

پیش‌بینی تبخیر-تعرق مرجع روزانه با استفاده از مدل ترکیبی موجک-شبکه عصبی مصنوعی

مسعود کرباسی¹

تاریخ دریافت: 1394/5/20 تاریخ پذیرش: 1394/9/25

چکیده

تبخیر-تعرق گیاه مرجع یکی از مهم‌ترین و مؤثرترین عوامل در بهینه‌سازی مصرف آب کشاورزی و مدیریت منابع آب می‌باشد. پیش‌بینی تبخیر-تعرق مرجع روزانه می‌تواند در پیش‌بینی نیاز آبی گیاهان و برنامه‌ریزی کوتاه‌مدت آبیاری مورد استفاده قرار گیرد. در سال‌های اخیر استفاده از شبکه‌های عصبی مصنوعی و مدل هیبریدی موجک-عصبی در پیش‌بینی پارامترهای هیدرولوژیکی بسیار متداول شده است. هدف تحقیق حاضر استفاده از مدل‌های شبکه عصبی مصنوعی و موجک-شبکه عصبی در پیش‌بینی تبخیر-تعرق مرجع در بازه 1 تا 28 روز در ایستگاه همدیدی تبریز و مقایسه بین آن‌ها می‌باشد. بدین منظور یک دوره آماری 10 ساله (2000 الی 2009) که 7 سال (2000-2006) آن برای آموزش و 3 سال (2007-2009) جهت آزمون و صحت سنجی مدل‌های پیشنهادی { در نظر گرفته شد. برای ایجاد سری زمانی تبخیر-تعرق مرجع روزانه در دوره موردنظر با استفاده از معادله استاندارد پنمن-مانتیت فائو 56 محاسبه گردید. ترکیب‌های متفاوتی از داده‌های ورودی (تأخیرهای مختلف) و انواع موجک‌های مادر مورد ارزیابی قرار گرفت. نتایج پیش‌بینی تبخیر-تعرق مرجع برای یک روز آینده، نشان داد که مدل ترکیبی موجک-عصبی ($R=0/999$ و $RMSE=0/07$ mm/day) در مقایسه با مدل شبکه عصبی مصنوعی ($R=0/964$ و $RMSE=0/69$ mm/day) دارای توانایی و دقت بالاتری در پیش‌بینی تبخیر-تعرق روزانه برای یک روز آینده می‌باشد. همچنین نتایج نشان داد که استفاده از تأخیرهای زمانی 1 تا 7 (M7) و 1 تا 6 (M6) روزه بالاترین دقت را ارائه می‌دهند و استفاده از تأخیرهای کم‌تر و تأخیرهای یک‌ساله دوساله دقت مدل را کاهش می‌دهند. بررسی انواع موجک‌های مادر نیز نشان داد که پیش‌پردازش داده‌ها با موجک میر به دلیل پیچیدگی بیش‌تر و تشابه به سری زمانی تبخیر-تعرق مرجع، می‌تواند موجب افزایش دقت، پیش‌بینی گردد. برای پیش‌بینی تبخیر-تعرق مرجع در 2 تا 28 روز آینده، مدل موجک-شبکه عصبی پیشنهادی مورد استفاده قرار گرفت. نتایج نشان داد که با بیشتر شدن زمان پیش‌بینی از 2 تا 28 روز، دقت مدل‌ها کاهش (R) از 0/997 برای 2 روز تا 0/929 برای 28 روز) می‌یابد. همچنین در پیش‌بینی‌های 2 تا 12 روزه استفاده از تأخیرهای سالانه موجب کاهش دقت مدل گردید، درحالی‌که در پیش‌بینی‌های 13 تا 28 روزه استفاده از تأخیر زمانی سالانه افزایش دقت مشاهده گردید. در نهایت برای مقایسه مدل‌ها از نظر آماری، آزمون‌های t و F برای مقایسه میانگین و واریانس انجام گرفت. نتایج مقایسه نشان داد که کلیه مدل‌های پیشنهادی در سطوح 99 و 95 درصد تفاوت معنی‌داری وجود ندارد.

واژه‌های کلیدی: سری زمانی، شبکه عصبی، موجک، نیاز آبی گیاهان

مقدمه

متغیرها، پیش‌بینی تحولات آینده را که عامل کلیدی در برنامه‌ریزی، طراحی و مدیریت منابع آب است، ممکن می‌سازد. استفاده از مدل‌های مبتنی بر میانگین درازمدت سری‌های زمانی یک روش ساده و پرکاربرد در پیش‌بینی مقادیر آینده تبخیر-تعرق مرجع است ولی با توجه به تغییر اقلیم و روند افزایشی تبخیر-تعرق مرجع در اکثر مناطق ایران این روش موجب خطا در پیش‌بینی‌های آینده می‌گردد (Tabari et al., 2011). برخی مدل‌های آماری، تجزیه و تحلیل سری‌های زمانی می‌توانند موجب کاهش خطای پیش‌بینی گردند. کشاورزان و متصدیان سامانه‌های آبیاری می‌توانند، در رابطه با میزان آب، آبیاری موردنیاز بر اساس پیش‌بینی‌های بارش و آب مورد نیاز

برآورد مقدار تبخیر-تعرق گیاهی به‌منظور تعیین میزان آب آبیاری و برنامه زمان‌بندی آن ضروری است. با توجه به بحران آب و نیاز به برنامه‌ریزی دقیق لازم بنظر می‌رسد. اطلاع از وضعیت آبی تبخیر-تعرق مرجع می‌تواند به تصمیم‌گیری‌ها پیش‌رو برای برنامه‌ریزی منابع آب و روش‌های مدیریتی مناسب کمک کند (به‌منش و همکاران، 1393). تقاضای آب و مصرف آن در اکوسیستم‌های کشاورزی به‌شدت وابسته به پارامترهای اقلیمی است. در برنامه‌ریزی و مدیریت منابع آب، آبیاری نیاز به تجزیه تحلیل متغیرهای هیدرولوژیکی نظیر بارش و تبخیر-تعرق است. استفاده از اطلاعات گذشته در این

1 - استادیار گروه مهندسی آب دانشگاه زنجان (m.karbasi@znu.ac.ir)

مرجع تحقیقات متعددی صورت گرفته است (Kisi, 2008 & Tabari et al., 2010)، ولی کاربرد مدل‌های هوش مصنوعی در پیش‌بینی مقادیر آینده تبخیر-تعرق مرجع کم‌تر مورد توجه قرار گرفت است و تحقیقات محدودی در این زمینه وجود دارد. تراکویچ و همکاران با استفاده از شبکه‌های عصبی نوع RBF اقدام به پیش‌بینی مقادیر تبخیر-تعرق مرجع ماهیانه نمودند (Trajkovic et al., 2003). لاندراکس و همکاران با استفاده از شبکه‌های عصبی مصنوعی، تبخیر-تعرق مرجع هفتگی را پیش‌بینی کردند (Landeras et al., 2009). تبدیل موجک با تجزیه سری زمانی، ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. در سال‌های اخیر استفاده از مدل ترکیبی موجک-شبکه عصبی در پیش‌بینی سری‌های زمانی هیدرولوژیکی (مانند دبی رودخانه‌ها، خشک‌سالی، بارندگی، سطح آب زیرزمینی و غیره)، توجه بسیاری از پژوهشگران را به خود جلب نموده است (Nourani et al., 2014). کاربرد تبدیل موجک در پیش‌پردازش سری زمانی تبخیر-تعرق مرجع تحقیقات محدودی انجام گرفته است. وانگ و لو از مدل ترکیبی موجک-شبکه عصبی برای پیش‌بینی تبخیر-تعرق مرجع یک ماه آینده، استفاده نمودند. نتایج نشان داد که استفاده از تبدیل موجک به‌عنوان پیش‌پردازش داده‌ها موجب بهبود پیش‌بینی تبخیر-تعرق مرجع ماهانه می‌گردد (Wang and Lou., 2007). باچور و همکاران، با استفاده از مدل $MRVM^3$ و ترکیب آن با تبدیل موجک اقدام به پیش‌بینی تبخیر-تعرق مرجع برای 16 روز آینده نمودند. نتایج نشان داد که استفاده از تبدیلی موجک به‌عنوان یک روش پیش‌پردازش می‌تواند موجب افزایش دقت پیش‌بینی گردد (Bachour et al., 2015).

