به انتخاب دو لایه پنهان، نرون‌های بهینه‌سازی شده در گام ۲، در لایه‌ها توزیع شده و در هر شبکه، مقادیر MSE و R<sup>2</sup> مقایسه شد. در نهایت با توجه به شرایط بهینه‌سازی شده در مراحل قبلی، اقدام به تعیین ساختار نهایی شبکه شد. بر این اساس ساختار نهایی شبکه عصبی مصنوعی بهینه جهت تخمین تبخیر و تعرق گیاه مرجع عبارتست از: شبکه عصبی MLP، تابع انتقال تانژانت خطی برای لایه پنهان و تانژانت برای لایه خروجی، قانون آموزش لونبرگ-مارکوارت برای لایه پنهان و لایه خروجی و ساختار نهایی ۱-۱۴-۱۱-۶.

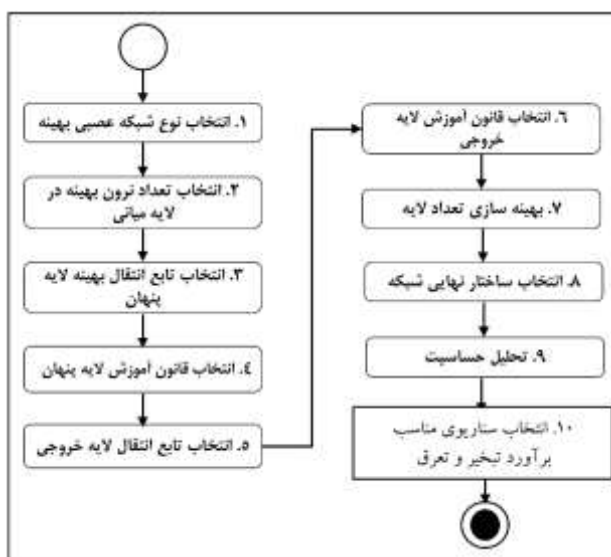
آنتونوپولوس و آنتونوپولوس (۲۰۱۷) شبکه‌ای با یک لایه پنهان و ساختار نهایی ۱-۶-۴ را به‌عنوان شبکه مناسب برای برآورد ETo در یونان معرفی کردند (Antonopoulos and Antonopoulos, 2017)، در حالیکه نتایج تحقیقات دئو و شاهین (۲۰۱۵) نشان داد شبکه‌ای با یک لایه پنهان و ساختار نهایی ۱-۴۳-۱۸ بهترین مدل برای برآورد ETo در استرالیا می‌باشد (Deo and Sahin, 2015). در شکل ۳ مقایسه بین نتایج خروجی مدل بهینه با داده‌های تبخیر و تعرق محاسباتی که جهت آزمون در شبکه عصبی انتخاب شده‌اند، نمایش داده شده است. رابطه رگرسیون بین داده‌های آزمون و خروجی مدل نیز در شکل ۴ نمایش داده شده است. با توجه به مقدار  $R^2 = 98\%$ ، مدل شبکه عصبی مصنوعی انتخاب شده انطباق مناسبی با داده‌های محاسباتی دارد.

### تحلیل حساسیت مدل شبکه عصبی انتخاب‌شده و ETo-calculator

برای تحلیل حساسیت مدل شبکه عصبی مصنوعی انتخاب‌شده، با توجه به این‌که در مرحله قبل بهترین شبکه ممکن برای تخمین تبخیر و تعرق گیاه مرجع آموزش داده و دقت آن سنجیده شد، حساسیت خروجی مدل نسبت به هر یک از پارامترهای ورودی بررسی شد. با توجه به شکل ۵، مشاهده می‌شود که پارامترهای مؤثر بر مدل‌سازی ETo به ترتیب عبارتند از: درجه حرارت حداکثر، درجه حرارت حداقل، درصد رطوبت نسبی حداکثر، سرعت باد در ارتفاع ۲ متری، تعداد ساعات آفتابی در شبانه‌روز و نهایتاً درصد رطوبت نسبی حداقل هوا. برای تحلیل حساسیت ETo-calculator نیز از تکنیک حذف پارامترهای ورودی استفاده شد. با این تفاوت که ETo-calculator به منظور برآورد ETo به حداقل دو پارامتر ورودی درجه حرارت حداکثر و حداقل وابسته است. بنابراین نرم‌افزار نسبت به این

حساسیت مدل شبکه عصبی نیز مؤید این مطلب است که دو پارامتر درجه حرارت حداکثر و حداقل بیشترین تأثیر را در برآورد ETO دارند.

