


پیش‌بینی تبخیر-تعرق مرجع با استفاده از شبکه‌های عصبی مصنوعی MLP و RBF، SVM

سهیلا پناهی، مسعود کرباسی و جعفر نیکبخت



دوره ۲، شماره ۱، بهار ۱۳۹۵، صفحات: ۶۳-۵۱

www.jewe.ir

نحوه ارجاع به این مقاله: پناهی س. کرباسی م. و نیکبخت ج. (۱۳۹۵). پیش‌بینی تبخیر-تعرق مرجع با استفاده از شبکه‌های عصبی مصنوعی SVM، MLP و RBF، محیط‌زیست و مهندسی آب، جلد ۲، شماره ۱، صفحات: ۶۳-۵۱

How to cite this paper: Panahi S., Karbasi M. and Nikbakht J. (2016). Forecasting of reference evapotranspiration using MLP, RBF and SVM neural networks, J. Environ. Water Eng. 2(1), 51-63

پیش‌بینی تبخیر-تعرق مرجع با استفاده از شبکه‌های عصبی مصنوعی SVM، RBF، و MLP

سهیلا پناهی^{۱*}، مسعود کرباسی^۲ و جعفر نیکبخت^۳

۱- دانشجوی کارشناسی ارشد آبیاری و زهکشی، دانشگاه زنجان، زنجان، ایران

۲- استادیار، گروه مهندسی آب، دانشگاه زنجان، زنجان، ایران

۳- دانشیار، گروه مهندسی آب، دانشگاه زنجان، زنجان

*نویسنده مسئول: soheilapanahi@znu.ac.ir

تاریخ پذیرش: [۱۳۹۵/۰۳/۱۹]

تاریخ دریافت: [۱۳۹۴/۱۲/۱۶]

چکیده

تخمین تبخیر-تعرق گیاه مرجع یکی از مهم‌ترین مؤلفه‌ها در بهینه‌سازی مصرف آب کشاورزی و مدیریت منابع آب است. پیش‌بینی تبخیر-تعرق مرجع روزانه و هفتگی می‌تواند در پیش‌بینی نیاز آبی گیاهان و برنامه‌ریزی کوتاه‌مدت آبیاری مورد استفاده قرار گیرد. هدف از این تحقیق، ارزیابی عملکرد سه نوع شبکه عصبی مصنوعی MLP (پرسترون چندلایه)، RBF (شبکه تابع پایه‌ای شعاعی)، SVM (ماشین بردار پشتیبان) در پیش‌بینی تبخیر-تعرق مرجع روزانه و هفتگی در ایستگاه همدیدی تبریز است. برای این منظور از داده‌های هواشناسی با دوره آماری ۳۹ ساله (۲۰۰۹-۱۹۷۱) استفاده شد. برای آموزش شبکه‌های عصبی ۸۰ درصد سری‌های زمانی ایجاد شده به تصادف انتخاب و ۲۰ درصد داده‌ها برای صحت‌سنجی مدل‌های پیشنهادی به کار رفتند. برای ایجاد سری زمانی تبخیر-تعرق مرجع روزانه و هفتگی در دوره مورد نظر با استفاده از معادله استاندارد پنمن-مانتیث فائو ۵۶ محاسبه گردید. ترکیب‌های متفاوتی از داده‌های ورودی (تأخیرهای مختلف) مورد ارزیابی قرار گرفت. نتایج مربوط به پیش‌بینی روزانه شبکه‌های عصبی نشان داد شبکه عصبی مصنوعی SVM-RBF kernel با تأخیر زمانی M5 دارای RMSE و R^2 به ترتیب برابر با ۰/۵۱ میلی‌متر در روز و ۰/۹۲ بهترین عملکرد را داشت. همچنین نتایج مربوط به پیش‌بینی هفت‌روزه نشان داد که شبکه عصبی MLP با تأخیر زمانی M8 دارای RMSE و R^2 به ترتیب برابر با ۳/۸۸ میلی‌متر در هفته و ۰/۹۵ دارای بیش‌ترین دقت بودند.

واژه‌های کلیدی: تبریز، سری‌های زمانی، شبکه‌های عصبی مصنوعی، روش پنمن-مانتیث، نیاز آبی گیاهان

۱- مقدمه

فرآیند تبخیر-تعرق از اساسی‌ترین اجزای چرخه هیدرولوژی است. تخمین دقیق مقدار تبخیر-تعرق برای انجام بسیاری از تحقیقات، ضروری و از مهم‌ترین مسائل در طرح‌های آبیاری و زهکشی و منابع آب به شمار می‌رود. در فرآیند تبخیر-تعرق عوامل مختلف طبیعی (خاک، گیاه و اتمسفر) و انسانی وجود دارد که در اندرکنش با یکدیگرند و با توجه به عدم امکان اندازه‌گیری دقیق تمام پارامترها، به‌کارگیری مدل‌های تجربی و یا شبکه‌های عصبی مصنوعی با ساختاری مشابه مغز، قابل توجیه و مقرون‌به‌صرفه است. در ساختار شبکه عصبی مصنوعی با معرفی عملکرد یک سیستم دینامیکی و آموزش آن، عملکرد سیستم در مقایسه با شرایط واقعی سنجیده می‌شود. شبکه‌های عصبی مصنوعی می‌توانند با حداقل تعداد متغیرهای مستقل اندازه‌گیری شده و پیش‌بینی مناسبی از متغیرهای وابسته را با دقت قابل قبول ارائه دهند (Zare Abyaneh et al. 2009). با استفاده از روش‌های ذکرشده، می‌توان سری زمانی آینده تبخیر-تعرق مرجع را پیش‌بینی نمود تا بتوان پیش‌بینی مناسبی برای منابع آب موردنیاز در آینده انجام داد (Fooladmand, 2010). استفاده از مدل‌های سری زمانی در پیش‌بینی تبخیر-تعرق مرجع در مقیاس‌های زمانی ماهیانه و هفتگی توسط پژوهشگران مختلف موردبررسی و تحقیق قرار گرفته است. Ghahreman و Gharakhani (2011) توانمندی مدل‌های آریمای در برآورد مقادیر روزانه تبخیر از تشت در ایستگاه شیراز مورد مطالعه قرار دادند. نتایج مطالعه آن‌ها نشان داد که مدل سری زمانی $ARIMA(1,1,1)$ عملکرد بسیار بهتری نسبت به سایر مدل‌های $ARIMA$ دارد. (Dodangeh et al. 2012). کاربرد مدل‌های سری زمانی را به‌منظور تعیین روند پارامترهای اقلیمی از جمله درصد رطوبت، تبخیر، دمای هوا، سرعت با دو تعداد ساعات آفتابی در آینده برای اصفهان مورد ارزیابی قرار دادند و در نهایت مدل آریمای برای پیش‌بینی پارامترهای یادشده استفاده کردند. (Behmanesh et al. 2014). مدل‌های سری زمانی خطی را به همراه مدل غیرخطی دوسویه^۱ در پیش‌بینی مقادیر ماهانه تبخیر-تعرق در ایستگاه همدیدی ارومیه مورد مقایسه قرار دادند. نتایج آن‌ها نشان داد که مدل غیرخطی دوسویه توانایی بیشتری در مدل‌سازی و پیش‌بینی مقادیر ماهانه تبخیر-تعرق گیاه مرجع در مقایسه با مدل خطی را داراست. یکی از مشکلات مدل سری زمانی $SARIMA$ در پیش‌بینی داده‌های با مقیاس روزانه این است که طول فصل ۳۶۵ روز است و در اکثر موارد مدل نمی‌تواند همگرا شود، در نتیجه در عمل استفاده از مدل‌های سری زمانی در پیش‌بینی روزانه تبخیر-تعرق مرجع امکان‌پذیر نیست (Bachour et al. 2015).

