

## ارزیابی مدل‌های تجربی و هوشمند در تخمین تبخیر و تعرق مرجع در شرایط حداقل داده اقلیمی؛ مطالعه موردی شهر کرد

سید محمد رضا حسینی وردنجانی<sup>۱</sup>، ناصر گنجی خرم دل<sup>۲</sup>، امیر حسین خلت آبادی فراهانی<sup>۳</sup>

تاریخ دریافت: ۱۳۹۴/۰۲/۱۵

تاریخ پذیرش: ۱۳۹۵/۰۶/۲۳

### چکیده

امروزه منابع آب به شدت تحت تاثیر چرخه‌ی هیدرولوژیکی هستند و برآورد تبخیر و تعرق که جزء اصلی از چرخه‌ی هیدرولوژیکی است، در مدیریت منابع آب نقش بسزایی دارد. این پدیده، غیرخطی و از این لحاظ که پارامترهای بسیاری در برآورد آن دخیل هستند، کاری بسیار مشکل است. روش‌های زیادی برای برآورد تبخیر و تعرق وجود دارد که هر کدام با مشکلی مواجه می‌باشند. بعضی از این روش‌ها مثل لایسیمتر هزینه‌بر و زمانبر می‌باشند و برخی دیگر مثل روش‌های تجربی اعتبار محلی دارند. استفاده از روشی که بتواند با توجه به ماهیت و استفاده‌ی حداقل از داده‌های اقلیمی تبخیر و تعرق را مدل کند، ضروری به نظر می‌رسد. امروزه شبکه‌های عصبی که شاخه‌ای از هوش محاسباتی می‌باشند، در علوم مختلف مورد استفاده قرار می‌گیرند. در این تحقیق از داده‌های روزانه‌ی دو ایستگاه فرخ‌شهر و فرودگاه شهرکرد در بازه‌ی زمانی ۲۰۱۳-۲۰۰۴ شامل دمای حداقل، دمای حداکثر، رطوبت نسبی میانگین، ساعات آفتابی و سرعت باد در ارتفاع دو متری تحت سناریوهای مختلف استفاده شد. ابتدا به محاسبه‌ی چند روش تجربی در برآورد تبخیر و تعرق مرجع پرداخته شد. روش‌های تجربی مورد استفاده این تحقیق هارگریوز، بلانی کریدل، پریستلی تیلور و جنسن هیز بودند. مدل شبکه‌ی عصبی مصنوعی تحت سناریوهای مختلف داده‌ی ورودی به کمک نرم‌افزار MATLAB (R2012b) طراحی گردید. در این قسمت با انجام تست‌های مختلف با توجه به حساسیت و میزان دقت مورد انتظار از دو تابع تانژانت سیگموئید و لوگ سیگموئید در لایه پنهان، تابع خطی در لایه خروجی و قاعده‌ی آموزش لونیبرگ مارکوات استفاده شد. برای ارزیابی مدل‌ها از مدل پنمن مونتیت فائو ۵۶ استفاده شد. شاخص‌های آماری RMSE و MAE و R محاسبه گردید. نتایج نشان داد که از بین ده سناریوی مورد بررسی، سناریوی یک با هر پنج متغیر ورودی، کمترین خطا را نسبت به روش فائو ۵۶ و عملکرد بسیار بهتری نسبت به روش‌های تجربی داشت. از بین روش‌های تجربی نیز مدل پریستلی تیلور و هارگریوز عملکرد بهتری داشتند. همچنین نتایج آنالیز حساسیت نشان داد که دمای ماکزیمم و سرعت باد بیشترین تاثیر را بر تبخیر و تعرق مرجع در این منطقه داشتند.

<sup>۱</sup> - کارشناس مهندسی آب، دانشجوی کارشناسی ارشد آبیاری و زهکشی، گروه مهندسی آب، دانشگاه اراک، ایران. شهرکرد، فردوسی شمالی.

mohammad.mrh2015@gmail.com ۰۰۹۳۹۹۷۱۴۶۲۸

<sup>۲</sup> - استادیار، دانشکده کشاورزی، گروه مهندسی آب، دانشگاه اراک، اراک، ایران. ۰۰۹۳۹۳۹۷۵۲۵۷. Naser.GanjiKhorramdel@gmail.com

(مسئول مکاتبات)

<sup>۳</sup> - استادیار، دانشکده کشاورزی گروه علوم دامی، دانشگاه اراک، اراک، ایران. ۰۰۹۱۲۵۳۵۱۹۵۶. a-farahani@araku.ac.ir

واژه‌های کلیدی: تبخیر و تعرق مرجع، روش‌های تجربی، شبکه‌ی عصبی مصنوعی، MATLAB، منطقه خشک سرد.

## مقدمه

بخش کشاورزی مصرف کننده‌ی اصلی آب در کشور است و مدیریت مصرف آب در این بخش کمک شایانی در صرفه‌جویی آب دارد. از طرفی با پیشرفت علم و افزایش جمعیت و توسعه‌ی صنایع و معادن و بالا رفتن سطح بهداشت، مصرف آب در آینده دچار تغییراتی زیادی خواهد بود. افزایش رقابت بر سر استفاده از آب در میان مصرف کنندگان این ماده‌ی حیاتی، ضرورت تخمین دقیق آب مصرفی گیاه را بیشتر نشان می‌دهد (احمدزاده قره‌گویز و همکاران، ۱۳۸۹). تبخیر و تعرق<sup>۱</sup> مرجع یکی از اجزای اصلی چرخه‌ی هیدرولوژیکی است. برآورد دقیق آن از اهمیت زیادی برخوردار است و برای بسیاری از مطالعات مانند توازن هیدرولوژیکی، طراحی سیستم‌های آبیاری، شبیه‌سازی عملکرد محصول و مدیریت منابع آب از اهمیت زیادی برخوردار می‌باشد (Kumar et al., 2011) بیش از ۶۰ درصد کل بارش جهانی صرف تبخیر و تعرق می‌شود (Chow et al., 1988). تبخیر و تعرق ترکیبی از سه مرحله شامل تبخیر از سطح آب آزاد، تعرق از برگ گیاهان و تصعید یخ و برف است (Penman, 1948). میزان نیاز آبی گیاه می‌تواند به طریق مستقیم و با استفاده از تکنیکهای پرهزینه هواشناسی که مبتنی بر بیلان انرژی و نیز انتقال جریان جرم بخار می‌باشند، صورت پذیرد. بکارگیری لایسیمتر امکان تعیین تبخیر و تعرق را بر اساس اندازه‌گیری برخی از مؤلفه‌های بیلان آب در یک سطح گیاهی کنترل شده فراهم می‌آورد. این روش‌ها زمان‌بر و نیازمند هزینه‌ی زیاد می‌باشند (Allen et al., 1998). تاکنون روش‌های تجربی زیادی به کمک داده‌های اقلیمی در نقاط

مختلف جهان با اقلیم‌های گوناگون تهیه شده است. روش پنمن مونتیت که توسط آلن و همکاران در سال ۱۹۹۸ ارائه گردید، توسط سازمان فائو به عنوان روش استاندارد در برآورد تبخیر و تعرق در صورت عدم دسترسی به داده‌های لایسیمتری پیشنهاد گردید (Ladlani et al., 2012). این معادله مبنای فیزیکی داشته و به داده‌های دما، رطوبت، سرعت باد و تشعشع خورشیدی نیاز دارد (Allen et al., 1998). همه‌ی این متغیرها معمولاً در تمام ایستگاه‌ها ثبت نمی‌شوند. از طرفی تبخیر و تعرق پدیده‌ای غیرخطی و پیچیده است و عوامل بسیار زیادی بر روی این پدیده تاثیر گذار است و تأسیس ایستگاه هواشناسی جدید هزینه بر و زمانبر می‌باشد. داده‌هایی هم که در ایستگاه‌های مختلف هواشناسی اندازه‌گیری و بایگانی می‌شوند، حجم زیادی از اطلاعات را شامل می‌شوند و به مرور بر حجم آنها افزوده می‌شوند. بنابراین توسعه و ارائه‌ی روشی که با حداقل داده اقلیمی این پارامتر را بر نماید، ضروری به نظر می‌رسد (Ladlani et al., 2012 ; Kumar et al., 2008).