دو پارامتر بسیار حساس بوده و تحلیل حساسیت آن نسبت به سایر پارامترهای ورودی بررسی شد (شکل ۶). نتایج حاصل از تحلیل

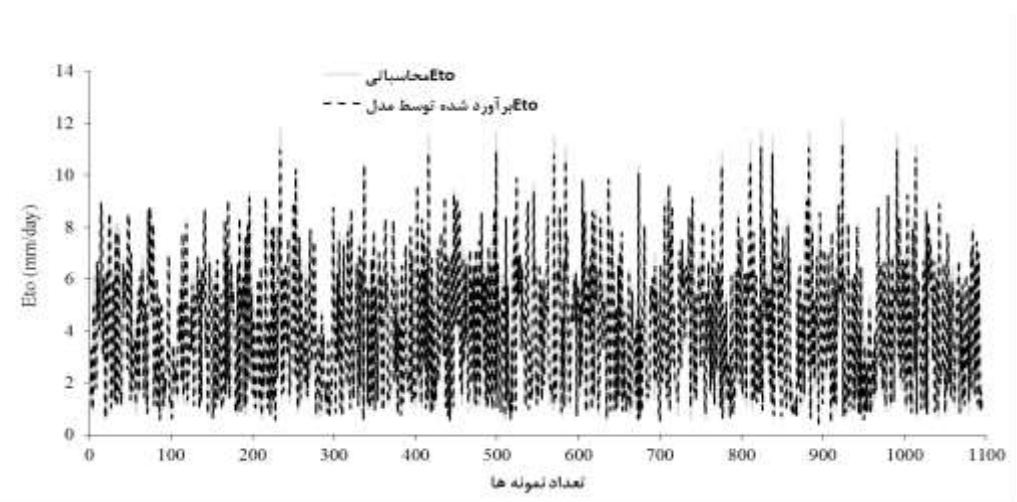


شکل ۲- مراحل بهینه‌سازی شبکه عصبی مصنوعی


جدول ۲- نتایج مراحل مختلف انتخاب شبکه بهینه در مدل‌سازی تبخیر و تعرق گیاه مرجع

		پارامترهای شبکه		گام‌های انتخاب مدل بهینه
MSE	R <sup>2</sup>	الگوریتم		
۰/۰۲۹	۰/۹۸۸۵ *	MLP		۱- مدل شبکه عصبی
۰/۴۲۱	۰/۷۰۵۸	GFF		
۰/۲۴۰	۰/۷۸۸۴	RBF		
		۲۵		۲- تعداد نرون در لایه میانی
۰/۳۳۴	۰/۷۲۱۹	تانژانت		۳- تابع انتقال لایه پنهان
۰/۶۳۲	۰/۶۲۱۲	سیگموئید		
۰/۷۹۹	۰/۵۷۷۰	خطی		
۰/۰۹۷	۰/۹۰۹۵ *	تانژانت خطی		
۰/۲۰۲	۰/۸۰۰۷	سیگموئید خطی		۴- قانون آموزش لایه پنهان
۰/۰۵۷	۰/۹۴۶۵ *	لونیبرگ- مارکوارت <sup>۱</sup>		
۰/۱۳۰	۰/۸۵۴۲	مومنتوم		
۰/۴۴۴	۰/۶۹۹۷	دلتا بار دلنا		۵- تابع انتقال لایه خروجی
۰/۰۸۷	۰/۹۳۱۲ *	تانژانت		
۰/۵۶۸	۰/۶۵۶۰	سیگموئید		
۰/۶۹۱	۰/۶۰۹۸	خطی		
۰/۱۱۳	۰/۸۸۸۱	تانژانت خطی		۶- قانون آموزش لایه خروجی
۰/۵۰۱	۰/۶۸۵۰	سیگموئید خطی		
۰/۱۰۱	۰/۹۲۸۰ *	لونیبرگ- مارکوارت		
۰/۲۶۸	۰/۷۳۷۱	مومنتوم		۷- بهینه‌سازی تعداد لایه
۰/۷۴۵	۰/۵۹۵۴	دلتا بار دلنا		
		۲		۸- ساختار نهایی شبکه
		۶-۱۱-۱۴-۱		


\*: نشان‌دهنده بیشترین مقدار R<sup>2</sup> و کمترین مقدار MSE می‌باشد.