در زمینه‌ی کاربرد مدل‌های هوش مصنوعی در برآورد تبخیر-تعرق مرجع تحقیقات متعددی صورت گرفته است (Kisi, 2008; Tabari et al. 2010). حال آنکه کاربرد مدل‌های هوش مصنوعی در پیش‌بینی مقادیر آینده تبخیر-تعرق مرجع کم‌تر مورد توجه قرار گرفته و تحقیقات محدودی در این زمینه وجود دارد. (Trajkovic et al. 2003). استفاده از شبکه‌های عصبی نوع RBF^2 اقدام به پیش‌بینی مقادیر تبخیر-تعرق مرجع ماهیانه نمودند. آن‌ها در تحقیق خود از تأخیرهای زمانی یک و دوساله استفاده نمودند. نتایج نشان داد که شبکه عصبی نوع RBF قادر است میزان تبخیر-تعرق مرجع ماهیانه را با اطمینان بالایی پیش‌بینی کند. (Landeras et al. 2009). استفاده از شبکه‌های عصبی مصنوعی، تبخیر-تعرق مرجع هفتگی را پیش‌بینی کردند. آن‌ها در تحقیق خود از دو نوع شبکه عصبی مصنوعی RBF^3 و MLP^3 با تأخیرهای زمانی ۱، ۲، ۳ و ۴ هفته و ۱، ۲، ۳ و ۴ ساله استفاده نمودند. نتایج آن‌ها نشان داد که شبکه‌های عصبی مصنوعی قادرند با دقت بالایی مقادیر هفتگی تبخیر-تعرق مرجع را پیش‌بینی کنند. (Luo et al. 2014). روشی برای پیش‌بینی ET_0 برای هفت روز آینده بر اساس داده‌های پیش‌بینی دما و مدل هارگریوز-سامانی استفاده کردند. سپس میزان پیش‌بینی شده ET_0 با میزان محاسبه شده آن را با مدل PM در چهار ایستگاه در نقاط مختلف چین با آب‌وهوای متفاوت مقایسه کردند. نتایج نشان داد دقت پیش‌بینی درجه حرارت بر اساس پیش‌بینی آب‌وهوای عمومی به‌طور کلی بالا و خطا در حداقل پیش‌بینی درجه حرارت کم‌تر از خطا در حداکثر پیش‌بینی درجه حرارت است و ضریب همبستگی

1- bilinear

2-Radial Basis Function

3- Multi-Layer Perceptron

بین مشاهده شده و پیش‌بینی شده درجه حرارت در همه ایستگاه‌ها بیش‌تر از ۰/۹۴ بود. نتایج آن‌ها همچنین نشان داد منابع خطا به‌طور عمده در دمای پیش‌بینی است. با این واقعیت که مدل هارگریوز-سامانی تنها حداقل و حداکثر درجه حرارت و سرعت باد و یا رطوبت در نظر می‌گیرد. با توجه به اهمیت پیش‌بینی تبخیر-تعرق مرجع در برنامه‌ریزی کوتاه‌مدت آبیاری و بهره‌برداری از کانال‌ها و مخازن، در تحقیق حاضر سه مدل شبکه عصبی مصنوعی (MLP، RBF و SVM) برای پیش‌بینی کوتاه‌مدت تبخیر-تعرق مرجع روزانه و هفتگی در ایستگاه همدیدی تبریز مورد استفاده قرار گرفتند و عملکرد مدل‌ها با یکدیگر مقایسه گردید.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

در مطالعه حاضر از اطلاعات هواشناسی ایستگاه همدیدی تبریز استفاده گردید. این ایستگاه دارای طول جغرافیایی $46^{\circ}17'$ و عرض جغرافیایی $38^{\circ}5'$ است. شهرستان تبریز با وسعت 2167 Km^2 (۴۸/۸ درصد مساحت استان)، مرکز استان آذربایجان شرقی بوده و ارتفاع تقریبی آن از سطح دریا 1350 m است. آب و هوای تبریز در زمستان‌ها بسیار سرد و در تابستان‌ها خشک و گرم است. ضمن اینکه حرارت به دلیل نزدیکی به کوه سهند و وجود باغ‌های فراوان در پیرامون شهر تعدیل می‌گردد.

۲-۲- داده‌های هواشناسی مورد استفاده

به‌منظور انجام تحقیق، ابتدا اطلاعات هواشناسی ایستگاه تبریز به‌صورت روزانه، شامل دمای کمینه، دمای بیشینه، سرعت باد در ارتفاع دو متری، رطوبت نسبی کمینه، رطوبت نسبی بیشینه و ساعات آفتابی با طول دوره آماری ۳۹ ساله (۱۹۷۱-۲۰۰۹) از سازمان هواشناسی کشور اخذ و استفاده گردید. سپس تبخیر-تعرق گیاه مرجع با استفاده از معادله پنمن-مانتیت به‌عنوان یک روش استاندارد در مقیاس‌های روزانه و هفتگی محاسبه گردید. در مرحله بعد با استفاده از روش شبکه‌های عصبی مصنوعی، در نرم‌افزار MATLAB، تبخیر-تعرق مرجع روزانه و هفتگی با ایجاد تأخیرهای زمانی مختلف پیش‌بینی گردید.