امروزه شبکه‌ی عصبی مصنوعی به طور گسترده‌ای در مطالعات مربوط به پیش بینی کاربرد گسترده‌ای دارند (Rahimi Khoob et al., 2008). شبکه‌ی عصبی مصنوعی یک ابزار بسیار قوی در مدلسازی پدیده‌های غیرخطی می‌باشد. در زمینه‌ی استفاده از شبکه عصبی مصنوعی مطالعات متعددی در زمینه‌های مختلف از جمله در هیدرولوژی صورت گرفته است. شایان نژاد (۱۳۸۵) به مقایسه عملکرد مدل شبکه عصبی مصنوعی و مدل پنمن مونتیت فائو نسبت به داده‌های لایسیمتری پرداخت. نتایج نشان داد که مدل شبکه عصبی مصنوعی نسبت به مدل پنمن مونتیت فائو عملکرد بهتری داشته و نیاز به داده‌های کمتری دارد. صیادی و همکاران (۱۳۸۸) عملکرد شبکه‌های

<sup>1</sup> - Evapotranspiration

و تفرق مرجع در مقایسه با داده‌های لایسیمتری در ایستگاه کهریزک ارومیه پرداختند. نتایج نشان داد که شبکه عصبی مصنوعی نسبت به تمامی روش‌های کلاسیک عملکرد بهتری داشت. از میان روش‌های کلاسیک روش تورک، جنسن هیز و پنمن مونتیث فائو در اولویت قرار داشتند.

از آنجا که تبخیر و تفرق دارای بعد مکانی و زمانی است، هدف از این تحقیق تعیین و ارزیابی بهترین مدل شبکه عصبی مصنوعی تحت سناریوهای مختلف حداقل داده‌ی اقلیمی و مقایسه آن با استفاده از شاخص‌های آماری با روش‌های تجربی معتبر و ارائه‌ی کاربردی‌ترین سناریوها در منطقه‌ی خشک سرد شهرکرد می‌باشد.

## مواد و روش‌ها

### منطقه مطالعاتی

شهرکرد یکی از شهرهای مرکزی ایران و مرکز شهرستان شهرکرد و استان چهارمحال و بختیاری است. شهرکرد طبق نمایه‌ی آمیژه دارای آب و هوای خشک سرد است. این شهر بین ۵۰ درجه و ۴۹ دقیقه و ۲۲ ثانیه تا ۵۰ درجه و ۵۳ دقیقه و ۴۴ ثانیه طول جغرافیایی و ۳۲ درجه و ۱۸ دقیقه و ۲۲ ثانیه تا ۲۳ درجه و ۲۱ دقیقه و ۵۰ ثانیه عرض جغرافیایی قرار گرفته است. این شهر با ارتفاع ۲۰۵۰ تا ۲۳۱۰ متر از سطح دریا مرتفع‌ترین شهر ایران است. میانگین سالیانه دما در این شهر ۱۱/۵ درجه سانتی‌گراد می‌باشد. سردترین و گرمترین ماه‌های آن به ترتیب دی و مرداد می‌باشد. در طول ۳۰ سال گذشته حداقل مطلق دما و حداکثر مطلق آن به ترتیب در شهرکرد به ۳۲ درجه سانتی‌گراد زیر صفر و ۴۲ درجه سانتی‌گراد بالای صفر رسیده است. موقعیت این شهر و مشخصات ایستگاه‌های مورد بررسی در (شکل ۱) و (جدول ۱) آمده است.

در این تحقیق ابتدا داده‌های هواشناسی روزانه دو ایستگاه فرخ‌شهر و فرودگاه شهرکرد شامل دمای روزانه‌ی حداقل و حداکثر، رطوبت نسبی متوسط،

مصنوعی  $RBF^1$  و  $MLP^2$  را در برآورد تبخیر و تفرق مرجع با استفاده از داده‌های سال‌های ۱۳۳۰ تا ۱۳۸۳ در ایستگاه تبریز مورد بررسی قرار دادند و نتیجه گرفتند که تنها با دو پارامتر دمای میانگین و سرعت باد به عنوان ورودی می‌توان میزان تبخیر و تفرق مرجع را با استفاده از این دو نوع شبکه با دقت قابل قبولی تخمین زد. احمدزاده قره‌گویز و همکاران (۱۳۸۹) به برآورد تبخیر و تفرق مرجع در مناطق بسیار خشک ایران به کمک شبکه‌های عصبی و سیستم عصبی فازی<sup>۳</sup> پرداختند. داده‌های مورد استفاده در این تحقیق داده‌های دما، رطوبت نسبی، ساعات آفتابی و سرعت باد در ارتفاع دو متری بودند. نتایج نشان داد که شبکه‌های عصبی عملکرد بهتری نسبت به روش‌های تجربی در هر سه ایستگاه کرمان اصفهان و یزد دارند. Huo et al., 2012 به کمک شبکه‌های عصبی، رگرسیون چند متغیره<sup>۴</sup>، معادله‌ی پنمن و دو معادله‌ی هارگریوز و پریستلی تیلور با استفاده از داده‌های ۵۰ ساله سه ایستگاه هواشناسی در شمال غربی چین به محاسبه‌ی تبخیر و تفرق پرداختند. داده‌های ورودی به مدل‌ها عبارت از دمای حداکثر و دمای حداقل، رطوبت نسبی، سرعت باد و ساعات آفتابی و خروجی مدل شبکه‌ی عصبی به کمک معادله پنمن مونتیث فائو<sup>۵</sup> محاسبه گردید. نتایج نشان داد که در نواحی خشک و نیمه خشک شبکه‌ی عصبی با همه‌ی پارامترهای ورودی دقت بالاتری نسبت به سایر مدل‌ها دارد. نوری و همکاران (۱۳۹۲) تبخیر و تفرق پتانسیل را به کمک شبکه‌ی عصبی و مدل‌های تجربی ماکینگ، هارگریوز و بلانی کریدل در مشهد برآورد نمودند. شبکه‌های مختلفی با سناریوهای گوناگون طراحی گردیدند. نتایج حاکی از برتری شبکه‌ی عصبی نسبت به مدل‌های تجربی بود. هژبر و همکاران (۱۳۹۳) به ارزیابی عملکرد شبکه‌های عصبی مصنوعی و یازده روش شناخته شده در تخمین تبخیر