شکل ۳- مقایسه نتایج خروجی مدل بهینه با داده‌های آزمون



شکل ۴- رابطه رگرسیونی بین داده‌های آزمون و خروجی مدل بهینه



شکل ۵- تحلیل حساسیت مدل بهینه نسبت به پارامترهای ورودی برای برآورد تبخیر و تعرق (Tmax: درجه حرارت حداکثر، Tmin: درجه حرارت حداقل، RHmax: درصد رطوبت نسبی حداکثر، RHmin: درصد رطوبت نسبی حداقل، U<sub>2</sub>: سرعت باد در ارتفاع ۲ متری، n: تعداد ساعات آفتابی در شبانه‌روز)



شکل ۶- تحلیل حساسیت نرم افزار ETo-calculator نسبت به پارامترهای ورودی برای برآورد تبخیر و تعرق (RHmax: درصد رطوبت نسبی حداکثر، RHmin: درصد رطوبت نسبی حداقل، U<sub>2</sub>: سرعت باد در ارتفاع ۲ متری، n: تعداد ساعات آفتابی در شبانه‌روز)

انتخاب سناریوی مناسب در چپش داده‌های ورودی استفاده شد. نتایج حاصل از پیش‌پردازش پارامترهای ورودی به روش PCA جدول‌های ۳ و ۴ نشان داده شده است. همان‌طور که جدول ۳، نشان می‌دهد مقدار ویژه<sup>۱</sup> اولین مؤلفه بزرگتر از یک بوده و حدود ۹۰ درصد پراکندگی مجموعه داده‌ها<sup>۲</sup> توسط این مؤلفه بازگو می‌شود. با توجه به ضرایب محاسباتی در بردار اول که در جدول شماره ۴ قابل مشاهده است، متغیرهای Tmax، Tmin، RHmax، U<sub>2</sub> و n به ترتیب بیشترین تا کمترین همبستگی را با مؤلفه اول دارا می‌باشند.

ارتباط بین مؤلفه اول که در خروجی‌های روش PCA، F<sub>1</sub> نامیده می‌شود و متغیرهای اصلی با توجه به جدول ۴ به صورت رابطه (۹) می‌باشد. با توجه به وزن کم پارامتر n در مقایسه با سایر پارامترهای ورودی، می‌توان از این پارامتر چشم‌پوشی کرد.

$$F_1 = 0.66 Tmax + 0.52RHmax + 0.45Tmin + 0.37U_2 + 0.002n \quad (9)$$

در نهایت نتایج حاصل از ترکیب PCA با شبکه عصبی مصنوعی انتخاب شده نشان داد که، سناریوی استفاده از چهار پارامتر Tmax، Tmin، RHmax و U<sub>2</sub> با شاخص‌های آماری R<sup>2</sup>=۰/۹۴ و MSE=۰/۰۹۷، بهترین سناریو در کاهش تعداد پارامترهای ورودی به مدل، کاهش حجم مدل و ساده سازی آن است. به همین دلیل و در نهایت چنانچه دسترسی به تمامی پارامترهای هواشناسی ممکن نباشد، تنها با بهره‌گیری از سناریوهای عنوان شده و مدل شبکه عصبی انتخاب شده، می‌توان با دقت قابل قبولی ETo را برآورد نمود.

