

## پیش‌بینی تبخیر-تعرق مرجع هفتگی با استفاده از مدل ترکیبی موجک-فازی عصبی تطبیقی

مسعود کرباسی<sup>۱\*</sup>

استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه زنجان.

m.karbasi@znu.ac.ir

### چکیده

تبخیر-تعرق مرجع یکی از مهم‌ترین و مؤثرترین مؤلفه‌ها در بهینه‌سازی مصرف آب کشاورزی و مدیریت منابع آب می‌باشد. در سال‌های اخیر استفاده از روش‌های هوش مصنوعی و مدل هیبریدی بر پایه موجک در پیش‌بینی پارامترهای هیدرولوژیکی بسیار متداول گشته است. در مطالعه حاضر کاربرد روش‌های ANFIS و موجک-ANFIS در پیش‌بینی تبخیر-تعرق مرجع هفتگی مرجع در ایستگاه‌های همدیدی تبریز، اهواز، بندرعباس و رامسر که دارای اقلیم‌های مختلفی هستند، مورد بررسی و ارزیابی قرار گرفت. بدین منظور یک دوره آماری ۲۰ ساله (۱۹۹۰ الی ۲۰۰۹) که ۱۵ سال (۱۹۹۰-۲۰۰۴) آن برای آموزش و پنج سال انتهایی (۲۰۰۹-۲۰۰۵) جهت آزمون مدل‌های مختلف در نظر گرفته شد. ترکیب‌های مختلفی از داده‌های ورودی (تأخیرهای مختلف) و انواع موجک‌های مادر مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل هیبریدی موجک-ANFIS در هر چهار ایستگاه همدیدی مورد استفاده نسبت به مدل ANFIS دارای توانایی و دقت بالاتری در پیش‌بینی تبخیر-تعرق هفتگی می‌باشد. همچنین نتایج نشان داد که استفاده از تأخیرهای زمانی سالانه در مدل ANFIS موجب افزایش دقت گردید درحالی‌که در مدل موجک-ANFIS استفاده از تأخیرهای زمانی سالانه موجب افزایش دقت نمی‌گردد و در برخی موارد حتی موجب کاهش دقت نیز می‌گردد. بررسی انواع موجک‌های مادر نیز نشان داد که موجک‌میر مناسب‌ترین نوع موجک برای پیش‌بینی تبخیر-تعرق مرجع در مقیاس هفتگی می‌باشد. از نتایج تحقیق حاضر می‌توان در برنامه‌ریزی آبیاری مناطق مورد مطالعه استفاده نمود.

واژه‌های کلیدی: سری زمانی، تبدیل موجک، ANFIS.

<sup>۱</sup> - آدرس نویسنده مسئول : دانشگاه زنجان، گروه مهندسی آب.

\* - دریافت: آبان ۱۳۹۴ و پذیرش: اسفند ۱۳۹۴

## مقدمه

ایران کشوری با متوسط ریزش‌های جوی ۲۵۰ میلی‌متر است و در زمره مناطق خشک و نیمه‌خشک جهان طبقه‌بندی می‌گردد. محدودیت منابع آب و نبود آب باکیفیت مناسب از عمده‌ترین مشکلات کشاورزی در کشور است؛ بنابراین یافتن راهکارهایی برای غلبه بر کمبود آب در این مناطق همواره از اولویت‌های مطالعاتی و تحقیقاتی است. تقاضای آب و مصرف آن در اکوسیستم‌های کشاورزی به شدت وابسته به پارامترهای اقلیمی است. در برنامه‌ریزی و مدیریت منابع آب برای آبیاری نیاز به تجزیه تحلیل متغیرهای هیدرولوژیکی نظیر بارش و تبخیر-تعرق وجود دارد. استفاده از اطلاعات گذشته در این 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. با این حال، برخی روش‌های آماری تجزیه و تحلیل سری‌های زمانی می‌توانند موجب کاهش خطای پیش‌بینی گردند. کشاورزان و متصدیان سامانه‌های آبیاری می‌توانند، در مورد آب آبیاری مورد نیاز بر اساس پیش‌بینی‌های بارش و آب مورد نیاز محصولات، تصمیم‌گیری‌ها را بر اساس زمان واقعی<sup>۱</sup> اعمال کنند. بارش معمولاً در پیش‌بینی هوا از طریق پیش‌بینی وضعیت آب‌وهوا پیش‌بینی می‌شود، در حالی که نیاز آبی گیاهان در پیش‌بینی‌ها انجام نمی‌پذیرد. با توجه به اینکه نیاز آبی گیاهان از حاصل ضرب تبخیر-تعرق مرجع ( $ET_0$ ) در ضریب گیاهی  $k_e$  به دست می‌آید و  $k_e$  تابعی از نوع گیاه و مرحله رشد است (آلن و همکاران، ۱۹۹۸)، پیش‌بینی تبخیر-تعرق مرجع ( $ET_0$ ) نقش مهمی را در برنامه‌ریزی زمان واقعی آبیاری ایفا می‌کند.

استفاده از مدل‌های سری زمانی در پیش‌بینی تبخیر-تعرق مرجع در مقیاس‌های زمانی ماهیانه و هفتگی

توسط محققین مختلف مورد بررسی و تحقیق قرار گرفته است. فولادمند و همکاران (۱۳۸۹) با استفاده از مدل‌های سری زمانی تبخیر-تعرق مرجع ماهانه را در شماری از ایستگاه‌های همدیدی استان فارس پیش‌بینی نمودند. آن‌ها با مقایسه مقادیر پیش‌بینی شده با محاسبه شده در هر ایستگاه از نظر آماری نشان دادند که مدل سری زمانی مناسب برای پیش‌بینی  $ET_0$  در ایستگاه‌های مختلف یکسان نیست. به علاوه در کلیه ایستگاه‌های ذکر شده بین مقادیر پیش‌بینی شده و محاسبه شده تفاوت معنی‌داری وجود ندارد، لذا می‌توان با استفاده از مدل‌های سری زمانی مناسب برای هرایستگاه مقادیر ماهانه  $ET_0$  پیش‌بینی نمود.