<sup>1</sup> - Multilayer Perceptron networks

<sup>2</sup> - Radial Basis networks

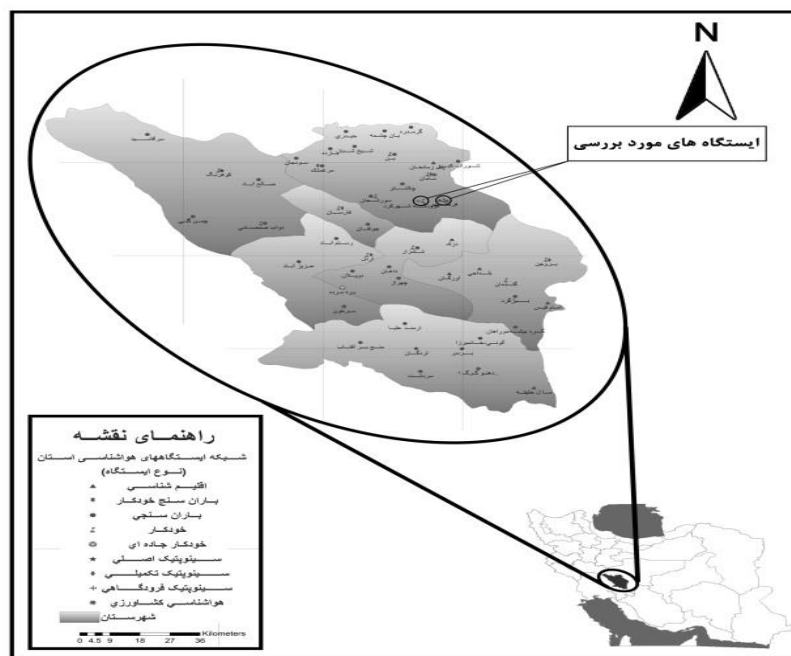
<sup>3</sup> - Neuro - Fuzzy

<sup>4</sup> - Multivariate regression

سرعت باد و ساعات آفتابی در بازه‌ی زمانی سال ۲۰۱۳-۲۰۰۴ از اداره هواشناسی استان تهیه گردید.

جدول (۱): ویژگی‌های ایستگاه‌های مورد مطالعه

نام ایستگاه	اقلیم	ارتفاع از سطح دریا	طول جغرافیایی	عرض جغرافیایی
فرخشهر	خشک سرد	۲۰۷۳	۵۰/۹۳	۳۲/۳۰
فرودگاه شهرکرد	خشک سرد	۲۰۵۰	۵۰/۸۴	۳۲/۲۹



شکل (۱): موقعیت ایستگاه‌های مورد مطالعه

## مدل‌های مورد استفاده

## مدل پنمن مونتیث فائو

این مدل یکی از معتبرترین روش‌ها برای تخمین  $ET_0$  است که مورد استفاده متخصصان قرار می‌گیرد. در روش مذکور، گیاه مرجع، چمن با ارتفاع ۱۲ سانتی‌متر و ضریب بازتاب تابش آن ۲۳ درصد است (علیزاده و همکاران، ۱۳۸۳). این معادله به عنوان معادله مرجع تبخیر و تعرق شناخته شده و

سایر روش‌ها نسبت به این روش کالیبره می‌شوند. مدل این روش به صورت رابطه‌ی (۱) می‌باشد.

$$ET_0 = \frac{0.408 \Delta (R_n - G) + \gamma \left[ \frac{900}{(T+273)} \right] U_2 (e_s - e_d)}{\Delta + \gamma (1 + 0.34 U_2)} \quad (1)$$

در این رابطه  $ET_0$  تبخیر و تعرق روزانه (mm/day)،  $R_n$  تابش خورشیدی روزانه رسیده به سطح گیاه ( $Mj m^{-2} d^{-1}$ )،  $G$  شار گرما به داخل خاک

سال هفتم • شماره بیست و پنجم • پاییز ۱۳۹۵

$$e_{s,max} = \exp\left(\frac{19.08T_{max} + 429.41}{T_{max} + 237.3}\right) \quad (7)$$

در این رابطه  $e_{s,max}$  فشار بخار اشباع به ازای ماکزیمم روزانه دمای هوا در گرمترین ماه سال (mbar)،  $e_{s,min}$  فشار بخار اشباع به ازای مینیمم روزانه دمای هوا در گرمترین ماه سال ( $R_5$ ، mbar)، تابش خورشیدی در دوره‌ی مورد نظر (mm/day) می‌باشد.

#### مدل بلانی کریدل<sup>۵</sup>

این روش فقط به دمای روزانه نیاز دارد و از طریق رابطه‌ی (۸) محاسبه می‌شود (Wang et al., 2008).

$$ET_0 = P(0.46T + 8.13) \quad (8)$$

در این رابطه  $p$  درصد ساعات روشنایی روزانه می‌باشد که به عرض جغرافیایی بستگی دارد.

#### مدل هارگریوز<sup>۶</sup>

این روش بر پایه دمای حداکثر و حداقل می‌باشد و می‌تواند تبخیر و تعرق را ماهانه، هفتگی، ده روزه و یا ۲۴ ساعته محاسبه کند و به صورت رابطه‌ی (۹) تعریف می‌شود (Hargreaves et al., 1985).

$$ET_0 = 0.0023(T_{mean} + 17.8)(T_{max} - T_{min})^{0.5} \cdot R_a \quad (9)$$

در این رابطه  $R_a$  تابش برون‌زمینی برحسب  $(Mj m^{-2} d^{-1})$  می‌باشد.

$\gamma$  ثابت سایکرومتری  $(Mj m^{-2} d^{-1})$ ،  $T$  میانگین دمای روزانه  $(C^{\circ})$ ،  $u_2$  سرعت باد در ارتفاع دو متری  $(m/s)$ ،  $e_a$  فشار بخار اشباع  $(kpa)$ ،  $e_d$  فشار بخار واقعی  $(kpa)$  و  $\Delta$  شیب منحنی فشار بخار اشباع  $(kpa^{-1})$  می‌باشد. (Allen et al., 1998).

#### مدل پریتلی - تیلور

این روش توسط پریتلی<sup>۱</sup> و تیلور<sup>۲</sup> در سال ۱۹۷۲ ارائه شده و به داده‌های تابش خورشیدی و دما نیاز دارد. این ساده‌سازی بیشتر به این دلیل است که تبخیر و تعرق بیشتر از سرعت باد به تبخیر خورشیدی وابسته است. این مدل مطابق با رابطه‌ی (۲) محاسبه می‌شود (Priestley et al., 1972).

$$ET_0 = \frac{\alpha \Delta}{\lambda(\Delta + \gamma)} (R_n - G) \quad (2)$$

در این رابطه  $\alpha = 1.26$  می‌باشد.