با توجه به اهمیت پیش‌بینی تبخیر-تعرق مرجع در برنامه‌ریزی کوتاه‌مدت آبیاری و بهره‌برداری از کانال‌ها و مخازن، در تحقیق حاضر دو مدل شبکه عصبی مصنوعی و ترکیبی موجک-شبکه عصبی برای پیش‌بینی کوتاه‌مدت تبخیر-تعرق مرجع روزانه در مقیاس‌های 1 الی 28 روز در ایستگاه همدیدی تبریز مورد استفاده قرار گرفتند و عملکرد دو مدل با یکدیگر مقایسه گردید.

مواد و روش‌ها

منطقه مورد مطالعه

در مطالعه حاضر، داده‌های اقلیمی متوسط ماهانه کمینه و بیشینه دما، کمینه و بیشینه رطوبت نسبی، سرعت باد و ساعات آفتابی مربوط به ایستگاه همدیدی تبریز مربوط به دوره آماری سال 1999 تا 2009 برای محاسبه تبخیر و تعرق روزانه گیاه مرجع مورد استفاده

محصولات، تصمیم‌گیری‌ها را بر اساس زمان واقعی¹ اعمال کنند. بارش به طور معمول در پیش‌بینی هوا از طریق پیش‌بینی وضعیت آب و هوا پیش‌بینی می‌شود، درحالی‌که نیاز آبی گیاهان در پیش‌بینی‌ها انجام نمی‌پذیرد. با توجه به این‌که نیاز آبی گیاهان از حاصل‌ضرب تبخیر-تعرق مرجع (ET_0) در ضریب گیاهی k_c به دست می‌آید و k_c تابعی از نوع گیاه و مرحله رشد است (Allen et al., 1998)، پیش‌بینی تبخیر-تعرق مرجع (ET_0) نقش مهمی را در برنامه‌ریزی زمان واقعی آبیاری ایفا می‌کند. پیش‌بینی هفتگی و ماهانه تبخیر-تعرق مرجع در برنامه‌ریزی‌های میان‌مدت و بلندمدت آبیاری مفید هستند، لیکن پیش‌بینی روزانه تبخیر-تعرق مرجع نقش مهمی را در برنامه‌ریزی کوتاه‌مدت آبیاری ایفا می‌کند (Lou et al., 2014).

استفاده از مدل‌های سری زمانی در پیش‌بینی تبخیر-تعرق مرجع در مقیاس‌های زمانی ماهیانه و هفتگی توسط پژوهشگران مختلف مورد بررسی و تحقیق قرار گرفته است. فولادمند و همکاران، (1389) با مقایسه مقادیر پیش‌بینی شده با محاسبه‌شده در هر ایستگاه از نظر آماری نشان دادند که مدل سری زمانی مناسب برای پیش‌بینی تبخیر-تعرق مرجع در ایستگاه‌های مختلف یکسان نمی‌باشد. شیروانی و هنر (1390) پیش‌بینی مقادیر تبخیر-تعرق ماهانه و هفتگی با استفاده از مدل‌های اتورگرسیو- میانگین متحرک تلفیق شده فصلی را برای ایستگاه باجگاه مورد بررسی قراردادند. نتایج نشان داد که مدل فوق‌قادر است مقادیر تبخیر-تعرق را در مقیاس‌های اشاره‌شده به‌خوبی پیش‌بینی کند. لاندراکس و همکاران مدل ARIMA را جهت پیش‌بینی مقادیر هفتگی تبخیر-تعرق در شمال اسپانیا مورد ارزیابی قراردادند (Landeras et al., 2009). نتایج نشان داد که مدل فوق‌نسبت به مقادیر متوسط بلندمدت از دقت بالاتری برخوردار است. آزاد طلاتپه و همکاران (1392)، عملکرد مدل‌های سری زمانی را در پیش‌بینی تبخیر-تعرق ماهانه در ایستگاه همدیدی ارومیه مورد ارزیابی قراردادند. به‌منش و همکاران (1393) مدل‌های سری زمانی خطی را به همراه مدل غیرخطی دوسویه² در پیش‌بینی مقادیر ماهانه تبخیر-تعرق در ایستگاه همدیدی ارومیه مورد مقایسه قراردادند. نتایج نشان داد که مدل غیرخطی دوسویه توانایی بیش‌تری در مدل‌سازی و پیش‌بینی مقادیر ماهانه تبخیر-تعرق گیاه مرجع در مقایسه با مدل خطی برخوردار است. از مشکلات مدل سری زمانی (SARIMA) در پیش‌بینی داده‌های با مقیاس روزانه این است که طول فصل 365 روز است و در اکثر موارد مدل نمی‌تواند همگرا شود، بنابراین در عمل استفاده از مدل‌های سری زمانی در پیش‌بینی روزانه تبخیر-تعرق مرجع امکان‌پذیر نیست (Bachour et al., 2015).

در زمینه کاربرد مدل‌های هوش مصنوعی در برآورد تبخیر-تعرق

1- Real-time

2- bilinear

3- Multivariate relevance vector machine

$$\varphi_{j,k}(t) = \frac{1}{\sqrt{|s_0^j|}} \varphi\left(\frac{t - k\tau_0 s_0^j}{s_0^j}\right) \quad (3)$$

که در آن $\varphi_{j,k}$ تابع موجک به ازای مقادیر معین k و j (اعداد صحیح)، t زمان، $s_0 (> 1)$ ثابت گام اتساع، τ_0 ثابت انتقال زمان بوده و وابسته به s_0 می‌باشند.

با اعمال تبدیل گسسته، داده‌های اولیه موجکی شده و به دو دسته تقسیم می‌شوند. دسته اول که تقریب نامیده می‌شوند، دارای فرکانس کم بوده و نشان‌دهنده روند کلی داده‌های موجود است که در محاسبات نقش بسیار مهمی ایفا می‌کند. دسته دوم جزئیات نام دارد که دارای فرکانس بالاست و بیانگر تغییرات محدوده در داده‌هاست. فرایند تجزیه سیگنال شامل یک یا چند مرحله است که در تجزیه چندمرحله‌ای، موج پس از اولین مرحله تفکیک با تجزیه مجدد قسمت تقریبی، تجزیه موج ادامه می‌یابد. به دلیل گسسته بودن اکثر سیگنال‌های سری‌های زمانی هیدرولوژیکی و حجم زیاد اطلاعات حاصل از تبدیل موجک پیوسته (Nourani et al, 2014)، در تحقیق حاضر از تبدیل موجک گسسته در به دست آوردن ضرایب موجک استفاده شده است.