با توجه به شکل ۶ مشاهده می‌شود که پارامترهای مؤثر بر مدل‌سازی ETo توسط ETo-calculator به ترتیب عبارتند از: درصد رطوبت نسبی حداکثر، سرعت باد در ارتفاع ۲ متری، تعداد ساعات آفتابی در شبانه روز و درصد رطوبت نسبی حداقل هوا. بنابراین با توجه به آن که تحلیل حساسیت مدل شبکه عصبی مصنوعی انتخاب شده و ETo-calculator روند مشابهی را نشان می‌دهند، به طور کلی می‌توان نتیجه گرفت که تمامی پارامترهای ورودی تا حدودی بر مدل‌سازی تأثیرگذار هستند، درجه حرارت حداکثر و حداقل تأثیرگذارترین و تعداد ساعات آفتابی در شبانه‌روز و حداقل رطوبت نسبی هوا، کم‌اثرترین پارامترها در برآورد ETo هستند. این نتایج تا حدودی منطبق بر نتایج حسینی و همکاران (۱۳۹۵)، دین‌پژوه و همکاران (۱۳۹۲) و محمدرضاپور (۱۳۹۶) می‌باشد. بر اساس مطالعات حسینی و همکاران (۱۳۹۵) در منطقه شهرکرد دو پارامتر دمای حداکثر و سرعت باد بیشترین تأثیر را در برآورد ETo دارند. نتایج تحقیقات محمدرضاپور (۱۳۹۶) نشان داد که متوسط دمای هوا، رطوبت نسبی و سرعت باد به ترتیب اثرگذارترین پارامترها در برآورد ETo در منطقه سیستان و بلوچستان هستند. همچنین نتایج مطالعات دین‌پژوه و شریفی (۱۳۹۲) نیز نشان داد که متوسط دمای هوا اثرگذارترین پارامتر در برآورد ETo در مناطق سنندج و سبزوار می‌باشد. در مقابل مساعدی و همکاران (۲۰۱۶) گزارش کردند که در منطقه بندر انزلی، دو پارامتر رطوبت نسبی حداکثر و سرعت باد تأثیر بسزایی در تعیین تبخیر و تعرق گیاه مرجع دارند (Mosaedi et al., 2016).

### انتخاب سناریوی مناسب در برآورد تبخیر و تعرق به روش تحلیل مؤلفه‌های اصلی

بعد از انجام تحلیل حساسیت برای آن که بیشتر به تأثیر هر کدام از پارامترهای ورودی پی برده شود، از روش (PCA) به منظور

1- Eigenvalue  
2- Proportion



توابع انتقال تانژانت خطی و تانژانت برای لایه‌های پنهان و خروجی، قانون آموزش لونیگ مارکوات برای لایه پنهان و لایه خروجی و ساختار ۱-۱۴-۱۱-۶. نتایج تحلیل حساسیت مدل شبکه عصبی مصنوعی انتخاب شده نسبت به پارامترهای هواشناسی نشان داد که مدل انتخاب شده و ETo-calculator روند مشابهی داشته و پارامترهای دمای حداکثر و تعداد ساعات آفتابی در شبانه روز به ترتیب اثرگذارترین و کم‌اثرترین پارامترها در برآورد ETo هستند. همچنین ارزیابی سناریوهای مختلف در چپش و پیش‌پردازش پارامترهای هواشناسی مورد استفاده با روش تحلیل مؤلفه‌های اصلی، نشان داد که استفاده از سناریوی کاربرد چهار پارامتر دمای حداقل و حداکثر، رطوبت نسبی حداکثر و سرعت باد می‌تواند با دقت قابل قبولی تبخیر و تعرق گیاه مرجع را برآورد کند.

### منابع

حسینی، س.م.ر.، گنجی خرم‌دل، ن. و خیت‌آبادی فراهانی، ا.ج. ۱۳۹۵. ارزیابی مدل‌های تجربی و هوشمند در تخمین تبخیر و تعرق مرجع در شرایط حداقل داده‌های اقلیمی؛ مطالعه موردی شهرکرد. فصلنامه علمی پژوهشی مهندسی آبیاری و آب. ۷ (۲۵): ۱۴۱-۱۲۸.

دین‌پژوه، ی. و شریفی، ع.ر. ۱۳۹۲. حساسیت تبخیر و تعرق گیاه مرجع به تغییر در پارامترهای هواشناسی (مطالعه موردی: سنج و سیروار). نشریه دانش آب و خاک. ۲۳ (۳): ۴۲-۲۵.