۲-۳- معادله پنمن-مانتیت

به‌منظور برآورد مقدار ET_0 از روش پنمن-مانتیت از معادله (۱) استفاده گردید (Allen et al. 1998):

$$ET_0 = \frac{0.408\Delta(R_n - G)}{\Delta + \gamma(1 + 0.34u)} + \frac{900\gamma}{[\Delta + \gamma(1 + 0.34u)]} \cdot \frac{uD}{(T + 273)} \quad (1)$$

در رابطه بالا ET_0 ، تبخیر تعرق مرجع (mm/day)، T متوسط دمای هوا در ارتفاع ۲ متری از سطح زمین ($^{\circ}\text{C}$)، G شار گرما به داخل خاک ($\text{MJm}^{-2}\text{d}^{-1}$)، U_2 میانگین سرعت باد در ارتفاع دو متری، e_s فشار بخار اشباع (kpa)، e_a فشار بخار واقعی (kpa)، $e_s - e_a$ کمبود فشار بخار اشباع (kpa)، Δ شیب منحنی فشار بخار ($\text{kpa}^{\circ}\text{C}^{-1}$)، γ ضریب ثابت سایکرومتری ($\text{kg}^{\circ}\text{kkj}^{-1}\text{day}^{-1}$) و R_e تابش خالص ورودی به سطح گیاه ($\text{MJm}^{-2}\text{d}^{-1}$) می‌باشند.

۲-۴- روش شبکه عصبی مصنوعی

شبکه عصبی عبارت است از یک سیستم انطباقی که تعدادی عناصر پردازش ساده را شامل می‌شود که از شبکه اعصاب مغز الگو برداری شده است. شبکه‌های عصبی مصنوعی مانند مغز انسان عمل کرده و ساختاری شبیه به آن دارند. مغز به‌عنوان یک سیستم پردازش اطلاعات از عناصر اصلی ساختاری به نام نرون تشکیل شده است. شبکه‌های عصبی علی‌رغم تنوع از ساختار مشابهی برخوردار می‌باشند. یک شبکه عصبی معمولاً از سه لایه ورودی^۱، پنهان^۱ و خروجی^۲ تشکیل شده است (Najafi و

Tarazkar, 2006). در تحقیق حاضر شبکه‌های عصبی MLP، RBF و SVM برای پیش‌بینی تبخیر-تعرق به کار گرفته شدند که شرح مختصری از آن‌ها در ذیل ارائه می‌گردد.

۲-۵- شبکه عصبی MLP

در حالت کلی، شبکه‌های MLP شامل سه لایه ورودی، پنهان و خروجی بوده که در هر لایه تعدادی واحد پردازشگر به نام نرون وجود دارد. هر نرون، خروجی وزن دار شده از نرون قبلی را دریافت کرده و از یک تابع فعال‌سازی یا آستانه عبور می‌دهد. این توابع می‌توانند از انواع مختلف مانند سیگموئیدی، گوسی، خطی و باینری باشند. مبنای آموزش این شبکه‌ها، تغییر وزن اتصالات به منظور رسیدن به خروجی مطلوب است (Ellis et al. 1995).

۲-۶- شبکه عصبی RBF

تفاوت اساسی شبکه‌های شعاع مبنا RBF با شبکه‌های پرسپترون چندلایه، در بردار ورودی و تابع محرک است. در شبکه‌های RBF، ابتدا بردار فاصله میان بردار وزن و بردار ورودی به کمک یک ضرب اسکالر محاسبه می‌شود. سپس بردار حاصل در بردار بایاس ضرب و حاصل ضرب آن به عنوان بردار ورودی شبکه در نظر گرفته می‌شود (Chen et al. 1991). شبکه‌های عصبی RBF معمولاً دارای سه لایه هستند: یک لایه ورودی، یک لایه مخفی با توابع محرک غیرخطی RBF و یک لایه خروجی خطی. به دلیل طولانی بودن روابط ریاضی این نوع شبکه عصبی، از ارائه روابط صرف نظر شده و خوانندگان در صورت نیاز می‌توانند به Hayking (1999) مراجعه کنند.

۲-۷- شبکه عصبی SVM

یکی از قوی‌ترین طبقه‌بندی‌ها در حوزه یادگیری ماشین، ماشین بردار پشتیبان SVM است که با یافتن نقاط حاشیه بین دو کلاس، این کلاس‌ها را از یکدیگر جدا می‌کند. SVM ماشین بردار پشتیبان به اطلاعات ساختاری و پیشین درون کلاس داده، توجهی ندارد و بیش‌تر توجه آن بر روی جداسازی بین کلاس‌هاست. یکی از الگوریتم‌هایی که بر روی اطلاعات ساختاری توجه نموده، الگوریتم S-TWSVM که از دو ابر صفحه (دو مدل) برای تشخیص کلاس داده‌ی جدید، استفاده می‌کند. به صورتی که هر مدل، فقط اطلاعات ساختاری یک کلاس را در نظر می‌گیرد و با دور شدن از کلاس دیگر، به این کلاس موردنظر نزدیک‌تر می‌شود. در الگوریتم فوق کلیه نقاط کلاس موردنظر با درج اهمیت یکسانی بررسی می‌شود، درحالی‌که ممکن است تعدادی از نقاط آن کلاس از درجه اهمیت بیش‌تر و تعدادی از آن‌ها نویز باشند که درجه اهمیت پایینی داشته باشند. الگوریتم پیشنهادی با وزن دهی به نقاط نواحی متراکم، توجه الگوریتم به این نقاط را بیش‌تر و با وزن دهی کم‌تر به نقاط پرت و نویز، اهمیت این نقاط کم‌تر می‌نماید به طوری که دقت الگوریتم افزایش می‌یابد. اطلاعات ساختاری داده‌ها، زیرمجموعه‌های از دانش و اطلاعات پیشین است. ماشین بردار پشتیبان به عنوان یکی از بهترین طبقه‌بندی‌های موجود در زمینه یادگیری ماشین نسبت به توزیع داده‌ها اهمیتی قائل نمی‌شود (Hayking, 1999).

۲-۸- ورودی‌های مدل

در تحقیق حاضر برای پیش‌بینی تبخیر-تعرق مرجع روزانه هشت الگو با ترکیبات مختلف از تأخیرهای زمانی، به مدل‌های MLP، RBF و SVM معرفی گردید (Landeras et al. 2009). جدول (۱) ترکیب‌های مختلف ورودی را نشان می‌دهد.

جدول ۱- مدل‌های ورودی به شبکه‌های عصبی برای پیش‌بینی تبخیر-تعرق روزانه

| متغیر خروجی (Output variable) | متغیرهای ورودی (Input variables) | مجموعه ورودی (Input set) |
|----------------------------------|---|--------------------------------|
| ET_t | ET_{t-1} | M1 |
| ET_t | ET_{t-1}, ET_{t-2} | M2 |
| ET_t | $ET_{t-1}, ET_{t-2}, ET_{t-3}$ | M3 |
| ET_t | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-365}$ | M4 |
| ET_t | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-365}, ET_{t-730}$ | M5 |
| ET_t | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-365}, ET_{t-730}, ET_{t-1095}$ | M6 |
| ET_t | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-365}, ET_{t-730}, ET_{t-1095}, ET_{t-1460}$ | M7 |
| ET_t | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-365}, ET_{t-730}, ET_{t-1095}, ET_{t-1460}, ET_{t-1830}$ | M8 |

برای پیش‌بینی تبخیر-تعرق مرجع هفتگی نیز ۹ الگو با ترکیب‌های مختلف داده‌های ورودی مورد استفاده قرار گرفت که جدول (۲) ورودی‌ها را برای پیش‌بینی هفتگی نشان می‌دهد (Landeras et al. 2009).