شبکه‌های 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. عناصر پردازش که در واقع همان نورون‌ها هستند، به هم می‌پیوندند تا یک مسیر پردازش را کامل کنند. این عناصر پردازش که معمولاً در لایه‌ها با صفحات منظمی قرار گرفته‌اند، به طوری که بین لایه‌ها، ارتباطات کامل و یا تصادفی وجود دارد. لایه ورودی به عنوان پردازش گری عمل می‌کند که پس از پردازش داده‌های ورودی آن‌ها را به شبکه ارائه می‌دهد. لایه ورودی لایه عصبی محاسباتی نیست، زیرا گره‌های آن نه وزن ورودی دارند و نه تابع فعال‌سازی. لایه آخر، لایه خروجی است که خروجی شبکه را در پاسخ به یک ورودی مشخص نشان می‌دهد. لایه دیگر لایه پنهان یا لایه میانی نامیده می‌شود. این لایه به این دلیل پنهان نامیده می‌شود، چون بین آن و دنیای خروجی ارتباطی وجود ندارد (Hykin., 1999). عصب‌ها یا نورون‌های مصنوعی اجزای اصلی یک شبکه عصبی هستند. الگوی ورودی به یک گره شبیه یک سلول زیستی است که می‌توان آن را با برداری با M مؤلفه به صورت $X = (x_1, x_2, \dots, x_m)$ نشان داد. مجموع حاصل ضرب ورودی‌ها در وزن‌های نظیرشان را می‌توان با کمیت اسکالر s نمایش داد (رابطه 4):

قرار گرفت. ایستگاه همدیدی تبریز در 38 درجه و 5 دقیقه عرض جغرافیایی و 46 درجه و 17 دقیقه طول جغرافیایی و در ارتفاع 1361 متر بالاتر از سطح دریاهای آزاد واقع شده است. متوسط بیشینه و کمینه دما در ایستگاه به ترتیب 18 و 7 درجه سانتی‌گراد، میانگین سرعت باد 2/37 متر بر ثانیه می‌باشد. معادله پنمن-مانتیث

به منظور برآورد مقدار تبخیر-تعرق روزانه و ایجاد سری زمانی مورد نظر، از مدل پنمن-مانتیث مطابق معادله 1 استفاده گردید (Allen et al, 1998)

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

که در آن ET_0 تبخیر-تعرق گیاه مرجع (میلی‌متر در روز) R_n تابش خالص در سطح پوشش گیاهی (مگاژول بر مترمربع در روز)، T میانگین دمای هوا در ارتفاع 2 متری از سطح زمین (درجه سانتی‌گراد)، u_2 سرعت باد در ارتفاع 2 متری از سطح زمین (متر بر ثانیه)، $(e_a - e_d)$ کمبود فشار بخار اشباع (کیلو پاسکال)، Δ شیب منحنی فشار بخار (کیلو پاسکال بر درجه سانتی‌گراد)، γ ضریب رطوبتی (کیلو پاسکال بر درجه سانتی‌گراد)، G شار گرمایی زمین (مگاژول بر مترمربع در روز) می‌باشند.

تبدیل موجک

تبدیلات موجک به دو نوع پیوسته و گسسته تقسیم می‌شوند. تبدیل موجک پیوسته یک سیگنال $x(t)$ به صورت رابطه 2 تعریف می‌گردد:

$$CWT_x^\varphi = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} x(t) \varphi^*\left(\frac{t - \tau}{s}\right) dt \quad (2)$$

در رابطه فوق φ تابع موجک، $s (> 1)$ پارامتر مقیاس یا اتساع، τ پارامتر انتقال زمان، t زمان و علامت * نشان‌دهنده مزدوج مختلط می‌باشد. مدل CWT ، سیگنال را به وسیله تعداد بی‌شمار و نامحدودی از پارامترهای مقیاس و انتقال تجزیه می‌کند. در این مدل پارامترهای مقیاس و انتقال به صورت پیوسته تغییر می‌کنند. از این رو محاسبه ضرایب موجک برای همه مقیاس‌های ممکن، علاوه بر تولید حجم زیادی از اطلاعات، نیاز به کوششی قابل‌ملاحظه دارد؛ اما می‌توان با استفاده از زیر نمونه‌هایی از CWT ویژگی‌های کلیدی تبدیل را حفظ نمود. این ایده منجر به ابداع تبدیل گسسته موجک (DWT) گردیده است (Heil and walnut, 1989). شکل گسسته تابع موجک به صورت معادله 3 می‌باشد:

هستند) و جزئیات² (d) که دارای فرکانس بالا هستند (نشان‌دهنده تغییرات محدوده داده‌ها هستند)، تجزیه می‌شوند. در مرحله بعد زیر سری‌های تقریب $a_1, d_1, d_2, \dots, d_n$ که n سطح تجزیه می‌باشد، به‌عنوان ورودی‌های مدل شبکه عصبی برای پیش‌بینی تبخیر-تعرق مرجع، در نظر گرفته شدند (Adamovski & Sun, 2010, Kisi, 2010). تعیین نوع موجک مادر و سطح تجزیه سری زمانی نقش مهمی را در عمل‌کرد مدل‌های بر پایه موج ایفا می‌کنند. در تحقیق حاضر از موجک‌های خانواده دابچیز، کوئیفلت، سیملت و میر استفاده گردید. بعد از تعیین نوع موجک مادر، مهم‌ترین اقدام تعیین سطح تجزیه است. استفاده از حداکثر سطح تجزیه موجب کند شدن فرایند و آموزش و در برخی موارد می‌تواند موجب کاهش دقت مدل نیز گردد. جهت انتخاب سطح تجزیه تبدیل موجک گسسته رابطه 7 استفاده شد (Nourani et al., 2014).

$$L = \text{Int}[\log(N)] \quad (7)$$

در رابطه فوق L سطح تجزیه، N تعداد داده‌های سری زمانی و Int تابع جز صحیح می‌باشند.

ورودی‌های مدل‌های شبکه عصبی و موجک - شبکه عصبی در جدول 1 ارائه شده‌اند. برای ایستگاه مورد بررسی، تبخیر-تعرق مرجع از 1 روز تا 7 روز قبل در الگوهای M1 تا M7 ارائه شده‌اند. برای بررسی تأثیر تاریخچه سری زمانی بر نتایج، در دو مدل M8 و M9 به ترتیب از تأخیرهای یک و دوساله استفاده گردید.

معیار نیکویی برازش

به‌منظور 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 همبستگی پیرسون (R) و جذر میانگین مربعات خطا (RMSE) استفاده گردید (رابطه 8 و 9)

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - P_i)^2}{N}} \quad (8)$$

$$R = \frac{\sum_{i=1}^N (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2} \cdot \sqrt{\sum_{i=1}^N (P_i - \bar{P})^2}} \quad (9)$$

در روابط فوق پارامتر O_i مقادیر تبخیر-تعرق مرجع محاسبه‌شده از معادله پنمن-مانتیت و P_i مقادیر پیش‌بینی شده از مدل‌های

$$s = \sum_{m=1}^M w_m x_m = W^T X \quad (4)$$

که در رابطه بالا، $W = (w_1, w_2, \dots, w_M)$ بردار وزن نورون‌ها است. کمیت s سپس وارد یک تابع غیرخطی f می‌شود تا خروجی را نتیجه دهد.

$$y = f(s) \quad (5)$$

تابع غیرخطی انتقال به‌طور معمول به شکل سیگموئید تعریف می‌گردد (رابطه 6):

$$f(s) = \frac{1}{1 + e^{-s}} \quad (6)$$

که خروجی y می‌تواند نتیجه الگو یا ورودی لایه بعدی در شبکه‌های چندلایه باشد. منظور از آموزش یک شبکه انتخابی، بر مبنای اطلاعات موجود، تنظیم مقادیر وزن‌ها و بایاس‌ها یا مقادیر ثابت اولیه می‌باشد به‌گونه‌ای که خطای بین مقادیر خروجی محاسبه‌شده و مشاهده‌شده، حداقل گردد؛ بنابراین در فرآیند آموزش وزن‌های شبکه به شاخص‌های بهینه خود نزدیک می‌شوند. در پرسپترون چندلایه برای آموزش از الگوریتم‌های نظارت‌شده استفاده می‌گردد (مؤمنی و همکاران، 1390). برای آموزش شبکه‌های عصبی مصنوعی پرسپترون چندلایه به‌طور معمول از الگوریتم پس‌انتشار خطا، استفاده می‌گردد. 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 10000 استفاده شده است (Budu., 2014). 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 0 تا 1 مقیاس تبدیل شدند. در تحقیق حاضر 70 درصد داده‌ها (7 سال) برای آموزش شبکه و 30 درصد (3 سال) برای صحت‌سنجی مدل‌های پیشنهادی در نظر گرفته شدند.