قمرنیا، ه. و سلطانی، ن. ۱۳۹۷. بررسی کارایی روش‌های تجربی برآورد تبخیر-تعرق مرجع (بر پایه تشت تبخیر) در اقلیم‌های مختلف (مطالعه موردی ایران). تحقیقات منابع آب ایران. ۱۴ (۴): ۱۹۳-۱۷۴.

محمدرضاپور، ا. ۱۳۹۶. پیش‌بینی تبخیر-تعرق پتانسیل ماهانه با استفاده از مدل‌های ماشین‌بردار پشتیبان، برنامه‌ریزی ژنتیک و سیستم استنتاج عصبی-فازی. فصلنامه علمی پژوهشی مهندسی آبیاری و آب. ۷ (۲۷): ۱۵۰-۱۳۵.

نورانی، و. و سیاح‌فرد، م. ۱۳۹۲. آنالیز حساسیت داده‌های ورودی به شبکه عصبی مصنوعی به منظور برآورد مقدار تبخیر روزانه. مجله آب و فاضلاب. ۳: ۸۸-۱۰۰.

یزدانی، م.، دستجردی، ج.، مهدوی، م. و سلطانی، س. ۱۳۹۰. بررسی کارایی شبکه‌های عصبی پرسپترون چند لایه و زمان تأخیری در برآورد جریان‌های سطحی حوزه آبخیز زاینده‌رود. مجله علمی-پژوهشی علوم و مهندسی آبخیزداری ایران. ۱۶: ۶۲-۵۳.

Adnan, M., Ahsan, M., Rehman, A., and Nazir, M. 2017. Estimating evapotranspiration using machine

جدول ۳- مؤلفه‌های اساسی روش PCA

مؤلفه‌های اصلی <sup>۱</sup>	مقدار	درصد پراکندگی مجموعه	شماره مؤلفه
			ویژه
۱	۴/۲۵	۰/۹۰	
۲	۰/۲۷	۰/۰۶	
۳	۰/۱۲	۰/۰۲	
۴	۰/۰۱۷	۰/۰۰۱	

جدول ۴- اوزان متغیرهای ورودی به ازای هر مؤلفه اصلی PCA

شماره مؤلفه	متغیرهای ورودی	Tmin	Tmax	RHmin	RHmax	U <sub>2</sub>	n
۱		۰/۴۵	۰/۶۶	۰/۰۰	۰/۵۲	۰/۳۷	۰/۰۰۲
۲		۰/۴۳	۰/۴۳	۰/۰۸۷	۰/۱۲	۰/۲۳	۰/۳۲
۳		۰/۰۹۸	۰/۱۷	۰/۲۳۴	۰/۲۶	۰/۰۴	۰/۱۶
۴		۰/۱۲	۰/۵۷	۰/۳۹	۰/۱۴	۰/۸۷	۰/۱۴

### نتیجه‌گیری

شناخت فرآیند تبخیر و تعرق، به‌عنوان یکی از اثرگذارترین پارامترها بر بیلان آبی چه در مقیاس‌های کوچک مانند مزرعه و چه در مقیاس بزرگی مانند حوضه آبریز، دارای اهمیت بسیاری است. محدودیت‌های منابع آبی و بحران آب در کشور از یک سو و سهم بخش کشاورزی به‌عنوان عمده‌ترین مصرف‌کننده آب از سوی دیگر، لزوم استفاده از روش‌های نوین و قابل قبول به منظور مدیریت صحیح آب در این بخش را نمایان‌تر کرده است. برآورد صحیح و دقیق نیاز آبی گیاه مرجع منجر به طراحی دقیق‌تر سامانه‌های آبیاری، برنامه‌ریزی مناسب آبیاری و در نهایت کاهش تلفات آب می‌گردد. روش‌هایی همانند روش فائو پنمن مانیتث که مقبولیت زیادی در برآورد تبخیر و تعرق گیاه مرجع دارند، نیازمند پارامترهای فراوانی بوده و لذا زمان و هزینه بالایی را برای اندازه‌گیری می‌طلبند. به همین دلیل استفاده از یک مدل کارآ، که توانایی برآورد تبخیر و تعرق بر اساس داده‌های هواشناسی موجود و نیز تحلیل حساسیت این پارامتر نسبت به داده‌های هواشناسی را داشته باشد، می‌تواند تأثیر بسزایی در کاهش زمان و هزینه اندازه‌گیری‌ها و همچنین کاهش ریسک‌پذیری پروژه‌ها داشته باشد. در این پژوهش یک مدل شبکه عصبی مصنوعی بهینه برای مدل‌سازی تبخیر و تعرق گیاه مرجع انتخاب شد. برای این منظور شبکه عصبی مصنوعی، طی ۱۰ گام متوالی، بهینه‌سازی شده و مدل نهایی با دقت بالایی ETo را مدل‌سازی کرد ( $R^2 \approx 0.98$ ). مشخصات شبکه انتخاب شده برای پیش‌بینی تبخیر و تعرق گیاه مرجع عبارتست از: شیوه آموزش پرسپترون چند لایه‌ای با دو لایه میانی،