جدول ۲- مدل‌های ورودی به شبکه‌های عصبی برای پیش‌بینی تبخیر-تعرق هفتگی

| مجموعه ورودی Input set | متغیرهای ورودی Input variables | متغیر خروجی Output variable |
|---------------------------|---|--------------------------------|
| M1 | ET_{t-1} | ET_t |
| M2 | ET_{t-1}, ET_{t-2} | ET_t |
| M3 | $ET_{t-1}, ET_{t-2}, ET_{t-3}$ | ET_t |
| M4 | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}$ | ET_t |
| M5 | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-52}$ | ET_t |
| M6 | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-52}, ET_{t-104}$ | ET_t |
| M7 | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-52}, ET_{t-104}, ET_{t-156}$ | ET_t |
| M8 | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-52}, ET_{t-104}, ET_{t-156}, ET_{t-208}$ | ET_t |
| M9 | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-52}, ET_{t-104}, ET_{t-156}, ET_{t-208}, ET_{t-260}$ | ET_t |

سری‌های زمانی تبخیر-تعرق مرجع روزانه و هفتگی با استفاده از معادله پنمن-مانتیت در ایستگاه همدیدی تبریز ایجاد گردید. در مرحله دوم سری‌های زمانی ایجاد شده، ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد برای صحت‌سنجی شبکه‌های عصبی MLP، SVM و RBF به کار برده شد.

۲-۹- شاخص‌های آماری

به منظور بررسی صحت نتایج خروجی که در واقع بیان‌کننده اختلاف داده‌های مشاهداتی و محاسباتی است، از معیارهای متفاوتی استفاده می‌گردد. در مطالعه حاضر برای مقایسه مدل‌ها از دو شاخص آماری ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE) و میانگین خطای اریبی (MBE) استفاده گردید. این شاخص‌ها به صورت معادله‌های (۲) تا (۴) بیان می‌شوند:

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

$$R^2 = \frac{\left(\sum_{i=1}^N (O_i - \bar{O}_i)(P_i - \bar{P}_i) \right)^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2 \sum_{i=1}^N (P_i - \bar{P}_i)^2} \quad (3)$$

$$MBE = \frac{1}{N} \sum_{i=1}^N (O_i - P_i) \quad (4)$$

در روابط (۲)، تا (۴) پارامتر O_i مقادیر تبخیر-تعرق مرجع محاسبه شده از معادله پنمن-مانتیث و P_i مقادیر پیش‌بینی شده از مدل‌های مختلف، \bar{O}_i و \bar{P}_i به ترتیب میانگین مقادیر تبخیر-تعرق مرجع معادله پنمن-مانتیث و پیش‌بینی و N تعداد داده‌ها می‌باشند.

۳- یافته‌ها و بحث

۳-۱- پیش‌بینی تبخیر-تعرق مرجع روزانه

جدول (۳) نتایج پیش‌بینی تبخیر-تعرق مرجع روزانه را با استفاده از مدل شبکه عصبی MLP نشان می‌دهد. برای یافتن شبکه عصبی بهینه MLP و تعیین نرون‌ها در لایه پنهان از روش آزمون و خطا استفاده شد. آموزش و آزمون شبکه با تعداد نرون‌ها (لایه پنهان) از ۳ شروع و تا ۲۰ ادامه یافت. برای آموزش شبکه‌های عصبی مصنوعی پرسپترون چندلایه به‌طور معمول از الگوریتم پس انتشار خطا، استفاده گردید. در الگوبندی با استفاده از شبکه‌های عصبی مصنوعی از قانون آموزش لونبرگ مارکوات، به دلیل سرعت و دقت بالا، یک لایه پنهان و تعداد تکرار ۱۰۰۰۰ استفاده شد. توابع فعال‌سازی تانژانت هیپربولیک و خطی به ترتیب در لایه پنهان و خروجی مورد استفاده قرار گرفت. نرمال‌سازی داده‌ها نیز با استفاده از توابع آماده نرم‌افزار MATLAB انجام و داده به بازه ۰ تا ۱ مقیاس تبدیل شدند. نتایج نشان داد که کم‌ترین مقدار RMSE (۰/۷۱۸ میلی‌متر بر روز) در داده‌های صحت‌سنجی زمانی حاصل می‌گردد که تعداد نرون در لایه پنهان، ۷ باشد. با توجه به جدول (۳)، کم‌ترین میزان خطای RMSE (۰/۷۱۸ میلی‌متر بر روز) و بیش‌ترین مقدار ضریب تبیین R^2 (۰/۹۶۱) در الگوی M7 به‌دست آمده. پس از الگوی M7، الگوی M8 دارای کم‌ترین خطا است. در دو الگوی ذکر شده علاوه بر تأخیرهای روزانه از تأخیرهای ۱، ۲، ۳، ۴ و ۵ سال استفاده شد. نتیجه حاصله نشان‌دهنده این مطلب است که استفاده از تاریخچه سری زمانی موجب بهبود عملکرد مدل می‌گردد.

جدول ۳- مقادیر معیارهای ارزیابی در الگوهای ورودی و خروجی از تأخیرهای زمانی به شبکه MLP

| الگوهای ورودی به شبکه MLP | | | | | | | | معیارهای ارزیابی | ایستگاه |
|---------------------------|-------|-------|--------|-------|---------|--------|--------|---------------------|---------|
| M8 | M7 | M6 | M5 | M4 | M3 | M2 | M1 | | |
| ۰/۹۵۷ | ۰/۹۶۱ | ۰/۹۵۶ | ۰/۹۵۸ | ۰/۹۱۸ | ۰/۹۵۴ | ۰/۹۵۱ | ۰/۹۵۲ | R2 | |
| ۰/۷۵۲ | ۰/۷۱۸ | ۰/۷۶۹ | ۰/۷۵۳ | ۰/۷۷۴ | ۰/۷۸۵ | ۰/۸۲۳ | ۰/۸۱۲ | RMSE | تبریز |
| -۰/۰۳۶ | ۰/۰۱۹ | ۰/۰۰۲ | -۰/۰۱۴ | ۰/۰۰۳ | -۰/۰۰۰۴ | -۰/۰۰۳ | -۰/۰۳۰ | MBE | |

جدول (۴) نتایج پیش‌بینی تبخیر-تعرق مرجع روزانه را با استفاده از شبکه‌های عصبی RBF نشان می‌دهد. در شبکه عصبی RBF مورد استفاده در تحقیق حاضر از ۵۰ نرون در لایه پنهان استفاده گردید. با توجه به جدول (۴) بهترین نتیجه برای پیش‌بینی تبخیر-تعرق مرجع با استفاده از الگوی M3 به‌دست آمده است. پس از الگوی M3، الگوهای M4 و M2 نتایج بهتری را ارائه نمودند. نتایج شبکه عصبی RBF نشان‌دهنده این نکته است که تأخیرهای سالانه (استفاده از تاریخچه سری زمانی) نه تنها موجب افزایش دقت نشده، بلکه موجب کاهش آن نیز شده است. میزان خطای RMSE از مدل M3 (۰/۷۰۷) به ۰/۸۲۷ در مدل M8، افزایش یافت.