#### مدل جنسن هیز

این معادله توسط جنسن<sup>۳</sup> - هیز<sup>۴</sup> مطابق روابط (۳) تا (۷) ارائه شده است (علیزاده و همکاران، ۱۳۸۳).

$$ET_0 = C_t (T - T_x) R_5 \quad (3)$$

$$C_t = \frac{1}{45 - (h/137) + (365/e_{s,max} - e_{s,min})} \quad (4)$$

$$T_x = -2.5 - 0.14(e_{s,max} - e_{s,min}) - \left(\frac{h}{500}\right) \quad (5)$$

$$e_{s,min} = \exp\left(\left(\frac{19.08T_{min} + 429.41}{T_{min} + 237.3}\right)\right) \quad (6)$$

<sup>1</sup> - Priestley

<sup>2</sup> - Taylor

<sup>3</sup> - Jensen

<sup>5</sup> - Hayes

<sup>5</sup> - Blaney and Criddle

<sup>6</sup> - Hargreaves

پیشخور حلقه‌ی بازخور وجود ندارد که معروفترین آنها شبکه‌های پرسپترون چند لایه است. این شبکه‌ها رایج ترین شبکه‌های عصبی و جزء شبکه‌های پیشخور می باشد که قادرند با انتخاب مناسب تعداد لایه‌ها و نرون‌ها، یک نگاشت غیرخطی را با دقت دلخواه انجام دهند. پارامترهای قابل تنظیم در این شبکه‌ها، وزن اتصال ما بین لایه‌هاست و فرآیند آموزش در این شبکه‌ها به معنای یافتن مقادیر مناسب برای وزن‌های اتصالات ما بین نرون‌ها می‌باشد (دهقانی و همکاران، ۱۳۸۹). در شبکه‌های بازگشتی حلقه‌ی بازخور وجود دارد که معروفترین آنها شبکه‌های هاپفیلد می‌باشد.

#### معیارهای ارزیابی عملکرد

به منظور ارزیابی مدل‌ها، شاخص‌های آماری زیر مطابق روابط (۱۰) تا (۱۲) محاسبه گردیدند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - P_i)^2}{n}} \quad (10)$$

$$MAE = \frac{\sum_{i=1}^N (|O_i - P_i|)}{N} \quad (11)$$

$$R = \frac{\sum_{i=1}^N O_i P_i}{\sqrt{\sum_{i=1}^N O_i^2 \sum_{i=1}^N P_i^2}} \quad (12)$$

در این رابطه‌ها

$O_i$ : تخریر و تعرق به روش پنمن مونتیث فائو

$P_i$ : تخریر و تعرق محاسبه شده به هر روش

MAE: میانگین مطلق خطا<sup>۸</sup> که هر چه این شاخص به صفر نزدیک‌تر باشد، نشان دهنده‌ی انحراف کمتر و دقت بالاتر مدل می‌باشد.

RMSE: مجذور میانگین مربعات خطا<sup>۹</sup> که هر چه این شاخص به صفر نزدیک‌تر باشد، نشان دهنده‌ی خطای کمتر و دقت بالای مدل می‌باشد.

#### مدل شبکه عصبی مصنوعی

شبکه‌های عصبی به عنوان یکی از مولفه‌های اصلی هوش محاسباتی<sup>۱</sup> از خواص مهمی برخوردارند که آنها را در علوم و مسائل فنی مهندسی حائز اهمیت می‌نماید. بعضی از پیش زمینه‌های شبکه عصبی را می‌توان به اوایل قرن بیستم و اواخر قرن نوزدهم نسبت داد. اما دیدگاه جدید شبکه‌ی عصبی در دهه‌ی چهل قرن بیستم آغاز شد، زمانی که مک کلاچ<sup>۲</sup> و والتر پیترز<sup>۳</sup> نشان دادند که شبکه عصبی می‌تواند هر تابع منطقی و حسابی را محاسبه نمایند. اما نخستین کاربرد عملی شبکه‌های عصبی در اواخر دهه‌ی ۵۰ قرن بیستم مطرح شد. زمانی که روزنبلات<sup>۴</sup> در سال ۱۹۵۸ شبکه‌های پرسپترون را معرفی نمود. در خلال دهه‌ی هشتاد، شبکه‌ی عصبی برگشتی توسط جان هاپفیلد<sup>۵</sup> و الگوریتم پس‌انتشار توسط رامهارت و جیمز ملکنند ارائه گردید. در بین خواص شبکه‌های عصبی تقریب زنی توابع، ساختار موازی، قدرت یادگیری و تعمیم از اهمیت خاصی برخوردار است (منهاج و همکاران، ۱۳۸۱). از دیگر ویژگی این شبکه‌ها می‌توان به وابسته نبودن آنها به فرضیه‌های اولیه درباره‌ی داده‌های ورودی اشاره نمود. به این معنا که داده‌ها می‌توانند هر توزیع آماری داشته باشند (Civco et al., 1994). سرعت پردازش این شبکه‌ها یکی دیگر از ویژگی‌ها مهم است که این شبکه‌ها را نسبت به مدل‌های مشابه برجسته‌تر کرده است (Benediktsson et al., 1990). معماری شبکه‌های عصبی به دو دسته‌ی کلی شبکه‌های پیشخور<sup>۶</sup> و شبکه‌های بازگشتی<sup>۷</sup> تقسیم می‌شود. در شبکه‌های

<sup>۱</sup> - Computational Intelligence

<sup>۲</sup> - Mcculloch

<sup>۳</sup> - Pitts

<sup>۴</sup> - Rosenblatt

<sup>۵</sup> - Hopfield

<sup>۶</sup> - Feedforward

<sup>۷</sup> - Recurrent

<sup>۸</sup> - Mean Absolute Error

<sup>۹</sup> - Root Mean Square of Error

(آموزش<sup>۲</sup> و اعتبار<sup>۳</sup>) و ۲۵ درصد (تست<sup>۴</sup>) تقسیم شد (Falamarzi et al., 2014). متداولترین توابع فعال<sup>۵</sup> توابع سیگنوییدی و خطی می‌باشند (منهاج و همکاران، ۱۳۸۱). در این تحقیق از تابع تانژانت سیگموئید<sup>۶</sup> در لایه پنهان و تابع خطی در لایه خروجی و بار دیگر از تابع لوگ سیگموئید<sup>۷</sup> در لایه پنهان و تابع خطی در لایه خروجی استفاده شده است. از قاعده‌ی آموزش لونیبرگ مارکوات<sup>۸</sup> به دلیل سرعت همگرایی بالا در این تحقیق استفاده گردید (صیادی و همکاران، ۱۳۸۸). بهینه‌سازی لایه پنهان به روش سعی و خطا انجام گردید (Jain et al., 2008). نرون‌های مختلفی به روش سعی و خطا مورد آزمون قرار گرفتند. افزایش نرون‌ها اثر چشمگیری بر کاهش خطای شبکه نداشت. برای جلوگیری از بزرگتر شدن ساختار شبکه نرون بهینه در هر حالت انتخاب گردید.

R: ضریب همبستگی<sup>۱</sup> که هر چه این شاخص به یک نزدیک‌تر باشد، نشان دهنده‌ی همبستگی بالای مدل می‌باشد.

## نتایج و بحث

تحلیل اولیه آماری روی داده‌ها به کمک نرم افزار SPSS16.0 انجام و داده‌های پرت حذف گردیدند. سپس مدل‌ها تجربی برای هر دو ایستگاه به صورت روزانه محاسبه گردیدند.

برای طراحی شبکه عصبی مصنوعی وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. از آنجایی که هر کدام از پارامترها تقسیم‌بندی‌های مربوط به خودشان را دارند، بنابراین برای یکسان کردن دامنه تغییرات آنها، عمل نرمال‌سازی داده‌ها صورت می‌گیرد تا از کوچک شدن بیش از حد وزن‌های شبکه جلوگیری شود (Kisi et al., 2008). برای همین منظور با استفاده از رابطه‌ی (۱۳) اقدام به نرمال سازی داده‌ها گردید.