قهرمان و قره‌خانی (۱۳۹۰) توانمندی مدل‌های ARIMA در برآورد مقادیر روزانه تبخیر از تشت در ایستگاه شیراز را مورد بررسی قرار دادند. نتایج آن‌ها نشان داد که مدل سری زمانی  $ARIMA(1,1,1)$  عملکرد بسیار مطلوب‌تری نسبت به سایر مدل‌های ARIMA دارد. شیروانی و هنر (۱۳۹۰) پیش‌بینی مقادیر تبخیر-تعرق ماهانه و هفتگی با استفاده از مدل‌های اتورگرسیو-میانگین متحرک تلفیق شده فصلی را برای ایستگاه باجگاه مورد بررسی قرار دادند. نتایج نشان داد که مدل فوق قادر است مقادیر تبخیر-تعرق را در مقیاس‌های اشاره شده به خوبی پیش‌بینی کند. لاندراست و همکاران (۲۰۰۹) مدل ARIMA را جهت پیش‌بینی مقادیر هفتگی تبخیر-تعرق در شمال اسپانیا مورد ارزیابی قرار دادند. نتایج آن‌ها نشان داد که مدل فوق نسبت به مقادیر متوسط بلندمدت دقت بالاتری را دارا هست. آزاد طلاپه و همکاران (۱۳۹۲) عملکرد مدل‌های سری زمانی را در پیش‌بینی تبخیر-تعرق ماهانه در ایستگاه همدیدی ارومیه مورد ارزیابی قرار دادند. نتایج آن‌ها نشان داد که مدل سری زمانی  $AR(11)$  دارای خطای کمتری نسبت به سایر مدل‌ها است. بهمنش و همکاران (۱۳۹۳) مدل‌های سری زمانی خطی را به همراه

<sup>۱</sup>Real-time

مدل غیرخطی دوسویه<sup>۱</sup> 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 مدل سازی و پیش‌بینی مقادیر ماهانه تبخیر-تعرق مرجع در مقایسه با مدل خطی را دارا است.

در زمینه پیش‌بینی تبخیر-تعرق مرجع با استفاده از پیش‌بینی‌های هواشناسی می‌توان به موارد زیر اشاره نمود. لیو و همکاران (۲۰۱۴) مدلی را با استفاده از مدل هارگریوز - سامانی واسنجی شده و داده‌های پیش‌بینی دمای هوا در افق هفت‌روزه ارائه دادند. نتایج به‌دست‌آمده نشان داد که نتایج مدل پیشنهادی با نتایج معادله پنمن-مانیتث دارای همبستگی بالایی هستند و مدل فوق‌قادر است با خطای مطلق یک میلی‌متر در روز تبخیر-تعرق مرجع را پیش‌بینی کند. تیان و همکاران (۲۰۱۰) و سیلوا و همکاران (۲۰۱۲) نشان دادند که پیش‌بینی هواشناسی با استفاده از روش‌های عددی می‌تواند به‌عنوان راه‌کاری مناسب جهت پیش‌بینی تبخیر-تعرق در آینده مورد استفاده قرار بگیرد.

در زمینه کاربرد روش‌های هوش مصنوعی در برآورد تبخیر-تعرق مرجع تحقیقات متعددی صورت گرفته است (کیشی، ۲۰۰۸ و طبری و همکاران، ۲۰۱۰)، ولی کاربرد روش‌های هوش مصنوعی در پیش‌بینی مقادیر آینده تبخیر-تعرق مرجع کمتر مورد توجه قرار گرفته و تحقیقات محدودی در این زمینه موجود است. تراکویچ و همکاران (۲۰۰۳) با استفاده از شبکه‌های عصبی نوع RBF<sup>۲</sup> 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. لاندراکس و همکاران (۲۰۰۹) با استفاده از شبکه‌های عصبی مصنوعی، تبخیر-تعرق مرجع هفتگی را پیش‌بینی کردند. آن‌ها در

تحقیق خود از دو نوع شبکه عصبی مصنوعی MLP<sup>۳</sup> و RBF 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.

در سال‌های اخیر استفاده از مدل‌های ترکیبی بر پایه موجک در پیش‌بینی سری‌های زمانی هیدرولوژیکی (مانند دبی رودخانه‌ها، خشک‌سالی، بارندگی، سطح آب زیرزمینی و غیره)، مورد توجه بسیاری از محققان بوده است (نورانی و همکاران، ۲۰۱۴). برنامه‌ریزی آبیاری معمولاً بر اساس تناوب‌های هفتگی برنامه‌ریزی می‌شود و در شرایط عرضه محدود آب از مخازن آب، پیش‌بینی هفتگی تبخیر-تعرق مرجع می‌تواند در تخصیص آب مورد نیاز کشاورزان مورد توجه قرار بگیرد (لاندراکس و همکاران، ۲۰۰۹). با توجه به اهمیت مسئله پیش‌بینی نیاز آبی گیاهان که یکی از مهم‌ترین مصرف‌کنندگان آب می‌باشد، در تحقیق حاضر پیش‌بینی هفتگی تبخیر-تعرق مرجع با استفاده از مدل‌های فازی-عصبی و موجک-فازی عصبی در چهار ایستگاه همدیدی اهواز، تبریز، رامسر و بندرعباس که دارای اقلیم‌های مختلف هستند، صورت پذیرفت.