- 128(3): 857-873.
- Pereira, A.R., Villanova, N., Pereira, A.S., and Baebieri, V.A. 1995. A model for the class-A pan coefficient. *Agricultural Water Management* 76: 75-82.
- Raes, D. 2012. The ETo calculator, evapotranspiration from a reference surface. Reference Manual. Version 3.2. FAO. Rome, Italy.
- Raghuwanshi, N.S., and Wallender, W.W. 1998. Converting from pan evaporation to evapotranspiration. *Journal of Irrigation and Drainage Engineering, ASCE* 124(5): 275-277.
- Snyder, R.L. 1992. Equation for evaporation pan to evapotranspiration conversions. *Journal of Irrigation and Drainage Engineering, ASCE* 118(6): 977-980.
- Tayfur, G., and Singh, V.P. 2005. Predicting longitudinal dispersion coefficient in natural streams by artificial neural network. *Journal of Hydraulic Engineering, ASCE* 131(11): 991-1000.
- Wang S., Lian, J., Peng, Y., Hu, B., and Chen, H. 2019. Generalized reference evapotranspiration models with limited climatic data based on random forest and gene expression programming in Guangxi, China. *Agricultural Water Management* 221: 220-230.
- Yesilnacar, M.I., Sahinkaya, E., Naz, M., and Ozkaya, B. 2008. Neural network prediction of nitrate in groundwater of Harran plain, Turkey. *Environmental Geology* 56: 19-25.
- Zeinolabedini-Rezaabad, M., Ghazanfari, S., and Salajegheh, M. 2020. ANFIS modeling with ICA, BBO, TLBO, and IWO optimization algorithms and sensitivity analysis for predicting daily reference evapotranspiration. *Journal of Hydrologic Engineering* 25(8): 20-33.
- Zhang, X., Kang, S., Zhang, L., and Lu, J. 2010. Spatial variation of climatology monthly crop reference evapotranspiration and sensitivity coefficients in Shiyang river basin of northwest China. *Agricultural Water Management* 97: 1506-1516.
- learning techniques. *International Journal of Advanced Computer Science and Applications* 8(9): 108-113.
- Antonopoulos, V., and Antonopoulos, A. 2017. Daily reference evapotranspiration estimates by artificial neural networks technique and empirical equations using limited input climate variables. *Computers and Electronics in Agriculture* 132: 86-96.
- Chauhan, S., and Shrivastava, R.K. 2008. Performance evaluation of reference evapotranspiration estimation using climate based methods and artificial neural networks. *Water Resources Management* 23(5): 825-1023.
- Deo, R., and Sahin, M. 2015. Application of the artificial neural network model for prediction of monthly standardized precipitation and evapotranspiration index using hydro-meteorological parameters and climate indices in eastern Australia. *Atmospheric Research* 162: 65-81.
- Huo, Z., Feng, S., Kang, S., and Dai, X. 2012. Artificial neural network models for reference evapotranspiration in an arid area of northwest China. *Journal of Arid Environments* 82: 81-90.
- Laaboudi, A., Mouhouche, B., and Draoui, B. 2012. Neural network approach to reference evapotranspiration modeling from limited climatic data in arid regions. *International Journal of Biometeorology* 56: 831-841.
- Liu, Q., Yang, Z., Cui, B., and Sun, T. 2010. The temporal trends of reference evapotranspiration and its sensitivity to key meteorological variables in the Yellow River basin, China. *Hydrological Processes* 24: 2171-2181.
- Mohamed, H., Wahed, A., and Snyder, R.L. 2008. Simple equation reference evapotranspiration from evaporation pans surrounded by fallow soil. *Journal of Irrigation and Drainage Engineering, ASCE* 134(4): 425-429.
- Mosaedi, A., Ghabaei-Sough, M., Sadeghi, H., Mooshakian, Y., and Bannayan, M. 2016. Sensitivity analysis of monthly reference crop evapotranspiration trends in Iran: a qualitative approach. *Theoretical and Applied Climatology*