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (13)$$

$x_n$ : مقدار نرمالیز شده

X: مقدار هر متغیر ورودی

$x_{min}$ : منییم داده‌ی ورودی

$x_{max}$ : ماکزیمم داده‌ی ورودی

ورودی مدل‌ها، دمای حداکثر و دمای حداقل، ساعات آفتابی، سرعت باد در ارتفاع دو متری و رطوبت نسبی میانگین در شرایط مختلف، حداقل داده‌ی اقلیمی می‌باشند. مدل پنمن مونتیت فائو به دلیل نبود داده‌های لایسیمیتری به عنوان خروجی مدل‌ها در نظر گرفته شد. در این تحقیق از شبکه‌های پیشخور استفاده گردیده است. این شبکه‌ها در مطالعات هیدرولوژی کاربرد گسترده‌ای دارند (Kumar et al., 2011). داده‌ها به دو گروه ۷۵ درصد

<sup>2</sup>- Training

<sup>3</sup>- Validation

<sup>4</sup>- Testing

<sup>5</sup>- Active function

<sup>6</sup>- Tansig

<sup>7</sup>- Logsig

<sup>8</sup>- Levenberg-Marquardt

<sup>1</sup> - Correlation Coefficient

جدول (۲): نتایج آنالیزهای آماری مدل‌های تجربی

مدل‌های تجربی	RMSE*		MAE**		R***
	فرودگاه	فرخشهر	فرودگاه	فرخشهر	فرخشهر
هارگریوز	۰/۹۰	۰/۹۳۹	۰/۶۴	۰/۶۹۸	۰/۹۰
پرستلی تیلور	۰/۹۵۲	۰/۸۵۹	۰/۶۸۷	۰/۶۴۰	۰/۹۲۷
بلانی کریدل	۱/۰۷	۰/۹۹۲	۰/۸۵	۰/۸۱۵	۰/۹۰۸
جنسن هیز	۱/۷۱۲	۱/۷۹۲	۱/۳۶۳	۱/۴۰۴	۰/۸۹۳

\* مجذور میانگین مربعات خطا

\*\* میانگین مطلق خطا

\*\*\* ضریب همبستگی

جدول (۳): نتایج مدل شبکه عصبی ایستگاه فرودگاه با تابع تانزانت سیگموئید در لایه پنهان

سناریو (داده ورودی)	RMSE*		MAE**		R***
	آموزش	تست	آموزش	تست	تست
$ET_0 = F(T_{max}, T_{min}, RH_{mean}, n, U_2)$	۰/۲۸۰۱	۰/۲۹۷۵	۰/۲۱۶۵	۰/۲۳۱۱	۰/۹۹۸۰
$ET_0 = F(T_{max}, T_{min}, RH_{mean}, U_2)$	۰/۴۷۴۷	۰/۴۶۱۴	۰/۳۸۳۲	۰/۳۷۷۱	۰/۹۹۵۲
$ET_0 = F(T_{max}, T_{min}, RH_{mean}, n)$	۰/۷۲۰۴	۰/۶۸۴۲	۰/۵۳۰۵	۰/۵۲۵۵	۰/۹۸۹۴
$ET_0 = F(T_{max}, T_{min}, U_2, n)$	۰/۳۳۱۲	۰/۳۴۰۴	۰/۲۵۰۷	۰/۲۵۳۴	۰/۹۹۷۴
$ET_0 = F(T_{max}, T_{min}, RH_{mean})$	۰/۸۲۶۲	۰/۸۰۵۱	۰/۶۱۸۱	۰/۶۲۷۲	۰/۹۸۵۳
$ET_0 = F(T_{max}, T_{min}, U_2)$	۰/۵۶۸۵	۰/۵۳۸۶	۰/۴۵۲۲	۰/۴۳۰۳	۰/۹۹۳۴
$ET_0 = F(T_{max}, T_{min}, n)$	۰/۷۷۸۱	۰/۷۳۸۵	۰/۵۸۲۵	۰/۵۷۳۹	۰/۹۸۷۵
$ET_0 = F(RH_{mean}, U_2, n)$	۰/۹۱۶۳	۰/۹۶۸	۰/۶۸۹۶	۰/۷۲۱۹	۰/۹۷۹۹
$ET_0 = (T_{max}, T_{min})$	۰/۹۴۳۸	۰/۹۲۰۳	۰/۷۲۸۶	۰/۷۴۳۰	۰/۹۸۰۵
$ET_0 = (T_{max})$	۱/۰۰۱	۰/۹۷۶۲	۰/۷۵۷۸	۰/۷۸۵۵	۰/۹۷۸۰

\* مجذور میانگین مربعات خطا

\*\* میانگین مطلق خطا

\*\*\* ضریب همبستگی

جدول (۴): نتایج مدل شبکه عصبی ایستگاه فرودگاه با تابع لوگ سیگموئید در لایه پنهان

سناریو (داده ورودی)	RMSE*		MAE**		R***
	آموزش	تست	آموزش	تست	تست
$ET_0 = F(T_{max}, T_{min}, RH_{mean}, n, U_2)$	۰/۲۸۵۵	۰/۳۰۸۵	۰/۲۲۱۸	۰/۲۳۸۰	۰/۹۹۷۸
$ET_0 = F(T_{max}, T_{min}, RH_{mean}, U_2)$	۰/۴۷۵	۰/۳۸۴۸	۰/۳۷۷۶	۰/۳۸۴۸	۰/۹۹۵۱
$ET_0 = F(T_{max}, T_{min}, RH_{mean}, n)$	۰/۷۱۵۲	۰/۶۸۱۱	۰/۵۲۹۰	۰/۵۱۹۸	۰/۹۸۹۴
$ET_0 = F(T_{max}, T_{min}, U_2, n)$	۰/۳۳۴۷	۰/۳۴۵۵	۰/۲۵۳۲	۰/۲۵۵۵	۰/۹۹۷۳
$ET_0 = F(T_{max}, T_{min}, RH_{mean})$	۰/۸۲۹۰	۰/۸۰۴۹	۰/۶۲۰۸	۰/۶۲۵۳	۰/۹۸۵۴
$ET_0 = F(T_{max}, T_{min}, U_2)$	۰/۵۶۲۰	۰/۵۴۳۰	۰/۴۴۸۴	۰/۴۴۳۵	۰/۹۹۳۳
$ET_0 = F(T_{max}, T_{min}, n)$	۰/۷۶۵۳	۰/۷۴۰۱	۰/۵۷۷۷	۰/۵۷۱۸	۰/۹۸۷۶
$ET_0 = F(RH_{mean}, U_2, n)$	۰/۹۰۳۱	۰/۹۵۸۳	۰/۶۸۱۷	۰/۷۱۳۹	۰/۹۷۹۸
$ET_0 = (T_{max}, T_{min})$	۰/۹۵۰۳	۰/۹۲۹۴	۰/۷۳۴۰	۰/۷۴۸۶	۰/۹۸۰۱
$ET_0 = (T_{max})$	۰/۹۹۰۷	۰/۹۷۴۳	۰/۷۴۴	۰/۷۸۱۱	۰/۹۷۸۵

\* مجذور میانگین مربعات خطا

\*\* میانگین مطلق خطا

\*\*\* ضریب همبستگی



جدول (۵): نتایج مدل شبکه عصبی ایستگاه فرخشهر با تابع تانزانت سیگموئید در لایه پنهان