ساختار مدل موجک-شبکه عصبی

در تحقیق حاضر از نرم‌افزار (MATLAB (2013 b) که دارای جعبه ابزارهای شبکه عصبی و موجک می‌باشد، جهت پیش‌بینی تبخیر-تعرق مرجع استفاده شده است. هدف مدل هیبریدی موجک-عصبی مورد استفاده در تحقیق حاضر، پیش‌بینی تبخیر-تعرق مرجع روزانه در بازه 1 تا 28 روز بعد، با استفاده از زیر سری‌های به‌دست‌آمده از تبدیل موجک گسسته است. بدین منظور، ابتدا سری زمانی اصلی با استفاده از تبدیل موجک گسسته به زیر سری‌های تقریب¹ (a) که دارای فرکانس کم بوده (نشان‌دهنده روند کلی داده‌های موجود

مختلف و \bar{O}_i و \bar{P}_i نیز به ترتیب میانگین مقادیر تبخیر-تعرق مرجع معادله پنمن-مانتیت و پیش‌بینی می‌باشند. برای مقایسه میانگین مدل‌های پیشنهادی و مقادیر تبخیر-تعرق معادله پنمن-مانتیت آزمون F مورد استفاده قرار گرفت.

مختلف و \bar{O}_i و \bar{P}_i نیز به ترتیب میانگین مقادیر تبخیر-تعرق مرجع معادله پنمن-مانتیت و پیش‌بینی می‌باشند. برای مقایسه میانگین مدل‌های پیشنهادی و مقادیر تبخیر-تعرق معادله پنمن-مانتیت آزمون F مورد استفاده قرار گرفت.

جدول 1- مجموعه مختلف متغیرهای ورودی و خروجی مدل *


الگوی ورودی	متغیرهای ورودی	متغیر خروجی
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	$ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-5}$	ET_t
M6	$ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-5}, ET_{t-6}$	ET_t
M7	$ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-5}, ET_{t-6}, ET_{t-7}$	ET_t
M8	$ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-5}, ET_{t-365}$	ET_t
M9	$ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-5}, ET_{t-365}, ET_{t-730}$	ET_t

* در جدول منظور از ET_{t-1} تبخیر-تعرق یک روز قبل، ET_{t-2} دو روز قبل و ET_{t-365} ، ET_{t-730} روز قبل (یک سال) می‌باشند.

داده‌های سری زمانی تبخیر-تعرق مرجع برای 10 سال 3650 روز می‌باشد و استفاده از رابطه 7 سطح تجزیه 3 به دست می‌آید. شکل 1 تجزیه سیگنال سری زمانی تبخیر-تعرق مرجع روزانه را به سیگنال‌های پایه سازنده آن توسط تبدیل موجک میر با سطح تجزیه 3 نشان می‌دهد. همان‌طور که در شکل مشخص است، موجک میر، سیگنال S را به یک موجک تقریب (a_3) و سه موجک جزئیات (d_1, d_2, d_3) تجزیه کرده است، به طوری که $s = a_3 + d_1 + d_2 + d_3$.

نتایج و بحث

جهت تعیین تعداد بهینه نرون‌های لایه پنهان در مدل شبکه عصبی از روش آزمون و خطا استفاده شد. نتایج نشان داد که استفاده از 10 نرون در لایه پنهان کافی به نظر می‌رسد و با افزایش تعداد نرون‌ها کاهش خطایی مشاهده نشد. در مجموع 135 مدل با ترکیب ورودی‌ها و موجک‌های مادر مختلف اجرا و مورد ارزیابی قرار گرفتند. از 135 مدل 9 مدل مربوط به شبکه عصبی مصنوعی و 126 مدل مربوط به مدل موجک-عصبی می‌باشند. با توجه به اینکه تعداد



شکل 1 - سری‌های زمانی اصلی و تجزیه شده توسط موجک میر در دوره زمانی 2009-2000

مدل‌های مختلف نشان می‌دهند. در سطر اول جدول‌های مربوط به نتایج مربوط به شبکه‌های عصبی مصنوعی بدون پیش‌پردازش داده‌ها

پیش‌بینی تبخیر-تعرق مرجع برای یک روز آینده جدول‌های 2 و 3 به ترتیب مقادیر RMSE و R را برای

مدل ترکیبی موجک-عصبی، به نوع موجک مادر و الگوی ورودی بستگی دارد. با توجه به جداول 2 و 3 قابل مشاهده است که الگوهای ورودی M7 و M6 به طور متوسط دارای دقت بالاتری نسبت به سایر مجموعه‌های ورودی هستند. مقدار RMSE این دو الگو حداقل (0/07) میلی‌متر بر روز) و مقدار R برای آن‌ها حداکثر (0/999) است. استفاده از تأخیرهای بلندمدت یک سال (365 روز) در مدل M8 و دو سال (730 روز) در مدل M9 موجب کاهش دقت مدل‌های موجک-عصبی گردید. مقایسه نوع موجک‌های مادر نیز نشان می‌دهد که استفاده از موجک میر بهترین عملکرد را در پیش‌بینی یک روز آینده تخییر-تغرق مرجع داشته است. متوسط خطای RMSE برابر 0/18 میلی‌متر بر روز و متوسط ضریب همبستگی پیرسون (R) برابر 0/997 به دست آمدند. موجک‌های کوئیفلت 5، دابچیز 10، سیملت 8 و سیملت 10 از نظر دقت در رده‌های بعدی قرار می‌گیرند.

با توجه به مطالب ذکر شده انتظار می‌رود که بالاترین دقت زمانی حاصل شود که برای پیش‌پردازش داده‌ها از موجک میر و برای الگوی ورودی از الگوهای M7 و M8 استفاده شود. نتایج جداول 2 و 3 تأیید کننده مطلب فوق است و بیش‌ترین دقت با RMSE های 0/07 و 0/08 میلی‌متر بر روز در الگوهای ورودی M7 و M8 و استفاده از موجک میر به دست آمده است. انجام آزمون t بین میانگین مشاهدات و محاسبات و آزمون F بین نسبت اختلاف واریانس مشاهدات و محاسبات نشان داد که بین داده‌های مشاهداتی و پیش‌بینی شده مدل‌های موجک-شبکه عصبی در سطوح اطمینان 95 درصد و 99 درصد اختلاف معنی‌داری وجود ندارد.