اهداف تحقیق حاضر عبارت‌اند از:

پیش‌بینی تبخیر-تعرق مرجع هفتگی با استفاده از مدل فازی-عصبی، پیش‌بینی تبخیر-تعرق مرجع هفتگی با استفاده از مدل هیبریدی موجک-فازی عصبی و مقایسه عملکرد دو مدل ذکرشده در چهار اقلیم مختلف ایران

## مواد و روش‌ها

### منطقه مورد مطالعه

برای پیش‌بینی تبخیر-تعرق مرجع هفتگی چهار ایستگاه همدیدی بندرعباس، اهواز، تبریز و رامسر که دارای چهار اقلیم متفاوت هستند انتخاب شدند. مشخصات و مختصات ایستگاه‌های ذکرشده در جدول ۱

<sup>۳</sup>Multi-Layer Perceptron

<sup>۱</sup>Bilinear

<sup>۲</sup>Radial Basis Function

ارائه گشته است. در مطالعه حاضر، داده‌های اقلیمی روزانه کمینه و بیشینه دما، کمینه و بیشینه رطوبت نسبی، سرعت باد و ساعات آفتابی مربوط به ایستگاه‌ها مربوط به دوره آماری سال ۱۹۸۹ تا ۲۰۰۹ برای محاسبه تبخیر و تعرق

مرجع روزانه مورد استفاده قرار گرفت. سپس مجموع تبخیر-تعرق مرجع هفتگی با استفاده از داده‌های روزانه محاسبه گردید.

جدول ۱- مشخصات ایستگاه‌های مورد مطالعه در بازه زمانی ۱۹۵۵-۲۰۱۰

| ایستگاه  | عرض جغرافیایی |       | طول جغرافیایی |       | ارتفاع از سطح دریا (m) | متوسط دما (C) | متوسط بارش (mm) | اقلیم (آمیزه)     |
|----------|---------------|-------|---------------|-------|------------------------|---------------|-----------------|-------------------|
|          | درجه          | دقیقه | درجه          | دقیقه |                        |               |                 |                   |
| بندرعباس | ۲۷            | ۱۳    | ۵۶            | ۲۲    | ۹/۸                    | ۲۷            | ۱۷۶/۱           | بیابانی گرم شدید  |
| رامسر    | ۳۶            | ۵۴    | ۵۰            | ۴۰    | -۲۰                    | ۱۶/۱          | ۱۲۰۶/۲          | خیلی مرطوب        |
| اهواز    | ۳۱            | ۲۰    | ۴۸            | ۴۰    | ۲۲/۵                   | ۲۵/۴          | ۲۰۹/۲           | بیابانی گرم میانه |
| تبریز    | ۳۸            | ۵۳    | ۴۶            | ۱۷    | ۱۳۶۱                   | ۱۲/۶          | ۲۸۳/۸           | خشک سرد           |

#### معادله پنمن-مانتیت

است) می‌باشند. در رابطه (۱)،  $G$  شار گرمای خاک می‌باشد که مقدار آن برای دوره‌های روزانه و ده روز به‌طور نسبی پایین می‌باشد. بنابراین می‌توان از آن صرف‌نظر کرد (آلن و همکاران، ۱۹۹۸). در معادله ۱ فرض بر اینست که ارتفاع گیاه چمن مرجع ۰/۱۲ متر و مقاومت سطحی آن ۷۰ ثانیه بر متر است (آلن و همکاران، ۱۹۹۸). در تحقیق حاضر با استفاده از داده‌های هواشناسی روزانه ایستگاه‌های همدیدی مورد مطالعه، تبخیر-تعرق مرجع روزانه محاسبه و سپس با جمع مقادیر روزانه برای یک هفته، تبخیر-تعرق مرجع هفتگی تعیین گردید.

#### تبدیل موجک

موجک، یک موج کوچک است که انرژی آن در ناحیه کوچکی متمرکز شده و ابزار مناسبی برای بررسی پدیده‌های گذرا است. موجک نوسان حداقلی دارد که به سمت صفر نزول می‌کند و این نزول باید در جهات مثبت و منفی واقع در دامنه‌اش محدود شود. این مشخصه باعث می‌شود که موجک انعطاف‌پذیر بوده و مانند یک تابع رفتار کند، بنابراین با توجه به رفتارهای موجی نامنظم پدیده‌های هیدرولوژیک، قابلیت مدل‌سازی این پدیده‌ها توسط امواج نامنظم (موجک‌ها) نسبت به امواج منظم (امواج سینوسی) بیشتر است (حسن‌زاده و همکاران، ۱۳۹۱).

موجک دارای سه مشخصه تعداد نوسان محدود، بازگشت سریع به صفر در هر دو جهت مثبت و منفی در

به منظور برآورد مقدار  $ET_0$  روزانه (میلی‌متر بر روز) از روش پنمن-مانتیت مطابق معادله زیر استفاده گردید (آلن و همکاران، ۱۹۹۸):

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

در رابطه فوق  $u$  سرعت باد در ارتفاع دو متری از سطح زمین (متر بر ثانیه)،  $\gamma$  ضریب سایکرومتری (کیلوپاسکال بر درجه سلسیوس) که تابعی از فشار محل مورد نظر است،  $\Delta$  شیب منحنی فشار (کیلو پاسکال بر درجه سانتی‌گراد) که تابعی از دمای متوسط روزانه است،  $T$ : متوسط دمای روزانه،  $e_s - e_a$  کمبود فشار بخار اشباع است که برای تعیین  $e_a$  (فشار بخار واقعی) از دمای نقطه شبنم و برای تعیین  $e_s$  (فشار بخار اشباع) از حداکثر و حداقل دمای روزانه، استفاده شده است. برای محاسبه تابش خالص  $R_n$  روابط زیر مورد استفاده قرار گرفت:

$$R_n = R_{ns} - R_{nl} \quad (2)$$

$$R_{ns} = (1 - \alpha)R_s \quad (3)$$

$$R_{nl} = \sigma \left[ \frac{T_{max,k}^4 + T_{min,k}^4}{2} \right] (0.34 - 0.14\sqrt{e_a}) \left( 1.35 \frac{R_s}{R_{so}} - 0.35 \right) \quad (4)$$

$$R_{so} = (0.75 + 2 \times 10^{-5}Z)R_a \quad (5)$$

در روابط فوق  $\alpha$  ضریب آلبدو برای پوشش گیاهی که برای گیاه چمن مرجع ۰/۲۳ فرض می‌شود،  $\sigma$  ثابت قانون استفان-بولتزمن،  $Z$  ارتفاع از سطح دریا و  $R_a$  تابش فرازمینی (که تابع زمان و موقعیت جغرافیایی

انتقال زمان بوده و وابسته به  $s_0$  می‌باشند.

### سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)

مدل‌های فازی-عصبی که توسط جانگ در سال ۱۹۹۳ گسترش یافت، برای تسهیل فرایند یادگیری و انطباق، منطق فازی را با شبکه‌های عصبی - مصنوعی ترکی می‌کند. درواقع در مدل‌های فازی-عصبی برای حل مشکل شناسایی پارامترهای سیستم استنتاج فازی از یک شبکه تطبیقی که حالت عمومی شبکه عصبی پیشرو چندلایه است، استفاده می‌شود. نکته مهم منطق فازی امکان برقراری ارتباط بین فضای ورودی به فضای خروجی است و ساز و کار اولیه برای انجام این کار فهرستی از جملات If-Then است، که قانون نامیده می‌شوند. داشتن روشی که با استفاده از آن بتوان اطلاعات موجود برای ساخت این قواعد را استفاده کرد به عنوان ابزاری کارآمد بشمار می‌رود. از طرفی، شبکه‌های عصبی مصنوعی به دلیل قابلیت‌های آموزش‌پذیری با استفاده از الگوهای مختلف آموزشی می‌توانند ارتباط مناسبی بین متغیرهای ورودی و خروجی ایجاد نمایند. لذا استفاده ترکیبی از سامانه استنباط فازی و شبکه عصبی مصنوعی به‌عنوان ابزاری قدرتمند که قابلیت پیش‌بینی نتایج با استفاده از داده‌های عددی موجود را دارند، تحت عنوان سامانه استنتاج تطبیقی عصبی-فازی معرفی می‌شود. لذا این سیستم از الگوریتم‌های شبکه عصبی و منطق فازی به‌منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند.

ANFIS شامل پنج لایه است:

لایه اول، گره‌های ورودی: هر گره از این لایه مقادیر عضویتی که به هر یک از مجموعه‌های فازی مناسب تعلق دارند، با استفاده از تابع عضویت تولید می‌کند.

$$O_{1,i} = \mu_{A_i}(x) \text{ for } i=1,2 \quad (9)$$

$$O_{1,i} = \mu_{B_{i-2}}(y) \text{ for } i=3,4 \quad (10)$$

که  $x$  یا  $y$  ورودی‌های غیرفازی به گره  $i$  و  $A_i$  و  $B_i$  برچسب‌های زبانی هستند که به ترتیب با توابع عضویت

دامنه خود و میانگین صفر است که شرط مقبولیت نامیده می‌شود و به شکل رابطه زیر بیان می‌شود:

$$\int_{-\infty}^{+\infty} \varphi(t) dt = 0 \quad (6)$$

که در آن:

$\varphi(t)$ : تابع تبدیل موج (موجک مادر) است. عبارت مادر به این دلیل به‌کاررفته است که توابع (موجک‌های) متفاوت به وجود آمده بر اساس پارامترهای مقیاس و انتقال همگی از تابع پایه (موجک مادر) ناشی می‌شوند. تبدیل موجک عملگری است که یک تابع را به مجموعه‌ای از تبدیل موجک‌های مادر اصلاح‌شده تبدیل می‌کند که این تبدیل موجک‌های اصلاح‌شده همان تبدیل موجک دختر می‌باشند. (معروفی و همکاران، ۱۳۹۲) تبدیلات موجک به دو نوع پیوسته و گسسته تقسیم می‌شوند. تبدیل موجک پیوسته یک سیگنال  $x(t)$  به‌صورت زیر تعریف می‌گردد:

$$CWT_x^\varphi = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} x(t) \varphi\left(\frac{t-\tau}{s}\right) dt \quad (7)$$

در رابطه فوق  $\varphi$ : تابع موجک،  $s(>1)$ : پارامتر مقیاس یا اتساع،  $\tau$ : پارامتر انتقال زمان،  $t$ : زمان و علامت \* نشان‌دهنده مزدوج مختلط است. روش  $CWT$ ، سیگنال را به‌وسیله تعداد بیشمار و نامحدودی از پارامترهای مقیاس و انتقال تجزیه می‌کند. در این روش پارامترهای مقیاس و انتقال به‌صورت پیوسته تغییر می‌کنند. ازاین‌رو محاسبه ضرایب موجک برای همه مقیاس‌های ممکن، علاوه بر تولید حجم زیادی از اطلاعات، نیاز به کوششی فراوان 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 (عبداللهی اسدآبادی و همکاران، ۱۳۹۳). شکل گسسته تابع موجک به‌صورت زیر است:

$$\varphi_{j,k}(t) = \frac{1}{\sqrt{|s_0^j|}} \varphi\left(\frac{t-k\tau_0 s_0^j}{s_0^j}\right) \quad (8)$$

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،  $\tau_0$  ثابت

$\mu_{B_i}$  و  $\mu_{A_i}$  مشخص می‌شوند.

لایه دوم: هر گره در این لایه در سیگنال ورودی ضرب می‌شود و خروجی نتیجه‌ای از تمامی سیگنال‌های ورودی است:

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_{i-2}}(y), \quad i = 1, 2 \quad (11)$$

لایه ۳: گره  $i$  ام این لایه که با  $N$  نام‌گذاری شده که نسبت به قوانین نرمال شده را محاسبه می‌کند:

$$O_{3,i} = \bar{w} = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (12)$$

لایه ۴: گره  $i$  در این لایه مشارکت قانون  $i$  ام را به سمت خروجی مدل با استفاده از تابع زیر محاسبه می‌کند.

$$O_{4,i} = \bar{w}_i f = \bar{w}_i(p_i + q_i + r_i), \quad i = 1, 2 \quad (13)$$

که در آن:  $\bar{w}_i$  خروجی لایه سه و  $\{p_i, q_i, r_i\}$  مجموعه پارامترها هستند.