جدول ۴- مقادیر معیارهای ارزیابی در پیش‌بینی تبخیر-تعرق روزانه با الگوهای ورودی به شبکه RBF

| الگوهای ورودی به شبکه RBF | | | | | | | | معیارهای ارزیابی | ایستگاه |
|---------------------------|-------|-------|--------|-------|--------|--------|-------|---------------------|---------|
| M8 | M7 | M6 | M5 | M4 | M3 | M2 | M1 | | |
| ۰/۹۱۰ | ۰/۹۰۲ | ۰/۹۰۱ | ۰/۹۰۵ | ۰/۹۱۸ | ۰/۹۱۹ | ۰/۹۱۵ | ۰/۹۱۳ | R2 | |
| ۰/۸۲۷ | ۰/۸۱۱ | ۰/۷۸۲ | ۰/۷۵۸ | ۰/۷۱۸ | ۰/۷۰۷ | ۰/۷۲۶ | ۰/۷۳۳ | RMSE | تبریز |
| ۰/۱۰۶ | ۰/۰۹۶ | ۰/۱۰۹ | -۰/۰۷۹ | ۰/۰۷۲ | -۰/۰۱۹ | -۰/۰۱۸ | ۰/۰۲۴ | MBE | |

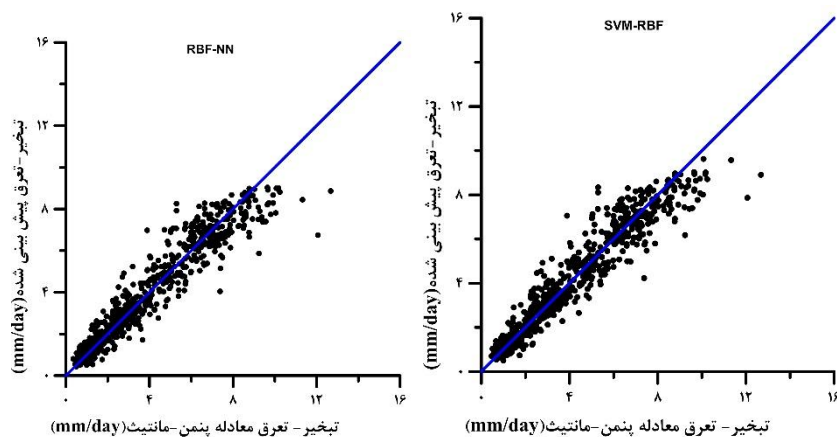
نتایج پیش‌بینی تبخیر-تعرق مرجع روزانه را با استفاده از شبکه عصبی ماشین بردار پشتیبان SVM در جدول (۵) ارائه شده است. در مدل SVM از سه نوع کرنل خطی Lin، چندجمله‌ای Poly و توابع بر پایه شعاعی RBF استفاده گردید. با توجه به جدول (۵) در مدل SVM با کرنل خطی، الگوهای M3 و M4 بهترین نتیجه را برای پیش‌بینی تبخیر-تعرق مرجع روزانه ارائه نمود. در مدل SVM با کرنل بر پایه توابع شعاعی نیز بهترین نتیجه در الگوی M4 و در مدل SVM با کرنل چندجمله‌ای، در الگوهای M3 و M4 به دست آمده. مقایسه بین کرنل‌های مختلف نشان داد که کم‌ترین خطا در کرنل RBF با الگوی ورودی M4 است. نتایج به دست آمده از مدل SVM نشان‌دهنده این است که در این مدل استفاده از تأخیرهای سالانه موجب افزایش خطا گردیده است. مقایسه بین شبکه‌های عصبی مختلف نشان می‌دهد که شبکه عصبی SVM با کرنل RBF با الگوی ورودی M4 کم‌ترین خطا (RMSE=۰/۵۱ mm/day) را داشت. شکل (۱) نمودارهای پراکندگی مقادیر مشاهداتی و پیش‌بینی شده حاصل از بهترین الگوها (SVM-RBF-M4 و RBF-M3) را نشان می‌دهد. نزدیک بودن نقاط به خط نیمساز نشان‌دهنده عملکرد بهتر مدل‌ها در پیش‌بینی است.

۳-۲- پیش‌بینی تبخیر-تعرق هفتگی با شبکه عصبی MLP، RBF و SVM

جدول (۶) نتایج پیش‌بینی تبخیر-تعرق مرجع هفتگی را با استفاده از مدل شبکه عصبی MLP نشان می‌دهد. با توجه به جدول (۶) کم‌ترین مقدار RMSE در داده‌های صحت‌سنجی زمانی حاصل می‌گردد که تعداد نرون در لایه پنهان، چهار باشد. با توجه به جدول کم‌ترین میزان خطای RMSE و بیش‌ترین مقدار ضریب تبیین در الگوی M6 (RMSE=۳/۸۱ و $R^2=۰/۹۵$) به دست آمد. پس از الگوی M6، الگوی M5 و M8 دارای کم‌ترین خطا است. در دو الگوی ذکر شده علاوه بر تأخیرهای هفتگی از تأخیرهای ۱، ۲، ۳ و ۴ سال استفاده شده است. نتیجه حاصله نشان‌دهنده این مطلب است که استفاده از تاریخچه سری زمانی موجب بهبود عملکرد مدل می‌گردد. (Landeras et al. (2009 تبخیر-تعرق مرجع هفتگی را با استفاده از دو مدل ARIMA و شبکه عصبی مصنوعی در شمال اسپانیا پیش‌بینی نمودند. نتایج Landeras et al. (2009 نشان داد که استفاده از تأخیرهای سالانه موجب افزایش دقت مدل‌های می‌گردد که مطابق با نتایج تحقیق حاضر است. برخلاف پیش‌بینی هفتگی، نتایج تحقیق حاضر در پیش‌بینی‌های روزانه نشان داد که استفاده از تأخیرهای زمانی سالانه موجب کاهش دقت پیش‌بینی‌های روزانه می‌گردد.