توسط تبدیل موجک، ارائه شده است. متوسط مقادیر RMSE و R هر الگوی ورودی در ردیف آخر و متوسط آن‌ها در ستون آخر جداول ارائه گشته است. با توجه به جدول‌های 2 و 3، نتایج مدل شبکه عصبی مصنوعی نشان می‌دهد که استفاده از الگوهای ورودی با تأخیرهای زمانی بیش‌تر، اندکی موجب افزایش دقت مدل‌ها گشته است، به طوری که کم‌ترین مقدار RMSE (0/69) میلی‌متر بر روز) و بیش-ترین مقدار R (0/966) در الگوی M9 به دست آمده‌اند. انجام آزمون t بین میانگین مشاهدات و محاسبات و آزمون F بین نسبت اختلاف واریانس مشاهدات و محاسبات نشان داد که بین داده‌های مشاهداتی و پیش‌بینی شده شبکه عصبی مصنوعی در سطوح اطمینان 95 درصد و 99 درصد اختلاف معنی‌دار وجود ندارد. ضریب همبستگی پیرسون (R) بین مقادیر مشاهداتی و مدل در تمام مدل‌های شبکه عصبی (ANN) در سطح 99 درصد معنی‌دار هستند که نشان دهنده مطابقت خوب مدل با داده‌های مشاهداتی است. بنابراین مدل شبکه عصبی مصنوعی به خوبی میانگین و واریانس را منتقل می‌کند. شکل 2 نمودار پراکنندگی مقادیر مشاهداتی و پیش‌بینی شده برای داده‌های آموزش (الف) و داده‌های صحت سنجی حاصل از بهترین الگوی ورودی (M9) را برای ایستگاه مورد بررسی نشان می‌دهد. در شکل 2 نزدیک‌تر بودن نقاط به خط نیمساز نشان دهنده دقت بالاتر مدل می‌باشد.

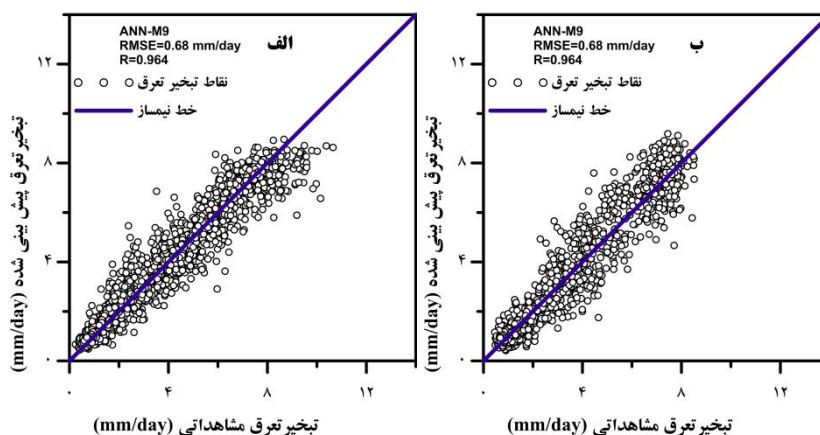
نتایج مدل‌های موجک-شبکه عصبی با توجه به نوع موجک مادر مورد استفاده و الگوی ورودی، در جداول 2 و 3 ارائه شده‌اند. مقادیر به دست آمده در جداول 2 و 3 نشان می‌دهد که عملکرد

جدول 2 - مقادیر RMSE (میلی‌متر بر روز) برای مدل‌های مختلف موجک-شبکه عصبی در سری داده‌های صحت سنجی

مدل	الگوی ورودی									میانگین
	M1	M2	M3	M4	M5	M6	M7	M8	M9	
ANN	0/74	0/73	0/72	0/72	0/71	0/72	0/71	0/71	0/69	0/72
db1	0/61	0/51	0/47	0/47	0/44	0/44	0/43	0/45	0/47	0/48
db2	0/55	0/42	0/40	0/36	0/38	0/38	0/35	0/37	0/39	0/40
db4	0/49	0/32	0/28	0/26	0/26	0/23	0/22	0/26	0/26	0/29
db6	0/52	0/31	0/28	0/22	0/22	0/18	0/18	0/22	0/22	0/26
db8	0/50	0/31	0/27	0/20	0/19	0/16	0/18	0/19	0/20	0/24
db10	0/51	0/28	0/25	0/18	0/17	0/13	0/12	0/17	0/16	0/22
sym2	0/55	0/42	0/40	0/36	0/38	0/30	0/35	0/37	0/40	0/39
sym4	0/51	0/34	0/32	0/28	0/26	0/22	0/22	0/27	0/27	0/30
sym8	0/50	0/28	0/25	0/20	0/13	0/15	0/13	0/18	0/19	0/22
sym10	0/51	0/30	0/26	0/19	0/17	0/13	0/13	0/18	0/18	0/23
coif1	0/52	0/38	0/39	0/36	0/20	0/32	0/33	0/36	0/35	0/35
coif3	0/50	0/30	0/27	0/21	0/21	0/17	0/18	0/21	0/24	0/25
coif5	0/50	0/28	0/24	0/17	0/15	0/11	0/12	0/15	0/16	0/21
dmey	0/49	0/26	0/22	0/14	0/11	0/08	0/07	0/12	0/15	0/18
میانگین	0/53	0/36	0/33	0/29	0/27	0/25	0/24	0/28	0/29	

جدول 3- مقادیر R برای مدل‌های مختلف موجک-شبکه عصبی در سری داده‌های صحت‌سنجی

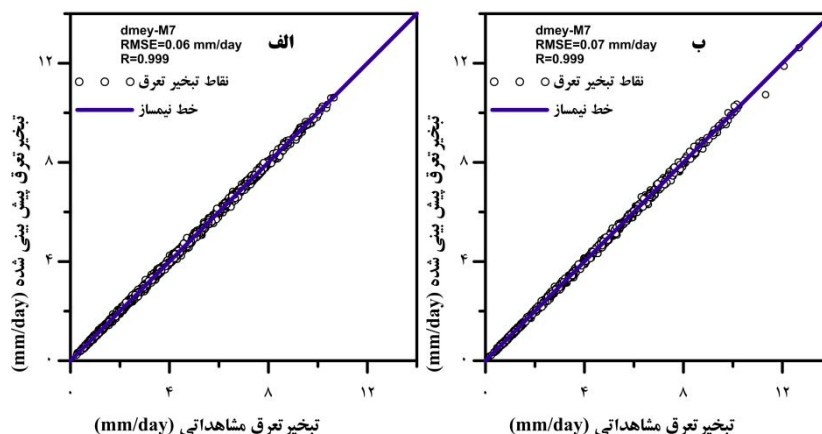
مدل	الگوی ورودی									میانگین
	M1	M2	M3	M4	M5	M6	M7	M8	M9	
ANN	0/961	0/962	0/964	0/963	0/964	0/964	0/964	0/965	0/966	0/964
db1	0/976	0/982	0/984	0/984	0/986	0/986	0/987	0/985	0/985	0/984
db2	0/979	0/987	0/989	0/991	0/989	0/989	0/991	0/990	0/990	0/989
db4	0/983	0/993	0/994	0/995	0/995	0/996	0/997	0/995	0/995	0/993
db6	0/981	0/993	0/994	0/996	0/997	0/997	0/998	0/996	0/996	0/994
db8	0/982	0/993	0/995	0/997	0/997	0/998	0/998	0/997	0/997	0/995
db10	0/982	0/994	0/996	0/998	0/998	0/999	0/999	0/998	0/998	0/996
sym2	0/979	0/987	0/989	0/991	0/990	0/993	0/991	0/990	0/989	0/989
sym4	0/982	0/992	0/993	0/994	0/995	0/996	0/997	0/995	0/995	0/993
sym8	0/982	0/994	0/996	0/997	0/999	0/998	0/999	0/998	0/997	0/996
sym10	0/982	0/994	0/995	0/997	0/998	0/999	0/999	0/998	0/998	0/995
coif1	0/981	0/990	0/989	0/991	0/997	0/992	0/992	0/991	0/991	0/991
coif3	0/983	0/994	0/995	0/997	0/997	0/998	0/998	0/997	0/996	0/995
coif5	0/983	0/994	0/996	0/998	0/998	0/999	0/999	0/998	0/998	0/996
dmey	0/983	0/995	0/996	0/999	0/999	0/999	0/999	0/999	0/998	0/997
میانگین	0/979	0/989	0/991	0/992	0/993	0/994	0/994	0/993	0/992	