R***		MAE**		RMSE*		سناریو
تست	آموزش	تست	آموزش	تست	آموزش	سناریو (داده ورودی)
۰/۹۹۷۳	۰/۹۹۷۳	۰/۲۶۰۹	۰/۲۴۰۴	۰/۳۳۸	۰/۳۱۷۸	$ET_0 = F(T_{max}, T_{min}, RH_{mean}, n, U_2)$
۰/۹۹۴۸	۰/۹۹۳۶	۰/۳۹۴۳	۰/۳۹۲۶	۰/۴۷۳۶	۰/۴۸۷۴	$ET_0 = F(T_{max}, T_{min}, RH_{mean}, U_2)$
۰/۹۸۷۹	۰/۹۸۲۷	۰/۵۶۲۲	۰/۶۰۸۴	۰/۷۲۵	۰/۸۰۲۹	$ET_0 = F(T_{max}, T_{min}, RH_{mean}, n)$
۰/۹۹۶۶	۰/۹۹۶۷	۰/۳۰	۰/۲۷	۰/۳۸۱۱	۰/۳۴۹	$ET_0 = F(T_{max}, T_{min}, U_2, n)$
۰/۹۸۲۷	۰/۹۷۷۲	۰/۶۶۲۴	۰/۷۱۰۴	۰/۸۵۳۰	۰/۹۱۹۵	$ET_0 = F(T_{max}, T_{min}, RH_{mean}, U_2)$
۰/۹۹۲۴	۰/۹۹۲۰	۰/۴۷۰۹	۰/۴۴۳۷	۰/۵۷۰۳	۰/۵۴۷۵	$ET_0 = F(T_{max}, T_{min}, U_2)$
۰/۹۸۶۵	۰/۹۸۱۹	۰/۶۱۵۶	۰/۶۲۲۰	۰/۷۷۴۶	۰/۸۱۹۹	$ET_0 = F(T_{max}, T_{min}, n)$
۰/۹۷۵۰	۰/۹۷۵۶	۰/۷۷۷۵	۰/۷۲۲۴	۱/۰۳۴	۰/۹۵۰۷	$ET_0 = F(RH_{mean}, U_2, n)$
۰/۹۷۹۲	۰/۹۷۴۶	۰/۷۵۳۶	۰/۷۵۷۶	۰/۹۴۲۴	۰/۹۶۸۸	$ET_0 = (T_{max}, T_{min})$
۰/۹۷۵۵	۰/۹۶۹۷	۰/۸۱۷۲	۰/۸۲۵۰	۱/۰۱۴۵	۱/۰۵۷۸	$ET_0 = (T_{max})$

\* مجذور میانگین مربعات خطا

\*\* میانگین مطلق خطا

\*\*\* ضریب همبستگی


جدول (۶): نتایج مدل شبکه عصبی ایستگاه فرخشهر با تابع لوگ سیگموئید در لایه پنهان

R***		MAE**		RMSE*		سناریو (داده ورودی)
تست	آموزش	تست	آموزش	تست	آموزش	
۰/۹۹۷۲	۰/۹۹۷۲	۰/۲۷۴۷	۰/۲۵۱۴	۰/۳۴۲۲	۰/۳۲۵۳	$ET_0 = F(T_{max}, T_{min}, RH_{mean}, n, U_2)$
۰/۹۹۴۷	۰/۹۹۳۴	۰/۴۰۰۵	۰/۴۰۳۳	۰/۴۷۷۶	۰/۴۹۵۳	$ET_0 = F(T_{max}, T_{min}, RH_{mean}, U_2)$
۰/۹۸۶۹	۰/۹۸۱۵	۰/۵۸۹۸	۰/۶۳۱۳	۰/۷۵۵	۰/۸۲۹۰	$ET_0 = F(T_{max}, T_{min}, RH_{mean}, n)$
۰/۹۹۶۵	۰/۹۹۶۸	۰/۳۰۱۶	۰/۲۶۴۷	۰/۳۸۷۲	۰/۳۴۴۶	$ET_0 = F(T_{max}, T_{min}, U_2, n)$
۰/۹۸۳۶	۰/۹۷۷۷	۰/۶۳۳۹	۰/۶۴۹	۰/۸۳	۰/۹۰۸۳	$ET_0 = F(T_{max}, T_{min}, RH_{mean}, U_2)$
۰/۹۹۲۲	۰/۹۹۱۹	۰/۴۷۹۲	۰/۴۴۴۹	۰/۵۷۸۱	۰/۵۴۸۷	$ET_0 = F(T_{max}, T_{min}, U_2)$
۰/۹۸۶۶	۰/۹۸۱۸	۰/۶۱۱۱	۰/۶۲۵۴	۰/۷۷۲۳	۰/۸۲۱۳	$ET_0 = F(T_{max}, T_{min}, n)$
۰/۹۷۸۲	۰/۹۷۷۸	۰/۷۴۲۹	۰/۶۸۷۵	۰/۹۸۱۹	۰/۹۰۷۰	$ET_0 = F(RH_{mean}, U_2, n)$
۰/۹۷۹۲	۰/۹۷۴۷	۰/۷۵۵۳	۰/۷۵۶۵	۰/۹۴۳۰	۰/۹۶۸۳	$ET_0 = (T_{max}, T_{min})$
۰/۹۷۶	۰/۹۷	۰/۸۱۳	۰/۸۲۲۸	۱/۰۱	۱/۰۰۹	$ET_0 = (T_{max})$


\* مجذور میانگین مربعات خطا

\*\* میانگین مطلق خطا

\*\*\* ضریب همبستگی



شکل (۲): پراکنش تبخیر و تعرق سناریو یک شبکه عصبی با تابع تانژانت سیگموئید در برابر روش پنمن مونتیث فائو، ایستگاه فرخ شهر



شکل (۳): انطباق عملکرد سناریو یک شبکه عصبی با تابع تانژانت سیگموئید در برابر مدل پنمن مونتیث فائو ایستگاه فرخ شهر

حداقل و حداکثر، رطوبت ساعات آفتابی و سرعت باد در ارتفاع دو متری، دقت بیشتری نسبت به دیگر سناریوها داشتند، ولی سناریو شش می‌تواند به عنوان بهینه‌ترین سناریو انتخاب گردد، زیرا از متغیرهای کمتری استفاده نموده و در مقایسه با سناریوهایی که از متغیرهای بیشتری استفاده کرده‌اند، قابل مقایسه است. سناریوی نه با دو ورودی دمای حداکثر و حداقل در شرایطی که داده‌های دیگر موجود نباشند، تبخیر و تعرق را با دقت قابل قبولی برآورد می‌کند (جداول ۳ و ۴ و ۵ و ۶). روند تغییرات مدل‌ها در ایستگاه فرودگاه مشابه ایستگاه فرخشهر می‌باشد، ولی دقت مدل‌ها در این ایستگاه کمی بیشتر است. همانطور که از (شکل ۳) مشخص است، شبکه عصبی، تبخیر و تعرق را نسبت به مدل پنمن مونتیت فائو کمتر برآورد می‌کند. با توجه به خطای هر یک از سناریوها و آنالیز حساسیت، پنج متغیر ورودی دمای حداکثر و سرعت باد بیشترین اثر و رطوبت نسبی میانگین کمترین تاثیر را بر تبخیر و تعرق این منطقه دارند. با توجه به عدم دسترسی به آمار و داده‌های مورد نیاز در برآورد تبخیر و تعرق و عدم اندازه‌گیری بعضی از این داده‌های مورد نیاز در بیشتر ایستگاه‌ها، مدل‌های هوشمند راهکار مناسب-تری نسبت به روش‌های تجربی در شرایط عدم وجود اطلاعات کافی می‌باشند. نتایج این تحقیق با تحقیقات (احمدزاده قرگوز و همکاران، ۱۳۸۹)، (سلطانی همکاران، ۱۳۹۱) و (نوری و همکاران، ۱۳۹۲) همخوانی دارد.