لایه ۵: تنها گره این لایه، خروجی کلی ANFIS به عنوان جمع‌بندی از تمام ورودی‌های مدل که غیر فازی شده است را مطابق زیر محاسبه می‌کند:

$$O_{5,i} = \sum_{i=1}^4 \bar{w}_i f = \frac{\sum_{i=1}^4 w_i f}{\sum_{i=1}^4 w_i} \quad (14)$$

برای تولید سیستم فازی (فازی سازی) از سه روش می‌توان استفاده کرد: ۱- بخش‌بندی شبکه‌ای<sup>۱</sup>، ۲- خوشه‌بندی جایگزین<sup>۲</sup> و ۳- خوشه‌بندی فازی C-means. هنگامی که تعداد داده‌های ورودی زیاد باشد روش بخش‌بندی شبکه‌ای با توجه به افزایش تعداد قواعد فازی به زمان زیادی جهت محاسبات نیاز خواهد داشت. برای به حداقل رساندن تعداد قوانین، اولین مرحله در ایجاد سیستم فازی، خوشه‌بندی داده‌های ورودی و خروجی است. خوشه‌بندی داده‌ها را از یک مجموعه بزرگ به چندین گروه که دارای بیشترین تشابه هستند تقسیم می‌کند.

### خوشه‌بندی جایگزین

زمانی که هیچ ایده‌ای در مورد تعداد خوشه‌ها در خوشه‌بندی داده‌های با حجم بالا وجود نداشته باشد،

خوشه‌بندی جایگزین می‌تواند مرکز خوشه‌ها را در مجموعه داده‌ها با سرعت بالایی پیدا کند. خوشه‌بندی جایگزین برای اولین بار توسط چپو (۱۹۹۴) پیشنهاد گردید. در این روش تمامی نقاط داده به‌عنوان کاندیدای مرکز خوشه در نظر گرفته می‌شوند و مقدار چگالی (هرچه تعداد نقاط در نزدیکی مرکز کلاستر بیشتر باشد چگالی افزایش می‌یابد) در نقاط  $x_i$  به شرح زیر تعریف می‌شود:

$$D_i = \sum_{j=1}^n \exp \left( -\frac{\|x_i - x_j\|^2}{\left(\frac{r_a}{2}\right)^2} \right) \quad (15)$$

در رابطه فوق  $r_a$ : شعاع همسایگی است که در محدود ۰/۱ تا ۱ می‌باشد و مقدار بهینه آن را می‌توان با استفاده از روش آزمون و خطابه دست آورد. اگر تعداد زیادی نقاط همسایگی مرکز خوشه باشند، نقطه فوق (مرکز خوشه) دارای چگالی بیشتری خواهد بود. بعد از خوشه‌بندی، مقدار چگالی برای تمامی نقاط محاسبه می‌شود و نقطه‌ای که دارای بیشترین مقدار چگالی است ( $D_{c1}$ ) به‌عنوان مرکز خوشه اول ( $x_{c1}$ ) انتخاب می‌شود. بنابراین مقدار چگالی در بقیه نقاط  $x_i$  برابر خواهد بود با:

$$D_i = D_i - D_{c1} \exp \left( -\frac{\|x_i - x_j\|^2}{\left(\frac{r_h}{2}\right)^2} \right) \quad (16)$$

که در اینجا  $r_h$  یک عدد مثبت است که مقدار آن  $1.5r_a$  است. در نقاط داده در نزدیکی مرکز خوشه اول، مقدار چگالی نقاط داده‌ها به میزان قابل‌توجهی دارای کاهش خواهند بود. بنابراین مرکز خوشه بعدی که به‌عنوان نقطه با بیشترین چگالی خواهد بود از مرکز خوشه اول دارای فاصله خواهد بود. این فرایند تا زمانی پیدا می‌کند تا تعداد کافی مراکز خوشه به دست آید (چپو، ۱۹۹۴). در تحقیق حاضر نیز به علت تعداد زیاد داده‌های ورودی (افزایش تعداد تأخیر و تجزیه با تبدیل موجک تعداد داده‌های ورودی را افزایش می‌دهد) روش خوشه‌بندی جایگزین جهت ایجاد سیستم فازی مورد استفاده قرار گرفته است. ساختار مدل هیبریدی موجک-فازی عصبی هدف مدل هیبریدی موجک-فازی عصبی مورد استفاده در تحقیق حاضر، پیش‌بینی تبخیر-تعرق مرجع هفتگی با

<sup>1</sup> Grid Partition

<sup>2</sup> Subclustering

$$R^2 = \frac{(\sum_{i=1}^N (O_i - \bar{O}_i)(P_i - \bar{P}_i))^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2 \sum_{i=1}^N (P_i - \bar{P}_i)^2} \quad (21)$$

در روابط فوق  $O_i$  مقادیر محاسبه شده از معادله پنمن-مانتیت و  $P_i$  مقادیر پیش‌بینی شده از مدل‌های مختلف و  $\bar{O}_i$  و  $\bar{P}_i$  نیز به ترتیب میانگین مقادیر محاسبه شده از معادله پنمن-مانتیت و پیش‌بینی می‌باشند.

## نتایج و بحث

### داده‌های ورودی به مدل‌ها

جهت به دست آوردن ترکیب مناسب ورودی‌های مدل، چندین ترکیب مختلف از داده‌های ورودی موردبررسی قرار گرفت. جدول ۲، ۹ ترکیب مختلف از داده‌های ورودی را نشان می‌دهد. در ترکیب جدول اعداد ۵۲ و ۱۰۴ به‌عنوان تأخیرهای یک و دوساله در نظر گرفته شده‌اند. ترکیب‌های فوق به‌عنوان ورودی برای مدل‌های ANFIS و موجک-ANFIS مورد استفاده قرار گرفت.