شکل 2- پراکندگی مقادیر مشاهداتی در مقابل مقادیر پیش‌بینی شده در داده‌های آموزش (الف) صحت‌سنجی (ب) در مدل شبکه عصبی برای الگوی ورودی M9

طوفانی و همکاران (1390) در پیش‌بینی بارندگی، رجایی و ابراهیمی (1393) در پیش‌بینی نوسانات سطح آب زیرزمینی و شعیب و همکاران در پیش‌بینی رواناب نیز گزارش نمودند که استفاده از موجک میر موجب افزایش دقت پیش‌بینی گشته است (shoib et al., 2015). در حالی که در اکثر تحقیقات مربوط به پیش‌بینی سری زمانی متغیرهای هیدرولوژیکی از موجک‌های مادر خانواده دابچیز (db1-db10) استفاده شده است (Nourani et al., 2014, Mehr et al., 2013). دلیل افزایش دقت در موجک میر را می‌توان به دلیل پیچیدگی بالا و شباهت به سیگنال تبخیر-تعرق مرجع روزانه، مرتبط

ضریب همبستگی پیرسون (R) بین مقادیر مشاهداتی و مدل در تمام مدل‌های موجک-شبکه عصبی در سطح 99 درصد معنی‌دار هستند که نشان دهنده مطابقت خوب مدل با داده‌های مشاهداتی است. شکل 3 نمودار پراکندگی مقادیر مشاهداتی و پیش‌بینی شده برای داده‌های آموزش (الف) و داده‌های صحت‌سنجی حاصل از بهترین الگوی ورودی (M7) و موجک مادر میر برای پیش‌پردازش داده‌ها را برای ایستگاه مورد بررسی نشان می‌دهد. در شکل 3 نزدیک‌تر بودن نقاط به خط نیمساز نشان دهنده دقت بالاتر مدل می‌باشد.



شکل 3- پراکندگی مقادیر مشاهداتی در مقابل مقادیر پیش‌بینی شده در داده‌های آموزش (الف) صحت سنجی (ب) در مدل موجک-شبکه عصبی برای الگوی ورودی M7 و موجک مادر میر

بررسی تأثیر تاریخچه سری زمانی بر روی پیش‌بینی مدل‌ها مورد استفاده قرار گرفتند. نتایج پیش‌بینی تبخیر-تعرق مرجع برای 2 تا 28 روز در جدول 4 ارائه شده است. بهترین نتیجه برای پیش‌بینی تبخیر-تعرق مرجع برای بازه زمانی مربوطه به صورت پرننگ در جدول 4 ارائه شده است. نتایج جدول 4 نشان دهنده این مطلب است که با افزایش بازه پیش‌بینی از 2 به 28 روز، دقت مدل کاهش می‌یابد. در پیش‌بینی‌های 2 تا 12 روز، الگوی ورودی M7 دارای بهترین عملکرد است و استفاده از تأخیرهای یک و دو ساله در الگوهای ورودی M8 و M9، موجب کاهش دقت شده است. در پیش‌بینی‌های 13 تا 28 روزه، استفاده از تأخیرهای یک ساله و دو ساله (M9 و M8) موجب افزایش دقت مدل در پیش‌بینی تبخیر-تعرق مرجع گشته است. شکل 4 نمودار پراکندگی مقادیر پیش‌بینی مدل را در مقابل مقادیر مشاهداتی برای بازه‌های 1، 4، 7، 14، 21 و 28 روز نشان می‌دهد. نتایج باچور و همکاران در پیش‌بینی 1 تا 16 روزه تبخیر-تعرق مرجع نیز نشان داد که هرچه بازه پیش‌بینی افزایش یابد، دقت مدل کاهش پیدا خواهد کرد. مقدار ضریب همبستگی R در نتایج باچور و همکاران در پیش‌بینی 1 تا 16 روزه تبخیر-تعرق مرجع، از 0/798 برای پیش‌بینی 16 روزه تا 0/878 برای یک روز متغیر است (Bachour et al., 2015). در حالی که در مدل پیشنهادی در این تحقیق ضریب همبستگی R از 0/929 برای پیش‌بینی 28 روزه تا 0/999 برای پیش‌بینی 1 روزه متغیر است، که نشان دهنده دقت بالاتر مدل پیشنهادی تحقیق حاضر است.

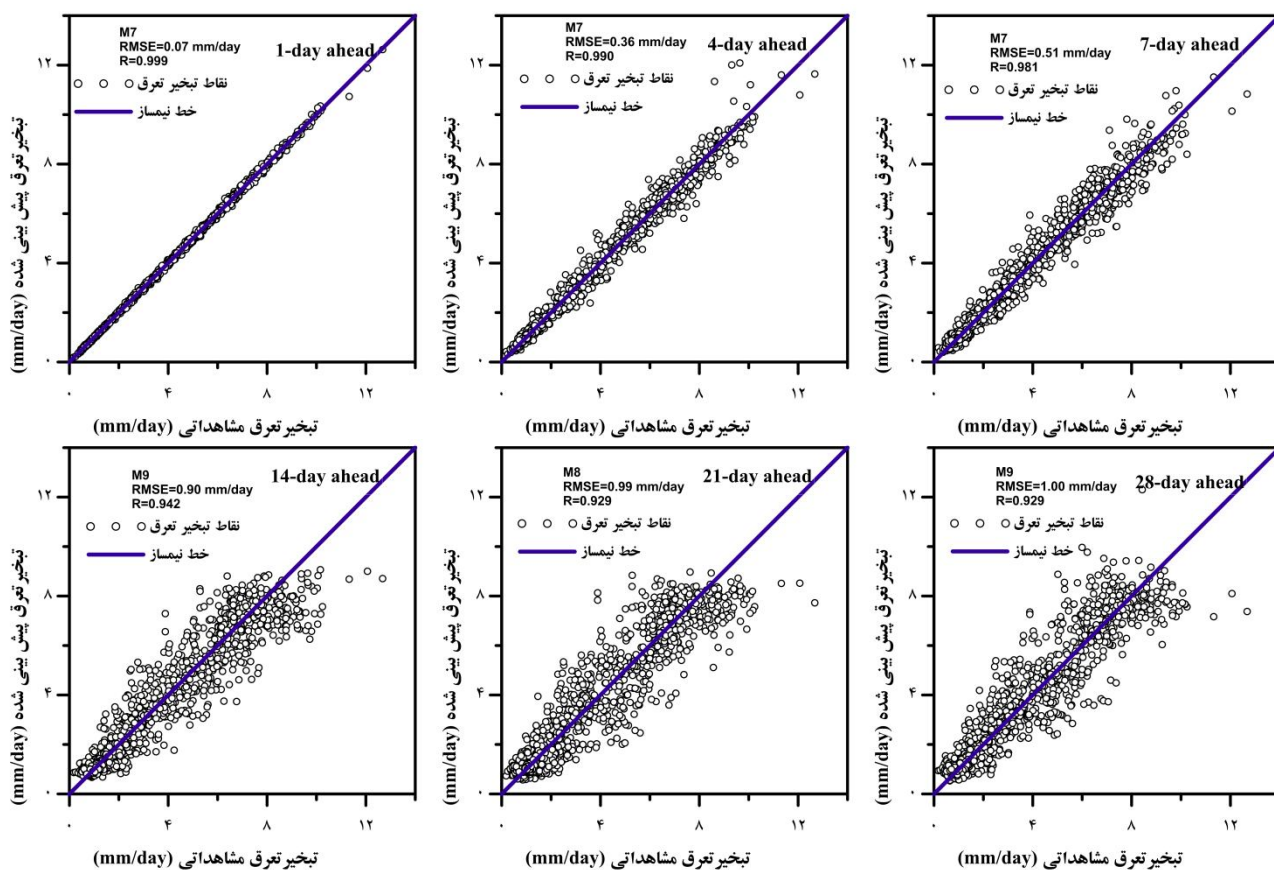
مقایسه بین نتایج مدل شبکه عصبی و موجک-شبکه عصبی نشان دهنده برتری کامل مدل‌های موجک-شبکه عصبی است، در حالی که ضعیف‌ترین نتایج به دست آمده از مدل موجک-عصبی (موجک db1 و الگوی M1) (R برابر 0/976) از بهترین نتیجه شبکه عصبی (الگوی M9) (R برابر 0/964) مناسب‌تر بوده است. نتیجه فوق توسط بسیاری از پژوهشگران، که مدل‌های هیبریدی بر پایه موجک را با مدل‌های بدون استفاده از موجک مقایسه کرده‌اند، گزارش شده است (عبداللهی اسدآبادی و همکاران، 1393، معروفی و همکاران، 1392 و Nourani et al., 2014 و Wang and Lou, 2007). نتایج تحقیقات ذکر شده حاکی از آن است که پیش‌پردازش داده‌های سری زمانی توسط تبدیل موجک، موجب افزایش دقت مدل‌های پیش‌بینی کننده می‌گردد. باچور و همکاران با استفاده از مدل MRVM و ترکیب آن با تبدیل موجک اقدام به پیش‌بینی تبخیر-تعرق مرجع برای 16 روز آینده نمودند. نتایج نشان داد که استفاده از تبدیلی موجک به عنوان یک روش پیش‌پردازش می‌تواند موجب افزایش دقت پیش‌بینی گردد (Bachour et al., 2015).