### نتیجه‌گیری

تبخیر و تعرق یک پدیده غیرخطی و پیچیده بوده و عوامل بسیار زیادی در تخمین این پدیده دخالت دارند که امکان اندازه‌گیری این پارامترها در همه‌ی ایستگاه‌ها میسر نیست. یکی از روش‌های اندازه‌گیری این پارامتر، لایسیمتر است که هزینه‌بر و زمان زیادی لازم دارد. لذا اندازه‌گیری تبخیر و تعرق به کمک داده‌های اقلیمی رایج‌تر است. در این تحقیق ابتدا چهار روش تجربی هارگریوز، پریستلی تیلور،

با توجه به معیارهای ارزیابی محاسبه شده و با در نظر گرفتن تمام معیارهای ارزیابی عملکرد به طور همزمان، از بین مدل‌های تجربی، مدل‌های پریستلی تیلور و هارگریوز عملکرد بهتر و مدل جنسن هیز ضعیف‌ترین عملکرد را داشتند (جدول ۲). نتایج مدلسازی تبخیر و تعرق با شبکه عصبی مصنوعی نشان داد که دو تابع تانژانت سیگموئید و لوگ سیگموئید در لایه‌ی پنهان، دقت بالایی برای مدلسازی این پدیده دارند. در بین سناریوهای طراحی شده، سناریوی یک با پنج متغیر ورودی با تابع لوگ سیگموئید، بیشترین همبستگی و کمترین خطا را برای ایستگاه فرودگاه  $RMSE=0.3085$  و برای ایستگاه فرخشهر  $RMSE=0.3422$  داشت. همچنین با بکارگیری تابع تانژانت سیگموئید مقدار  $RMSE=0.2975$  در ایستگاه بدست آمد که این مقدار در ایستگاه فرخشهر برابر  $RMSE=0.3380$  نتیجه و محاسبه گردید. برای بررسی تاثیر میزان پارامترهای ورودی بر میزان تبخیر و تعرق، از روش حذف متغیر ورودی استفاده شده است. به این ترتیب که ابتدا مدل را با کل داده‌های ورودی اجرا و سپس با حذف یکی از پارامترها مجدداً مدل اجرا گردید. پارامتری که بیشترین تاثیر را بر  $RMSE$  دارد، به عنوان حساس‌ترین پارامتر و پارامتری که حذف آن کمترین اثر را بر  $RMSE$  دارد، به عنوان کم اثرترین پارامتر در نظر گرفته شد (شایان نژاد و همکاران، ۱۳۸۷). با حذف متغیرهای ورودی، از دقت مدل‌ها کاسته شده و خطای مدل‌ها بیشتر شده است. در بین سناریوها با چهار متغیر ورودی، سناریو چهار با چهار متغیر ورودی دمای حداکثر و دمای حداقل، سرعت باد و ساعات آفتابی، بیشترین همبستگی و کمترین خطا را در مقایسه با روش پنمن مونتیت فائو دارد. در بین سناریوهای با سه متغیر ورودی، سناریوی شش، با سه متغیر ورودی دمای حداقل، دمای حداکثر و سرعت باد، بیشترین همبستگی و کمترین خطا را با روش پنمن مونتیت فائو داشت. اگرچه سناریو یک با هر پنج متغیر ورودی و سناریو چهار با چهار متغیر دمای

پارامترها، با دقت مطلوب به محاسبه‌ی این پدیده پردازیم. نتایج آنالیز حساسیت در این منطقه نشان داد که در بین پنج متغیر ورودی دمای حداکثر و سرعت باد بیشترین تاثیر و رطوبت نسبی میانگین، کمترین اثر را بر تبخیر و تعرق این منطقه دارد. برای برآورد دقیق تبخیر و تعرق در این منطقه به داده‌های دما و سرعت باد نیاز است.

### تقدیر و تشکر

در پایان این تحقیق از مدیریت محترم اداره‌ی کل هواشناسی استان چهارمحال و بختیاری به خاطر در اختیار گذاشتن داده‌های این تحقیق صمیمانه تشکر می‌گردد.

بلانی کریدل و جنسن هیز، در یک دوره ده ساله و به صورت روزانه مورد تحلیل قرار گرفتند. برای ارزیابی مدل‌ها از روش پنمن مونتیث فائو ۵۶ استفاده گردید. نتایج نشان داد که مدل پرستلی تیلور و هارگریوز عملکرد بهتری دارند و مدل جنسن هیز عملکرد ضعیف‌تری دارد. سپس به طراحی شبکه عصبی تحت سناریوهای مختلف داده‌ی ورودی پرداخته شد. نتایج نشان داد که هر دو تابع تانژانت سیگموئید و لوگ سیگموئید دقت قابل قبولی در تخمین این پدیده دارند. در بین سناریوهای طراحی شده، سناریو یک با تمام داده‌های ورودی، بهترین همبستگی و کمترین خطا را با روش پنمن مونتیث فائو داشت. هدف از این تحقیق این است که در شرایط نبود و فقدان داده برای برآورد تبخیر و تعرق مرجع، با داشتن موثرترین

### منابع

- احمدزاده قره‌گویز، م. میرلطیفی، ک. محمدی. ۱۳۸۹. مقایسه‌ی سیستم‌های هوش مصنوعی (ANN و ANFIS) در تخمین میزان تبخیر- تعرق مرجع در مناطق بسیار خشک ایران، نشریه آب و خاک. جلد ۲۴، شماره‌ی ۴. ص ۶۷۹-۶۸۹.
- دهقانی، ا.ا.، م. پیری، م. حسام، ن. دهقانی. 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، ص ۴۹-۶۷.
- سلطانی، ا.، م. میرلطیفی، ح. دهقانی سانج. ۱۳۹۱. برآورد تبخیر و تعرق با استفاده از داده‌های محدود هواشناسی در شرایط اقلیمی مختلف. نشریه آب و خاک. جلد ۲۶، شماره ۱. ص ۱۳۹-۱۴۹.
- شایان نژاد، م. ۱۳۸۵. مقایسه دقت روش‌های شبکه‌های عصبی مصنوعی و پنمن-مانتیس در محاسبه تبخیر و تعرق پتانسیل. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی. دانشگاه شهید چمران اهواز.
- شایان نژاد، م.، ح. ساداتی نژاد. ۱۳۸۷. تخمین تبخیر و تعرق پتانسیل روزانه گیاه مرجع چمن با استفاده از شبکه عصبی مصنوعی. مجله‌ی علمی پژوهشی مرتع، سال ۲، شماره‌ی ۲. ص ۱۹۴-۱۸۲.
- صیادی، ح.، ا. اولاد غفاری، ا. فعالیان، ع. صدرالدینی. ۱۳۸۸. مقایسه‌ی برآورد شبکه‌های MLP و RBF در برآورد تبخیر و تعرق مرجع. مجله‌ی دانش آب و خاک. جلد ۱۹، شماره‌ی ۱. ص ۱-۱۲.
- علیزاده، ا. ۱۳۸۳. رابطه‌ی آب و خاک و گیاه. مشهد، دانشگاه امام رضا. ویرایش ۳.
- منهاج، م. ب. ۱۳۸۱. مبانی شبکه‌های عصبی و هوش محاسباتی، جلد اول، انتشارات دانشگاه صنعتی امیر کبیر، تهران.