### نتایج مدل ANFIS

به‌منظور مدل‌سازی با مدل ANFIS، جعبه‌ابزار منطق فازی نرم‌افزار Matlab 2015a مورد استفاده قرار گرفت. برای ایجاد سیستم فازی مورد استفاده در مدل ANFIS روش خوشه‌بندی جایگزین مورد استفاده قرار گرفت. شعاع خوشه بین ۰/۱ تا ۱ در نظر گرفته شد. در تحقیق حاضر ۲۰ سال دوره آماری ۱۹۹۰ الی ۲۰۰۹ برای چهار ایستگاه منتخب در نظر گرفته شد. سال‌های آماری ۱۹۹۰-۲۰۰۴ (۷۵ درصد داده‌ها) به‌منظور آموزش و دوره ۲۰۰۵-۲۰۰۹ (۲۵ درصد داده‌ها) به‌عنوان داده‌های صحت‌سنجی انتخاب گردیدند. جدول ۳ نتایج پیش‌بینی تبخیر-تعرق مرجع هفتگی را با توجه به نوع داده ورودی در مرحله صحت‌سنجی نشان می‌دهد. با توجه به جدول ۳ مشاهده می‌گردد که استفاده از مجموعه ورودی‌های ۶، ۷، ۸ و ۹ با تأخیرهای سالانه موجب بهبود عملکرد مدل ANFIS می‌شود. در ایستگاه تبریز مجموعه ورودی نه با

استفاده از زیرسری‌های به‌دست آمده از تبدیل موجک گسسته است. بدین منظور، ابتدا سری زمانی اصلی با استفاده از تبدیل موجک گسسته به زیرسری‌های تقریب<sup>۱</sup> (A) که دارای فرکانس کم بوده نشان‌دهنده روند کلی داده‌های موجود هستند و جزئیات<sup>۲</sup> (D) که دارای فرکانس بالا هستند نشان‌دهنده تغییرات محدوده داده‌ها هستند، تجزیه می‌شوند. در مرحله بعد زیرسری‌های تقریب  $A_1, D_1, D_2, \dots, D_n$  که  $n$  سطح تجزیه می‌باشد، به‌عنوان ورودی‌های مدل فازی-عصبی برای پیش‌بینی تبخیر-تعرق مرجع، در نظر گرفته شدند. 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 زیر مورد استفاده شد (نورانی و همکاران، ۲۰۱۴).

$$L = \text{Int}[\log(N)] \quad (17)$$

در رابطه فوق  $L$  سطح تجزیه،  $N$  تعداد داده‌های سری زمانی و  $\text{Int}$  تابع جز صحیح می‌باشند.

### معیارهای آماری برای مقایسه مدل‌ها

به‌منظور مقایسه روابط مختلف از معیارهای آماری زیر استفاده گردیده است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - P_i)^2}{N}} \quad (18)$$

$$MBE = \frac{1}{N} \sum_{i=1}^N (O_i - P_i) \quad (19)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{O_i - P_i}{O_i} \right| \quad (20)$$

<sup>۱</sup>Approximation  
<sup>۲</sup>Details

مرجع هفتگی در ایستگاه‌های مورد مطالعه نشان می‌دهد که این مدل در ایستگاه بندرعباس با درصد خطای مطلق (MAPE) ۹/۱۱ درصد دارای بهترین عملکرد است. مقدار این خطا در ایستگاه‌های اهواز، تبریز و رامسر به ترتیب ۱۳/۴۳، ۱۴/۰۵ و ۱۵/۲۸ درصد است. این نتایج نشان‌دهنده این مطلب است که عملکرد مدل ANFIS در مناطق با اقلیم بیابانی مناسب‌تر است. شکل ۱ نیز نمودار پراکنندگی مقادیر به‌دست‌آمده از معادله پنمن مانیتث و پیش‌بینی‌شده حاصل از بهترین مجموعه ورودی را برای ایستگاه‌های موردبررسی نشان می‌دهد. لانداس و همکاران (۲۰۰۹) مقدار خطای مطلق به‌دست‌آمده از مدل‌های ARIMA و شبکه عصبی مصنوعی را در پیش‌بینی هفتگی تبخیر-تعرق مرجع بین ۱۲ الی ۱۳ درصد گزارش نمودند که به‌جز ایستگاه بندرعباس که خطای مطلق ۹/۱۱ درصد بوده است در بقیه ایستگاه‌ها مدل ANFIS نتایج ضعیف‌تری را ارائه نموده است.

RMSE ۴/۰۶ میلی‌متر در هفته و  $R^2$  ۰/۹۵۰، بهترین عملکرد را نسبت به سایر مجموعه ورودی‌های دارا است. در ایستگاه اهواز مجموعه ورودی شش با RMSE ۵/۶۴ میلی‌متر در هفته و  $R^2$  ۰/۹۲۶ دارای عملکردی بهتری نسبت به سایر مجموعه ورودی‌ها است. در ایستگاه بندرعباس مجموعه ورودی شش با RMSE ۳/۹۵ میلی‌متر در هفته و  $R^2$  ۰/۸۳۶ دارای عملکردی بهتری است. در ایستگاه رامسر مجموعه ورودی نه با RMSE ۳/۹۶ میلی‌متر در هفته و  $R^2$  ۰/۷۴۹ دارای عملکردی بهتری نسبت به سایر مجموعه ورودی‌ها است. یافته فوق با نتایج لانداس و همکاران (۲۰۰۹) در پیش‌بینی تبخیر-تعرق مرجع هفتگی مطابقت دارد. نتایج ایشان نشان داد که استفاده از تأخیرهای بیشتر زمانی موجب افزایش دقت مدل شبکه عصبی در پیش‌بینی تبخیر-تعرق مرجع هفتگی گشته است.