پیش‌بینی تبخیر-تعرق مرجع در بازه زمانی 2 تا 28 روزه

جهت بررسی پیش‌بینی‌های بیش از 1 روز، پیش‌بینی 2 تا 28 روز نیز انجام گرفت. برای پیش‌پردازش داده‌های ورودی، با توجه به اینکه موجک میر بهترین عملکرد را دارا می‌باشد، از این موجک استفاده گردید. همچنین با توجه به اینکه الگوی ورودی M7 بهترین نتیجه را برای پیش‌بینی تبخیر-تعرق مرجع یک روز بعد ارائه کرده است، از الگوی ورودی فوق استفاده گردید. الگوهای M8 و M9 نیز برای

جدول 4- پارامترهای آماری پیش‌بینی تبخیر-تعرق مرجع در بازه زمانی 2 تا 28 روز برای داده‌های صحت‌سنجی

M9		M8		M7		روز
R	RMSE	R	RMSE	R	RMSE	
0/997	0/11	0/998	0/11	0/999	0/07	1
0/994	0/30	0/994	0/29	0/997	0/22	2
0/990	0/37	0/992	0/34	0/993	0/32	3
0/985	0/47	0/988	0/42	0/991	0/36	4
0/984	0/48	0/984	0/47	0/987	0/43	5
0/981	0/52	0/982	0/51	0/987	0/44	6
0/974	0/61	0/980	0/54	0/981	0/51	7
0/972	0/63	0/976	0/58	0/978	0/56	8
0/968	0/68	0/973	0/63	0/976	0/59	9
0/949	0/84	0/959	0/76	0/974	0/61	10
0/945	0/88	0/956	0/79	0/961	0/75	11
0/942	0/90	0/946	0/88	0/953	0/82	12
0/937	0/94	0/947	0/86	0/924	1/03	13
0/942	0/90	0/935	0/95	0/911	1/11	14
0/928	1/02	0/929	0/99	0/895	1/20	21
0/929	1/00	0/925	1/04	0/894	1/22	28



شکل 4- پراکندگی مقادیر پیش‌بینی شده در مقابل مقادیر مشاهداتی برای پیش‌بینی‌های 1، 4، 7، 14، 21 و 28 روزه برای داده‌های صحت‌سنجی

نتیجه گیری

پیش بینی تبخیر-تعرق مرجع و به طبع آن نیاز آبی گیاهان مختلف می تواند کمک برای مدیریت منابع آب کشور باشد. در تحقیق حاضر عملکرد دو مدل موجک-شبکه عصبی و شبکه عصبی در پیش بینی تبخیر-تعرق مرجع روزانه در بازه زمانی 2 تا 28 روز در ایستگاه همدیدی تبریز مورد ارزیابی قرار گرفت. نتایج این تحقیق نشان داد که دو مدل موجک- شبکه عصبی و شبکه عصبی قادر هستند با دقت بالایی تبخیر-تعرق روزانه را برای یک روز بعد پیش بینی کنند. هرچند مدل شبکه عصبی توانایی مدل سازی رفتارهای غیرخطی را دارا است، ولی با توجه به ویژگی های نالیستایی سری زمانی تبخیر-تعرق مرجع روزانه، برای مدل سازی دقیق تر نیاز به پیش پردازش داده های ورودی به مدل است؛ زیرا تبدیل موجک با جدا نمودن سیگنال به فرکانس های بالا و پایین ویژگی های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می برد. همچنین نتایج این تحقیق نشان داد که استفاده از تأخیرهای زمانی بیش تر از 7 روز تأثیر چندانی بر دقت مدل های پیشنهادی ندارد و حتی در مدل بر پایه موجک موجب کاهش دقت نیز می گردد. مقایسه بین موجک های مادر مورد استفاده نیز نشان داد که موجک میر به دلیل پیچیدگی بالاتر و شباهت بیش تر به سری زمانی تبخیر-تعرق مرجع روزانه می تواند، موجب افزایش دقت پیش بینی گردد. بعد از تعیین بهترین الگوهای ورودی و موجک مادر مناسب برای پیش بینی یک روز آینده، از مدل پیشنهادی برای پیش بینی در بازه زمانی 2 تا 28 روز استفاده گردید. نتایج نشان داد که با افزایش بازه دوره پیش بینی دقت مدل کاهش می یابد. همچنین نتایج نشان داد که استفاده از تاریخچه سری زمانی در پیش بینی های بیش از 12 روز موجب افزایش دقت مدل می گردد. از نتایج تحقیق حاضر می توان در برنامه ریزی آبیاری و استفاده بهینه آب در مناطق مورد مطالعه استفاده نمود. پیشنهاد می گردد، مدل پیشنهادی تحقیق حاضر در اقلیم های مختلف ایران مورد بررسی قرار بگیرد.

تشکر و قدردانی

از سازمان هواشناسی کشور به دلیل در اختیار قرار دادن داده های هواشناسی ایستگاه همدیدی تبریز تشکر و قدردانی می گردد.

منابع

آزادلاتپه، ن، بهمنش، ج، منتصری، م. 1390. پیش بینی تبخیر-تعرق پتانسیل با استفاده از مدل های سری زمانی نشریه آب و خاک (علوم و صنایع کشاورزی). 27: 213-223.

بهمنش، ج، آزادلاتپه، ن، منتصری، م، بشارت، س. 1393. ارزیابی مدل های سری زمانی خطی و غیر خطی بیلینیر در پیش بینی تبخیر-تعرق گیاه مرجع در ایستگاه سینوپتیک ارومیه. نشریه پژوهش آب در کشاورزی. 28: 85-96

حسن زاده، ی، کردانی، ع، فاخری فردا، ا. 1391. پیش بینی خشکسالی با استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی-موجکی. فصلنامه علمی-پژوهشی آب و فاضلاب. 23: 48-59.

رجایی، ط، ابراهیمی، ه. 1393. مدل سازی نوسان های ماهانه آب زیرزمینی به وسیله تبدیل موجک و شبکه عصبی پویا. مجله مدیریت آب و آبیاری. 4: 87-73.