جدول ۵- مقادیر معیارهای ارزیابی در پیش‌بینی تبخیر-تعرق روزانه با الگوهای ورودی به شبکه SVM

| الگوهای ورودی به شبکه SVM | | | | | | | | معیارهای ارزیابی | ایستگاه | |
|---------------------------|--------|--------|--------|--------|--------|--------|--------|---------------------|--------------|-------|
| M8 | M7 | M6 | M5 | M4 | M3 | M2 | M1 | | | |
| ۰/۹۱۸ | ۰/۹۱۰ | ۰/۹۰۶ | ۰/۹۰۸ | ۰/۹۱۷ | ۰/۹۱۸ | ۰/۹۱۲ | ۰/۹۰۹ | R2 | SVM- Lin | تبریز |
| ۰/۷۹۵ | ۰/۷۷۴ | ۰/۷۶۰ | ۰/۷۴۲ | ۰/۷۱۹ | ۰/۷۱۳ | ۰/۷۳۸ | ۰/۷۵۱ | RMSE | | |
| -۰/۱۲۶ | -۰/۰۸۹ | -۰/۰۸۹ | -۰/۰۶۱ | -۰/۰۶۵ | -۰/۰۱۴ | -۰/۰۱۶ | -۰/۰۱۹ | MBE | | |
| ۰/۹۱۸ | ۰/۹۰۹ | ۰/۹۰۵ | ۰/۹۰۸ | ۰/۹۱۸ | ۰/۹۱۸ | ۰/۹۱۵ | ۰/۹۱۲ | R2 | SVM- RBF | تبریز |
| ۰/۷۹۱ | ۰/۷۷۵ | ۰/۷۶۵ | ۰/۷۴۳ | ۰/۵۰۹ | ۰/۷۱۲ | ۰/۷۲۷ | ۰/۷۳۸ | RMSE | | |
| -۰/۱۰۲ | -۰/۰۶۸ | -۰/۰۷۵ | -۰/۰۷۴ | -۰/۰۵۸ | -۰/۰۲۴ | -۰/۰۲۶ | -۰/۰۳۰ | MBE | | |
| ۰/۹۱۸ | ۰/۹۱۰ | ۰/۹۰۶ | ۰/۹۰۸ | ۰/۹۱۹ | ۰/۹۴۹ | ۰/۹۱۴ | ۰/۹۰۷ | R2 | SVM- PLOY | تبریز |
| ۰/۷۹۵ | ۰/۷۷۵ | ۰/۷۶۱ | ۰/۷۳۹ | ۰/۷۱۳ | ۰/۷۰۹ | ۰/۷۲۸ | ۰/۷۶۲ | RMSE | | |
| -۰/۱۲۶ | -۰/۰۸۹ | -۰/۰۹۲ | -۰/۰۶۳ | -۰/۰۶۶ | -۰/۰۲۳ | -۰/۰۱۶ | ۰/۰۷۲ | MBE | | |



شکل ۱- پراکندگی مقادیر تبخیر-تعرق مرجع روزانه محاسباتی از معادله پنمن-مانتیت و پیش‌بینی شده از شبکه‌های SVM-RBF-M4 و RBF-M3

جدول ۶- مقادیر الگوهای ورودی از تأخیرهای زمانی هفتگی به شبکه MLP

| الگوهای ورودی به شبکه MLP | | | | | | | | معیارهای ارزیابی | ایستگاه | |
|---------------------------|--------|--------|--------|-------|--------|-------|-------|---------------------|---------|--|
| M8 | M7 | M6 | M5 | M4 | M3 | M2 | M1 | | | |
| ۰/۹۵۳ | ۰/۹۵۱ | ۰/۹۵۰ | ۰/۹۵۱ | ۰/۹۳۸ | ۰/۹۱۳ | ۰/۹۲۹ | ۰/۹۳۵ | R2 | تبریز | |
| ۳/۸۸۰ | ۴/۱۷۹ | ۳/۸۱۰ | ۳/۸۷۹ | ۶/۱۱۸ | ۵/۷۰۳ | ۵/۰۵۹ | ۴/۵۵۴ | RMSE | | |
| -۰/۴۰۱ | -۰/۴۰۱ | -۰/۰۳۴ | -۰/۳۱۷ | ۳/۳۲۹ | -۰/۳۶۳ | ۱/۶۹۵ | ۰/۲۵۶ | MBE | | |

جدول (۷) نتایج پیش‌بینی تبخیر-تعرق مرجع هفتگی را با استفاده از شبکه‌های عصبی RBF نشان می‌دهد. با توجه به جدول (۷) بهترین نتیجه برای پیش‌بینی تبخیر-تعرق مرجع با استفاده از الگوی M7 به دست آمده است. پس از الگوی M7، الگوی M8 نتایج بهتری را ارائه نموده است. نتایج حاصل از شبکه عصبی RBF نیز نشان‌دهنده این مطلب است که استفاده از تاریخچه سری زمانی

می‌تواند موجب افزایش دقت مدل در پیش‌بینی تبخیر-تعرق مرجع هفتگی شود.


جدول ۷- مقادیر الگوهای ورودی از تأخیرهای زمانی هفتگی به شبکه RBF

| الگوهای ورودی به شبکه RBF | | | | | | | | معیارهای ارزیابی | ایستگاه |
|---------------------------|-------|-------|--------|--------|--------|--------|--------|---------------------|---------|
| M8 | M7 | M6 | M5 | M4 | M3 | M2 | M1 | | |
| ۰/۹۵۶ | ۰/۹۵۵ | ۰/۹۴۹ | ۰/۹۵۰ | ۰/۹۴۰ | ۰/۳۲۷ | ۰/۳۲۴ | ۰/۹۳۳ | R2 | |
| ۳/۹۶۵ | ۳/۹۳۰ | ۴/۱۳۴ | ۴/۰۸۵۳ | ۴/۵۳۷ | ۴/۸۰۶ | ۴/۸۱۶ | ۴/۷۹۰ | RMSE | تبریز |
| ۰/۲۸۶ | ۰/۱۸۵ | ۰/۲۱۶ | ۰/۰۱۳ | -۰/۰۲۵ | -۰/۱۳۹ | -۰/۱۱۳ | -۰/۰۶۲ | MBE | |