## Investigation of Artificial Neural Network Based Models and Sensitivity Analysis for Reference Evapotranspiration Estimating

S. Sepehri Sadeghian<sup>1\*</sup>, F. Abbasi<sup>2</sup>, G. Zarei<sup>3</sup>, M.M. Nakhjavanimoghaddam<sup>4</sup>

Received: Aug.25, 2020

Accepted: Nov.07, 2020

### Abstract

Reference evapotranspiration (ET<sub>o</sub>) is one of the most critical parameters in proper design of irrigation systems. Accurate estimation of ET<sub>o</sub> leads to reduction of water losses. Due to the ability of Artificial Neural Networks (ANNs) in computational analysis of complex processes, the main objective of this study was to investigate the sensitivity of the ET<sub>o</sub> trends to key climatic factors in Tehran province using the artificial neural networks, and compare it with the ET<sub>o</sub>-calculator software results. The ET<sub>o</sub> was calculated using meteorological data (10-year data of 12 meteorological stations in Tehran province) using the ET<sub>o</sub>-calculator software. In order to model ET<sub>o</sub>, a set of inputs to artificial neural networks including the minimum and maximum air temperature (T<sub>max</sub> and T<sub>min</sub>), the minimum and maximum relative humidity (RH<sub>min</sub> and RH<sub>max</sub>), sunshine hours (n), and wind speed (U<sub>2</sub>) were considered. After data tagging, by optimizing the number of hidden layers and network algorithms, output values were estimated. The results indicated that artificial neural network is a suitable technique for ET<sub>o</sub> analysis ( $R^2 \cong 98\%$ ). The best model for estimation of ET<sub>o</sub> is feed-forward Multi-Layer Perceptron (MLP) with two hidden layers in its structure (6-11-14-1), Levenberg–Marquardt training algorithm for both hidden and output layers and Linear Tanh and Tanh transfer functions for hidden and output layers, respectively. The sensitivity analysis of the model for input parameters showed that the optimal artificial neural network model and ET<sub>o</sub> calculator software have the same trend and the T<sub>max</sub> and n are the most effective and least effective parameters in ET<sub>o</sub> estimation, respectively. Also, based on PCA analysis results the scenario of using of four parameters (T<sub>max</sub>, T<sub>min</sub>, RH<sub>max</sub> and U<sub>2</sub>) as the only inputs to the selected artificial neural network, can estimate ET<sub>o</sub> with an acceptable accuracy ( $R^2 \cong 94\%$ ).

**Keywords:** Artificial intelligence, FAO-Penman-Monteith, Meteorological parameters, Optimization, Principal component analysis

---

1- Assistant Professor of Irrigation and Drainage Engineering, Agricultural Engineering Research Institute (AERI), Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran  
2- Professor of Irrigation and Drainage Engineering, Agricultural Engineering Research Institute (AERI), Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran  
3- Associate Professor of Irrigation and Drainage Engineering, Agricultural Engineering Research Institute (AERI), Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran  
4- Assistant Professor of Irrigation and Drainage Engineering, Agricultural Engineering Research Institute (AERI), Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran  
(\* - Corresponding Author Email: s.sepehri@aeri.ir)