نوری، س.، غ. فلاحتالهری، ح. ثنایی نژاد. ۱۳۹۲. مدل سازی تبخیر- تعرق گیاه پتانسیل با استفاده از شبکه عصبی مصنوعی با حداقل متغیرهای اقلیمی در ایستگاه سینوپتیک مشهد. نشریه پژوهش‌های حفاظت آب و خاک، جلد ۲۰، شماره ۵. ص ۱۶۳-۱۷۸.

هژبر، ح.، ه. معاضد، س. شکری کوچک. ۱۳۹۳. برآورد تبخیر و تعرق مرجع با استفاده از مدل‌های تجربی، مدل‌سازی آن با شبکه عصبی مصنوعی و مقایسه با داده‌های لایسیمیتری در ایستگاه کهریزک ارومیه. فصلنامه علمی و پژوهشی مهندسی آبیاری و آب. سال ۴. شماره ۱۶. ص ۱۳-۲۵.

Allen, R. G., L. S. Pereira, D. Raes and M. Smith. 1998. Crop Evapotranspiration - Guidelines for Computing Crop Water Requirements. FAO Irrigation and Drainage Paper 56.

Benediktsson, J. A., P. H., Swain and O. K. Erosy. 1990. Neural network approaches versus statistical methods in classification of multisource remote Sensing data. IEEE Transaction on Geosciences and Remote Sensing, 28(4): 540-551.

Chow, V. T., D. R., Maidment, and L.W., Mays, 1988. Applied Hydrology, illustrate. ed. McGraw-Hill Higher Education, New York, NY.

Civco, D. L., and Y. Wanug. 1994. Classification of multispectral, multitemporal, multisource Spatial data using artificial neural networks, Congress on Surveying and Mapping. USA.

Falamarzi, Y. N. palizdan, Y. feng Hung and T. shui lee. 2014. Estimating evapotranspiration from temperature and wind speed data using artificial and wavelet neural networks (WNNs). Agricultural Water Management 140 : 26-36

Hargreaves, G. H. and Z. A., Samani. 1985. Reference crop evapotranspiration from temperature. Transaction of ASAE 1(2):96-99.

Huo Z. S. Feng Kang and X. Dai. 2012. Artificial neural network models for reference evapotranspiration in an arid area of northwest China. Journal of Arid Environments 82 : 81-90.

Jain S. K, P. C, Nayak, K. P, Sudhir. 2008. Models for estimating evapotranspiration using artificial neural networks, and their physical interpretation. Hydrol Process 22(13):2225-2234

Kisi, O. 2008. River flow forecasting and estimation using different artificial neural network techniques, Hydrol. Res. 39: 1. 27-40.

Kumar, M., A., Bandyopadhyay, N. S., Raghuwanshi, R., Singh. 2008. Comparative study of conventional and artificial neural network-based ETo estimation mod-els. Irrig. Sci. 26, 531-545.

Kumar, M., N. S. , Raghuwanshi, R, Singh. 2011. Artificial neural networks approach in evapotranspiration modeling: a review. Irrig Sci 29:11-25.

Ladlani, I., L., Houichi, L., Djemili, S., Heddami and K., Belouz, 2012. Modeling daily reference evapotranspiration (ET<sub>0</sub>) in the north of Algeria using generalized regression neural networks (GRNN) and radial basis function neural networks (RBFNN): a comparative study. Meteorol. Atmos. Phys. 118, 163-178.

Priestley, C. H. B. and R. J. Taylor. 1972. On the assessment of surface heat and evaporation using large-scale parameters, Monthly Weather Review, 100: 81-92.

Penman, H. L. 1948. Natural evaporation from open water, bare soil and grass. Proc. R. Soc. London, Ser. A Math. Phys. Sci. 193, 120-145.

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

Wang, Y. M, S. Traore, and T. Kerh. 2008. Neural network approach for estimating reference evapotranspiration from limited climatic data in Burkina Faso. WSEAS Transactions on Computers. 7: 704-713.

## Empirical and intelligence Models Evaluation in Estimation of Reference Evapotranspiration by Minimum Climate Data; case study shahrekord

Hosseini Seyed MohammadReza<sup>1</sup>, Ganji Khorramdel Naser<sup>2</sup>, Khelatabadi Farahani Amir Hossein<sup>3</sup>

### Abstract

The water resources are severely affected by hydrological cycle. Estimation of evapotranspiration which is the main component of the hydrological cycle plays an important role in water resources management. This phenomenon is non-linear and many factors affect on that and its estimation is very difficult. Various methods have been employed to estimate evapotranspiration although they have some limitations or problems. Some of these methods are costly and time-consuming such as lysimeters, and other empirical methods have local authority. Accordingly, applying a method that can be able to model the evapotranspiration regard to the nature of the gathered data and usage of minimum climate parameters is necessary. Nowadays, Artificial Neural Network (ANN) as a novel intelligent method are used in various sciences. In this study, the daily data of two climatological stations, namely Farokhshahr and Shahrekord airport in the interval of 2004-2013 including minimum temperature, maximum temperature, average relative humidity, sunshine, and wind speed at the height of two meters under different scenarios were utilized. Initially, empirical methods of reference evapotranspiration were approximated. The used empirical methods in this research have been Hargreaves, Blyny Criddle, Priestley Taylor, and Jensen Hayes. The ANN model has been designed based on different scenarios of input data through MATLAB (R2012 b) Software. In this step, different ANN architectures were evaluated based on sensitivity and accuracy. So, threshold functions such as tangent sigmoid and log sigmoid in hidden layers, linear function output layer were tested in topology where as Levenberg Marquardt employed as learning function. To evaluate the models, Penman Monteis FAO 56 model was employed. The statistical indexes, namely RMSE, MAE and R were calculated. Ten scenarios have been examined, and the results demonstrated that Scenario one with five parameters had the lowest error in comparison to FAO 56 technique. Furthermore, the proposed model show superior performance than empirical methods. However, between the empirical methods, Priestley Taylor and Hargreaves had better performance. On the other hand, the sensitivity analysis illustrated that the maximum temperature and wind speed had the greatest influence on reference evapotranspiration in these regions.

**Keywords:** Artificial Neural Network (ANN), cold-Arid Region, Empirical Methods, MATLAB, Reference Evapotranspiration.

<sup>1</sup> MSc. Student, Department of Water Engineering, Faculty of Agriculture, Arak University, mohammad.mrh2015@gmail.com

<sup>2</sup> Assistant Professor, Department of Water Engineering, Faculty of Agriculture, Arak University, Naser.GanjiKhorramdel@gmail.com

<sup>3</sup> Assistant Professor, Department of Animal Science, Faculty of Agriculture, Arak University, a-farahani@araku.ac.ir