جدول (۸) نتایج پیش‌بینی تبخیر-تعرق مرجع هفتگی را با استفاده از شبکه عصبی ماشین بردار پشتیبان (SVM) نمایش می‌دهد. با توجه به جدول (۸) در مدل SVM با کرنل خطی، الگوهای M₇ و M₈ بهترین نتیجه را برای پیش‌بینی تبخیر-تعرق مرجع هفتگی ارائه نمودند. در مدل SVM با کرنل بر پایه توابع شعاعی نیز بهترین نتیجه در الگوهای M₇ و M₈ در مدل SVM با کرنل چندجمله‌ای، در الگوهای M₇ و M₈ به دست آمد. نتایج به دست آمده از مدل SVM حاکی از آن است که در این مدل استفاده از تأخیرهای سالانه موجب کاهش خطا گردیده است. مقایسه بین شبکه‌های عصبی مختلف نشان داد که شبکه عصبی SVM با کرنل PLOY، با الگوهای ورودی M₇ و M₈ کم‌ترین خطا (RMSE= 3.905 mm/day و RMSE= 3.946 mm/day) و پس از کرنل PLOY، مدل SVM با کرنل RBF با الگوهای ورودی M₇ و M₈ کم‌ترین خطا را داراست. نتایج تحقیق حاضر نشان داد که در حالت کلی مدل SVM دارای دقت بالاتری نسبت به سایر شبکه‌های عصبی مورد استفاده در این تحقیق (MLP و RBF) است. Guo et al. (2011) نیز نشان دادند که مدل SVM در مقایسه با MLP دارای دقت بالاتری در پیش‌بینی جریان ماهانه است. نتایج مشابه در پیش‌بینی جریان ماهانه رودخانه توسط Kishi و Kalteh et al. (2013) و Cimen (2011) نیز گزارش شده است. همچنین Yoon et al. (2011) در پیش‌بینی سطح آب زیرزمینی، Dibike et al. (2001) در مدل‌سازی بارش-رواناب و Eslamian et al. (2008) در تخمین تبخیر از تشت تبخیر نیز برتری مدل SVM را بر سایر شبکه‌های عصبی مصنوعی گزارش نموده‌اند. مقایسه بین کرنل‌های مختلف در مدل SVM نشان داد که دو کرنل RBF و POLY دارای عملکرد بهتری هستند که نتیجه فوق در مدل‌سازی متغیرهای هیدرولوژیکی توسط Raghavendra و Paresh (2014) نیز گزارش شده است. شکل (۲) نمودار پراکندگی مقادیر مشاهداتی و پیش‌بینی شده حاصل از بهترین الگوها (SVM-POLY-M₈ و MLP-M₆) را برای پیش‌بینی هفتگی نشان می‌دهد. نزدیک بودن نقاط به خط نیمساز نشان‌دهنده عملکرد بهتر مدل‌ها در پیش‌بینی است.

جدول ۸- مقادیر الگوهای ورودی از تأخیرهای زمانی هفتگی به شبکه SVM

| الگوهای ورودی به شبکه SVM | | | | | | | | معیارهای ارزیابی | ایستگاه |
|---------------------------|-------|-------|--------|--------|--------|--------|--------|---------------------|---------|
| M8 | M7 | M6 | M5 | M4 | M3 | M2 | M1 | | |
| ۰/۹۵۷ | ۰/۹۵۶ | ۰/۹۵۱ | ۰/۹۵۱ | ۰/۹۴۱ | ۰/۹۳۴ | ۰/۹۳۳ | ۰/۹۳۳ | R2 | تبریز |
| ۴/۰۰۲ | ۴/۰۴۲ | ۴/۱۲۷ | ۴/۲۳۷ | ۴/۶۵۸ | ۴/۸۵۹ | ۴/۸۶۹ | ۴/۸۶۲ | RMSE | |
| ۰/۳۲۴ | ۰/۲۱۷ | ۰/۱۹۵ | -۰/۰۰۸ | ۰/۰۳۴ | -۰/۰۰۷ | -۰/۰۶۸ | -۰/۰۴۲ | MBE | |
| ۰/۹۴۱ | ۰/۹۴۲ | ۰/۹۴۰ | ۰/۹۳۵ | ۰/۹۱۹ | ۰/۹۱۵ | ۰/۹۱۳ | ۰/۹۱۲ | R2 | تبریز |
| ۳/۹۶۴ | ۳/۹۳۰ | ۴/۱۳۴ | ۴/۰۸۵ | ۴/۵۳۷ | ۴/۸۰۹ | ۴/۸۱۶ | ۴/۷۹۱ | RMSE | |
| ۰/۴۰۵ | ۰/۲۰۰ | ۰/۱۲۰ | -۰/۰۶۸ | -۰/۲۴۰ | -۰/۲۷۰ | -۰/۲۹۵ | -۰/۳۰۵ | MBE | |
| ۰/۹۵۶ | ۰/۹۵۴ | ۰/۹۵۰ | ۰/۹۴۹ | ۰/۹۴۰ | ۰/۹۳۴ | ۰/۹۳۲ | ۰/۹۳۳ | R2 | تبریز |
| ۳/۹۰۵ | ۳/۹۴۶ | ۴/۰۷۲ | ۴/۱۱۴ | ۴/۵۲۸ | ۴/۷۴۸ | ۴/۸۲۰ | ۷/۷۹۴ | RMSE | |
| ۰/۳۲۸ | ۰/۲۰۴ | ۰/۱۹۷ | ۰/۰۱۴ | ۰/۰۱۵ | -۰/۰۲۷ | -۰/۱۱۹ | -۰/۰۶۲ | MBE | |



شکل ۲- پراکندگی مقادیر تبخیر-تعرق مرجع هفتگی محاسباتی از معادله پنمن-مانتیث و پیش‌بینی شده از شبکه‌های SVM-POLY-M8 و MLP-M6

۴- نتیجه‌گیری

پیش‌بینی تبخیر-تعرق مرجع و نیاز آبی گیاهان مختلف می‌تواند در مدیریت منابع آب کشور مورد استفاده قرار گیرد. در تحقیق حاضر عملکرد سه نوع مدل شبکه عصبی MLP، RBF و SVM در پیش‌بینی تبخیر-تعرق مرجع در مقیاس زمانی روزانه و هفتگی در ایستگاه همدیدی تبریز مورد ارزیابی قرار گرفت. نتایج این تحقیق نشان داد که سه مدل مورد بررسی در این تحقیق قادر هستند با دقت بالایی تبخیر-تعرق روزانه و هفتگی را پیش‌بینی کنند. در پیش‌بینی‌های روزانه در مدل شبکه عصبی MLP، جهت افزایش دقت مدل نیاز است که از تأخیرهای سالانه استفاده شود، در حالی که در مدل‌های RBF و SVM تأخیرهای سالانه موجب افزایش خطا می‌گردند. در دو مدل RBF و SVM تأخیرهای تا سه روز بهترین نتیجه را ارائه نمودند. از میان سه مدل مورد مطالعه مدل RBF با الگوی ورودی M3 بیشترین دقت را ارائه نمود. نتایج مربوط به پیش‌بینی‌های هفتگی نشان می‌دهد در مدل شبکه عصبی MLP، RBF و SVM جهت افزایش دقت مدل‌ها نیاز است که از تأخیرهای سالانه استفاده شود. از میان سه مدل مورد مطالعه مدل شبکه عصبی MLP با تأخیر زمانی M8 بیشترین دقت را ارائه نمود. از نتایج تحقیق حاضر می‌توان در برنامه‌ریزی آبیاری و استفاده بهینه آب در مناطق مورد مطالعه استفاده نمود. پیشنهاد می‌گردد، مدل پیشنهادی تحقیق حاضر در اقلیم‌های مختلف ایران مورد بررسی قرار بگیرد.