شفائی، م، فاخری فردا، ا، دربندی، ص، قربانی، م. 1392. پیش بینی جریان روزانه رودخانه با استفاده از مدل هیبرید موجک و شبکه عصبی؛ مطالعه موردی ایستگاه هیدرومتری ونیار در حوضه آبریز آچی چای. فصلنامه علمی پژوهشی مهندسی آبیاری و آب. 4: 14: 113-128.

شیروانی، ا، هنرت، ت. 1390. کاربرد مدل های سری های زمانی برای پیش بینی تبخیر-تعرق در ایستگاه باجگاه. مجله پژوهش آب ایران. 5: 8: 142-135.

طوفانی، پ، مساعدی، ا، فاخری فردا، ا. 1390. پیش بینی بارندگی با استفاده مستقیم از نظریه موجک. نشریه آب و خاک. 25: 5: 1217-1226

عبداللهی اسدآبادی، س، دین پژوه، ی، میرعباسی، ر. 1392. پیش بینی دبی متوسط روزانه جریان رودخانه بهشت آباد با استفاده از آنالیز موجک. نشریه آب و خاک. 28: 3: 534-545.

فولادمنده، ح. 1389. پیش بینی ماهانه تبخیر-تعرق پتانسیل گیاه مرجع در استان فارس. مجله دانش آب و خاک. 20: 4: 157-169.

معروفی، ص، امیرمردی، ک، پارسا فر، ر. 1392. پیش بینی جریان روزانه با استفاده از شبکه های عصبی مصنوعی و عصبی-موجکی (مطالعه موردی: رودخانه باراندوزچای). نشریه دانش آب و خاک. 23: 3: 93-103.

مؤمنی، ب، عباس پلنگی، ج، اقدسی، ب. 1390. تخمین تراز آب زیرزمینی با استفاده از شبکه های عصبی مصنوعی. چهارمین کنفرانس مدیریت منابع آب، دانشگاه صنعتی امیرکبیر تهران.

Adamowski, J and Sun, K. 2010. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. Journal of Hydrology. 39. 1: 85-91.

- Zheng,Q., Cai,X. 2014. Short-term forecasting of daily reference evapotranspiration using the Hargreaves-Samani model and temperature forecasts. *Agricultural Water Management*.136. 2: 42-51.
- Nourani,V., Hosseini Baghanam,A., Adamowski, and Kisi,O. 2014. Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review. *Journal of Hydrology*. 514. 3: 358-377.
- Shoab,M., Shamseldin,A.Y., Melville,B.W and Khan,M.M. 2015. Runoff forecasting using hybrid Wavelet Gene Expression Programming (WGEP) approach. *Journal of Hydrology*.272. 1:326-344.
- Tabari, H., Marofi, S., Sabziparvar, A.A. 2010. Estimation of daily pan evaporation using artificial neural network and multivariate non-linear regression. *Irrigation Science*. 28. 5:399-406.
- Tabari,H., Marofi,S., Aeni,A., Talaee,P.H., Mohammadi,K. 2011. Trend analysis of reference evapotranspiration in the western half of Iran. *Agricultural and Forest Meteorology*. 151. 2: 128-136.
- Trajkovic,S., Todorovic,B., Stankovic,M. 2003. Forecasting of reference evapotranspiration by artificial neural networks. *Journal of Irrigation and Drainage Engineering*. 129. 6: 454-457.
- Wang,W.G and Luo,Y.F. 2007. Wavelet network model for reference crop evapotranspiration forecasting. In *Wavelet Analysis and Pattern Recognition*. International Conference on IEEE. 2 : 751-755.
- Bachour,R., Maslova,I., Ticlavilca,A., Walker,W and McKee,M. 2015. Wavelet-multivariate relevance vector machine hybrid model for forecasting daily evapotranspiration. *Stochastic Environmental Research and Risk Assessment*.29. 2:1-15.
- Budu,K. 2013. Comparison of wavelet-based ANN and regression models for reservoir inflow forecasting. *Journal of Hydrologic Engineering*. 19. 7: 1385-1400.
- Mehr,A.D., Kahya,E and Olyaie,E. 2013. Streamflow prediction using linear genetic programming in comparison with a neuro-wavelet technique. *Journal of Hydrology*. 50. 5:240-249.
- Heil,C.E and Walnut,D.F. 1989. Continuous and discrete wavelet transforms. *SIAM review*. 31.4: 628-666.
- Hykin,S. 1999. *Neural Networks: A Comprehensive Foundation*. Printice-Hall. Inc., New Jersey.
- Kisi,O. 2010. Wavelet regression model for short-term streamflow forecasting. *Journal of Hydrology*. 389.3: 344-353.
- Kisi,O. 2008. The potential of different ANN techniques in evapotranspiration modelling. *Hydrological Processes*. 22. 14: 2449-2460.
- Landeras,G., Ortiz-Barredo,A and López,J.J. 2009. Forecasting weekly evapotranspiration with ARIMA and artificial neural network models. *Journal of Irrigation and Drainage Engineering*. 135. 3: 323-334.
- Luo,Y., Chang,X., Peng,Sh., Khan,Sh., Wang,W.,

Forecasting of Daily Reference Crop Evapotranspiration Using Wavelet-Artificial Neural Network Hybrid Model

M. Karbasi¹

Received: Aug.11, 2015

Accepted: Dec.16, 2015

Abstract

Reference crop evapotranspiration is one of the most important and effective factors for optimizing agricultural water consumption and water resources management. Forecasting of daily reference evapotranspiration can be used for short-term planning of irrigation water requirements. In recent years the use of artificial neural networks and wavelet-neural hybrid model has become very popular in the forecasting of hydrological parameters. The aim of the present study is to use artificial neural network and wavelet-neural network models to forecast reference evapotranspiration in the range of 1 to 28 days ahead at Tabriz synoptic station. For this purpose, a 10-year period (2000 to 2009), 7 years (2000-2006) for training and 3 years (2007-2009) to test and validation were considered. To create daily reference evapotranspiration time series at the given period, standard equation Penman-Monteith 56 is used. Different combinations of input data (various delays) and various mother wavelets were used. Results of reference evapotranspiration forecasts for a one day ahead, showed that the wavelet-ANN model (RMSE=0.07 mm/day and R=0.999) compared to the artificial neural network model (RMSE=0.69 mm/day and R=0.964) has higher accuracy in forecasting of reference evapotranspiration. The results showed that the use of time delays of 1 to 7 (M7) and 1 to 6 (M6) days can provide the highest accuracy and fewer delays and delays from one year to two years can reduce the accuracy of the models. Comparison of mother wavelets showed that Meyer wavelet due to greater complexity and similarity to the time series of reference evapotranspiration would increase the accuracy of forecasting. To forecast reference evapotranspiration in 2 to 28 days ahead, the wavelet-neural network with Meyer wavelet model was used. The results showed that the increasing of the forecasting period from 2 to 28 days would decrease the accuracy of models (R is ranged from 0.997 to 0.929 for 2 and 28 days ahead). Also, at forecasting 2 to 12 days, annual delays reduced the accuracy of the model, while at 13 to 28-day annual delay increased the accuracy of models. Finally, to compare the models, statistically, t and F tests were performed to compare the mean and variance. The comparison showed that in all the proposed models, at 99 and 95 percent levels, there was no significant difference between the results and observations. The results of this study can be used in irrigation scheduling at study area.

Key words: Crop water requirement, Time series, Wavelet, neural network

1 - Assistant professor of water Engineering Department of University of Zanjan
(*-Corresponding Author Email: m.karbasi@znu.ac.ir)