مقایسه مدل ANFIS در پیش‌بینی تبخیر-تعرق

جدول ۲- مجموعه مختلف متغیرهای ورودی و خروجی مدل

| متغیر خروجی | متغیرهای ورودی                                                  | مجموعه ورودی |
|-------------|-----------------------------------------------------------------|--------------|
| $ET_t$      | $ET_{t-1}$                                                      | ۱            |
| $ET_t$      | $ET_{t-1}, ET_{t-2}$                                            | ۲            |
| $ET_t$      | $ET_{t-1}, ET_{t-2}, ET_{t-3}$                                  | ۳            |
| $ET_t$      | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}$                        | ۴            |
| $ET_t$      | $ET_{t-1}, ET_{t-2}, ET_{t-52}$                                 | ۵            |
| $ET_t$      | $ET_{t-1}, ET_{t-2}, ET_{t-52}, ET_{t-104}$                     | ۶            |
| $ET_t$      | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-52}$                       | ۷            |
| $ET_t$      | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-52}$             | ۸            |
| $ET_t$      | $ET_{t-1}, ET_{t-2}, ET_{t-3}, ET_{t-4}, ET_{t-52}, ET_{t-104}$ | ۹            |

#### نتایج مدل هیبریدی موجک-ANFIS

در تحقیق حاضر از جعبه‌ابزار موجک نرم‌افزار MATLAB 2015a برای تجزیه سری زمانی استفاده گردید. همچنین اثر انواع مختلف موجک‌های مادر نیز موردبررسی قرار گرفت. بدین منظور عملکرد مدل برای موجک‌های مادر هار<sup>۱</sup> (db1)، دابچیز<sup>۲</sup> (db4، db8)، کوئفلت<sup>۳</sup> (coif1، coif3، coif5)، سیملت<sup>۴</sup> (db10)

(sym2، sym6، sym10) و میر<sup>۵</sup> (dmey) مورد بررسی و ارزیابی قرار گرفت. مؤلفه‌های تجزیه‌شده تبدیل موجک گسسته ( $A_3, D_1, D_2, D_3$ ) مورد استفاده قرار گرفت (آداموفسکی و سان، ۲۰۱۰ و کیشی، ۲۰۱۰). با توجه به اینکه تعداد داده‌های سری زمانی ۱۰۴۰ می‌باشد و استفاده از رابطه (۱۷) سطح تجزیه سه به دست می‌آید. برای بررسی تأثیر نوع موجک مادر بر نتایج نیز مجموعه داده ورودی چهار به عنوان مبنای مقایسه قرار گرفت و عملکرد موجک‌های مختلف با توجه به خطای RMSE

<sup>۱</sup> Haar

<sup>۲</sup> Daubechies

<sup>۳</sup> Coiflet

<sup>۴</sup> Symlet

<sup>۵</sup> Meyer


هیدرولوژیکی از موجک‌های مادر خانواده دابچیز (db10) استفاده شده است (عراقی و همکاران، ۲۰۱۵ و نورانی و همکاران، ۲۰۱۴). دلیل افزایش دقت در موجک میر را می‌توان به دلیل پیچیدگی بالا و شباهت به سیگنال تبخیر-تعرق مرجع هفتگی، مرتبط دانست. در تحقیق حاضر نیز با توجه به اینکه این موجک در تمامی ایستگاه‌ها بهترین عملکرد را دارا می‌باشد، بنابراین در بقیه مجموعه‌های ورودی موجک میر مورد استفاده قرار گرفت.


مورد ارزیابی قرار گرفت. شکل ۲ تأثیر نوع موجک مادر را بر عملکرد مدل موجک-فازی عصبی نشان می‌دهد. با توجه به شکل ۲ موجک میر (dmey) در مقایسه با سایر موجک‌ها دارای عملکرد بهتری می‌باشد. طوفانی و همکاران (۱۳۹۰) در پیش‌بینی بارندگی، رجایی و ابراهیمی (۱۳۹۳) در پیش‌بینی نوسانات سطح آب زیرزمینی و شعیب و همکاران (۲۰۱۵) در پیش‌بینی رواناب نیز گزارش نمودند که استفاده از موجک میر موجب افزایش دقت پیش‌بینی گشته است. درحالی‌که در اکثر تحقیقات مربوط به پیش‌بینی سری زمانی متغیرهای

جدول ۳- نتایج پیش‌بینی تبخیر-تعرق مرجع هفتگی با مدل ANFIS برای داده‌های صحت سنجی

| ایستگاه  | معیارهای آماری | ۱     | ۲     | ۳     | ۴     | ۵     | ۶     | ۷     | ۸     | ۹     |
|----------|----------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| تبریز    | RMSE           | ۴/۶۴  | ۴/۷۴  | ۴/۷۲  | ۴/۵۳  | ۴/۳۸  | ۴/۱۶  | ۴/۳۳  | ۴/۲۲  | ۴/۰۶  |
|          | R <sup>2</sup> | ۰/۹۳۴ | ۰/۹۳۳ | ۰/۹۳۳ | ۰/۹۳۸ | ۰/۹۴۲ | ۰/۹۴۸ | ۰/۹۴۳ | ۰/۹۴۶ | ۰/۹۵۰ |
|          | MAPE(%)        | ۱۶/۱۶ | ۱۶/۴۵ | ۱۶/۳۵ | ۱۶/۰۳ | ۱۵/۳۹ | ۱۴/۴۵ | ۱۵/۰۹ | ۱۴/۹۴ | ۱۴/۰۵ |
|          | MBE            | ۰/۱۹  | ۰/۱۵  | ۰/۱۵  | ۰/۱۷  | ۰     | ۰     | ۰/۰۱  | ۰/۰۳  | ۰/۰۳  |
| اهواز    | RMSE           | ۶/۵۸  | ۶/۵۰  | ۶/۵۳  | ۶/۴۹  | ۵/۸۴  | ۵/۶۴  | ۵/۸۸  | ۵/۸۶  | ۵/۶۶  |
|          | R <sup>2</sup> | ۰/۸۹۹ | ۰/۹۰۲ | ۰/۹۰۱ | ۰/۹۰۲ | ۰/۹۲۱ | ۰/۹۲۶ | ۰/۹۱۹ | ۰/۹۲۰ | ۰/۹۲۶ |
|          | MAPE(%)        | ۱۶/۴۱ | ۱۶/۴۵ | ۱۶/۰۵ | ۱۶/۰۱ | ۱۴/۰۶ | ۱۳/۷۶ | ۱۳/۹۴ | ۱۳/۸۷ | ۱۳/۴۳ |
|          | MBE            | -۰/۱۵ | -۰/۱۴ | -۰/۱۶ | -۰/۱۶ | -۰/۳۳ | -۰/۴۵ | -۰/۳۳ | -۰/۳۳ | -۰/۴۵ |
| بندرعباس | RMSE           | ۴/۳۹  | ۴/۲۴  | ۴/۲۵  | ۴/۲۷  | ۴/۰۹  | ۳/۹۵  | ۴/۱۰  | ۴/۱۴  | ۴/۰۰  |
|          | R <sup>2</sup> | ۰/۷۹۸ | ۰/۸۱۱ | ۰/۸۱۱ | ۰/۸۰۹ | ۰/۸۲۳ | ۰/۸۳۶ | ۰/۸۲۲ | ۰/۸۱۹ | ۰/۸۳۱ |
|          | MAPE(%)        | ۱۰/۱۹ | ۹/۷۶  | ۹/۷۶  | ۹/۷۸  | ۹/۵۹  | ۹/۱۱  | ۹/۶۴  | ۹/۷۲  | ۹/۲۲  |
|          | MBE            | ۰/۴۵  | ۰/۲۵  | ۰/۱۸  | ۰/۲۵  | ۰/۲۲  | ۰/۱۹  | ۰/۳۹  | ۰/۳۷  | ۰/۳۶  |
| رامسر    | RMSE           | ۴/۴۶  | ۴/۲۱  | ۴/۱۵  | ۴/۱۸  | ۴/۰۷  | ۳/۹۹  | ۴/۰۱  | ۴/۰۴  | ۳/۹۶  |
|          | R <sup>2</sup> | ۰/۶۸۴ | ۰/۷۱۹ | ۰/۷۲۶ | ۰/۷۲۳ | ۰/۷۳۷ | ۰/۷۲۶ | ۰/۷۴۴ | ۰/۷۴۱ | ۰/۷۴۹ |
|          | MAPE(%)        | ۱۷/۸۸ | ۱۶/۶۶ | ۱۶/۵۲ | ۱۶/۴۹ | ۱۵/۸۹ | ۱۵/۲۸ | ۱۵/۷۷ | ۱۵/۷۷ | ۱۵/۲۸ |
|          | MBE            | ۰/۳۳  | ۰/۳۱  | ۰/۲۴  | ۰/۲۶  | ۰/۲۳  | ۰/۲۳  | ۰/۱۷  | ۰/۱۷  | ۰/۱۵  |