References

- Allen R. G., Pereira L. S., Raes D. and Smith M. (1998). Crop evapotranspiration guideline for computing crop water requirements, FAO, Irrigation and Drainage Paper, No. 56, Rome.
- Bachour R., Maslova I., Ticlavilca A., Walker W. and McKee M. (2015). Wavelet-multivariate relevance vector machine hybrid model for forecasting daily evapotranspiration. Stochastic Environ. Res. Risk Assess., 29(2), 1-15.
- Behmanesh J., Azad Talatapeh N., Montaseri M. and Besharat S. (2014). Evaluation of linear and bilinear time series models in predicting of reference crop evapotranspiration at Urmia synoptic station. J. Wat. Res. Agricul., 28(1), 85-96 [In Persian].

- Chen S., Cowan C. and Grant P. M. (1991). Orthogonal least squares learning algorithm for radial basis function networks, *UIEEE Trans. Neural Networks*, 2(2), 302-309.
- Dibike Y., Velickov S., Solomatine D. and Abbott M. (2001). Model induction with support vector machines: introduction and applications. *J. Comput. Civ. Eng.*, 15(3), 208-216.
- Dodangeh S., Abedi Koupai J. and Gohari S. A (2012). application of time series modeling to investigate future climatic parameters trend for water resources management purposes. *J. Wat. Soil Sci.*, 59(16), 59-74 [In Persian].
- Ellis G. W., Yao C., Zhao R. and Penumadu D. (1995). Stress-strain modeling of sands using artificial neural networks. *J. Geotec. Eng., ASCE*, 121(5), 429-435.
- Eslamian S. S., Gohari S. A., Biabankai M. and Malekian R. (2008). estimation of monthly pan evaporation using artificial neural networks and support vector machines. *J. Appl. Sci.*, 19(8), 3497-3502.
- Fooladmand H. R. (2010). Monthly prediction of reference crop evapotranspiration in Fars Province. *J. Wat. Soil Sci.*, 20(1), 158-169 [In Persian].
- Ghahreman N. and Gharekhani A. (2011). Evaluation of stochastic time series models in prediction of pan evaporation. *J. Wat. Res. Agricul.*, 25(1), 75-81. [In Persian].
- Guo J., Zhou J., Qin H., Zou Q. and Li Q. (2011). Monthly stream flow forecasting based on improved support vector machine model, *Expert Sys. Appl.*, 38 (10), 13073-13081.
- Hayking S. (1999) *Neural networks: A comprehensive foundation*, 2nd Ed. Prentice-Hall, N. J.
- Kalteh A. M. (2013). Monthly river flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform, *Comp. Geosci.*, 54(4), 1-8.
- Kisi O. (2010). Wavelet regression model for short-term stream flow forecasting. *J. Hydrol.*, 389(3), 344-353.
- Kisi O. and Cimen M. (2011). A wavelet-support vector machine conjunction model for monthly streamflow forecasting. *J. Hydrol.*, 399(1-2), 132-140.
- Kisi O. (2008). The potential of different ANN techniques in evapotranspiration modeling. *Hydrol.Proc.*, 22(14), 2449-2460.
- Landeras G., Ortiz-Barredo A. and Javier Lopez J. (2009). Forecasting weekly evapotranspiration with ARIMA and artificial neural network models. *J. Irrig. Drain. Eng.*, 135(3), 323-334.
- Luo Y., Chang X., Peng Sh., Khan Sh., Wang W., Zheng Q. and Cai X. (2014). Short-term forecasting of daily reference evapotranspiration using the Hargreaves-Samani model and temperature forecasts, *Agricultural Water Management*, 13(6) 42-51.
- Najafi B. and Tarazkar M. H. (2006). Forecasting of Iranian pistachio export rate: Application of artificial neural network, *Iranian Journal of Trade Studies*, 39(2), 191-214 [In Persian].
- Raghavendra S. and Paresh D. (2014). Support vector machine applications in the field of hydrology: A review. *Appl. Soft Comp.*, 19(1), 372-386.

-
- Tabari H., Marofi S. and Sabziparvar A. A. (2010). Estimation of daily pan evaporation using artificial neural network and multivariate non-linear regression. *Irrig. Sci.*, 28(5), 399–406.
- Trajkovic S., Todorovic B. and Standkovic M. (2003). Forecasting of reference evapotranspiration by artificial neural network. *J. Irrig. Drain. Eng. ASCE*, 129(6), 454-457.
- Yoon H., Jun S. C., Hyun Y., Bae G. O. and Lee K. K. (2011). A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *J. Hydrol.*, 396(1-2), 128-138.
- Zare-Abyaneh H., Bayat M., Marofi S., Amiri R. (2009). Evaluation of artificial neural network and adaptive neuro fuzzy inference system in decreasing of reference evapotranspiration parameters. *J. Wat. Soil*, 24(2), 297-305 [In Persian].

Forecasting of Reference Evapotranspiration using MLP, RBF, and SVM Neural Networks

Soheila Panahi¹, Masoud Karbasi² and Jaefar Nikbakht³

¹ M.Sc. Student, Department of Water Engineering, Faculty of Agriculture, University of Zanjan, Iran

² Assistant Professor of Department of Water Engineering, University of Zanjan, Iran

³ Associate Professor of Department of Water Engineering, University of Zanjan, Iran

*Corresponding Author: soheilapanahi@znu.ac.ir

Received: March 6, 2016

Accepted: June 8, 2016

Abstract

Estimation of reference crop evapotranspiration is one of the most important elements in optimizing agricultural water consumption and in management of water resources. Forecasting the daily and weekly reference evapotranspiration can be used in predicting of crop water requirements and in short range planning irrigation. The aim of this study was to evaluate the performance of three types of artificial neural networks: MLP (multilayer perceptron), RBF (radial basis function network), and SVM (support vector machine) in forecasting the daily and weekly reference evapotranspiration at Tabriz synoptic stations. For this purpose, the meteorological data of 39-year period (1971-2009) were used. To train the neural network, 80 percent of time series data was selected randomly and 20 percent of data was used to validate the different models. To create the time series of daily and weekly reference evapotranspiration in a given period, the standard Penman-Monteith FAO 56 equation was used. Different combinations of input data (different delays) were used to evaluate the models. The results of daily forecasting of reference evapotranspiration showed that SVM with RBF kernel with input set of M5, RMSE=0.51 mm/day and $R^2=0.92$ had the best performance. Moreover, the results of weekly forecasting of reference evapotranspiration showed that SVM with polynomial kernel with inputs set of M8, RMSE=3.88 mm/week and $R^2=0.95$ had the best performance.

Keywords: Artificial Neural Networks, Crop water requirement, Time series, Penman-Monteith, Tabriz.