\*- واحد RMSE و MBE به میلی‌متر در هفته می‌باشد.






شکل ۱- پراکندگی به دست آمده از معادله پنمن مانتیث در مقابل مقادیر پیش‌بینی‌شده در داده‌های صحت‌سنجی در مدل فازی-عصبی برای بهترین مجموعه ورودی

قرار می‌گیرند. در ایستگاه رامسر مجموعه ورودی‌های ۴، ۸ و ۹ با RMSE، ۰/۸۱ میلی‌متر در هفته و ضریب  $R^2$ ، ۰/۹۸۹ دارای دقت بالاتری هستند. مجموعه ورودی‌های سه و هفت در رتبه‌های بعدی قرار می‌گیرند. با توجه به جدول ۴ مقایسه درصد خطای مطلق (MAPE) در چهار ایستگاه مورد مطالعه نشان می‌دهد که مدل موجک-فازی عصبی در ایستگاه بندرعباس با خطای مطلق ۲/۱۶ درصد برای داده‌های صحت‌سنجی بهترین عملکرد را در بین ایستگاه‌های مورد مطالعه داشته است. مقدار خطای مطلق در ایستگاه‌های اهواز، رامسر و تبریز به ترتیب ۳/۱۸، ۳/۱۹ و ۳/۲۶ می‌باشد. شکل ۳ نیز نمودار پراکندگی به دست آمده از معادله پنمن مانتیث و پیش‌بینی‌شده حاصل از بهترین مجموعه ورودی را برای ایستگاه‌های مورد نظر نشان می‌دهد.

جدول ۴ نتایج پیش‌بینی تبخیر-تعرق مرجع با مدل هیبریدی موجک-ANFIS را برای داده‌های صحت‌سنجی در چهار ایستگاه همدیدی مورد مطالعه نشان می‌دهد. در ایستگاه تبریز مجموعه ورودی ۴ بهترین نتیجه را با RMSE، ۰/۸۲ میلی‌متر در هفته و ضریب  $R^2$ ، ۰/۹۹۸ بهترین نتیجه را ارائه کرده است. مجموعه ورودی‌های ۸ و ۹ در رتبه‌های بعدی قرار می‌گیرند. در ایستگاه اهواز مجموعه ورودی ۸ با RMSE، ۱/۲۸ میلی‌متر در هفته و ضریب  $R^2$ ، ۰/۹۹۶ بهترین پیش‌بینی را از تبخیر-تعرق مرجع هفتگی ارائه نموده است. مجموعه ورودی‌های ۴ و ۹ بعد از مجموعه هشت قرار می‌گیرند. در ایستگاه بندرعباس مجموعه ورودی‌های ۴ و ۸ با RMSE، ۰/۹۹ میلی‌متر در هفته و ضریب  $R^2$ ، ۰/۹۸۹ بهترین عملکرد را در پیش‌بینی تبخیر-تعرق مرجع هفتگی داشته‌اند. مجموعه ورودی‌های ۹ و ۳ در رتبه‌های بعدی




شکل ۲ - بررسی تأثیر نوع موجک بر عملکرد مدل موجک-فازی عصبی در ایستگاه‌های مورد مطالعه

جدول ۴ - نتایج پیش‌بینی تبخیر-تعرق مرجع هفتگی با مدل موجک-ANFIS برای داده‌های صحت‌سنجی

| ایستگاه  | معیارهای آماری | مجموعه ورودی |       |       |       |       |       |       |       |       |
|----------|----------------|--------------|-------|-------|-------|-------|-------|-------|-------|-------|
|          |                | ۱            | ۲     | ۳     | ۴     | ۵     | ۶     | ۷     | ۸     | ۹     |
| تبریز    | RMSE           | ۳/۵۰         | ۱/۴۸  | ۱/۲۲  | ۰/۸۲  | ۱/۵۵  | ۱/۵۹  | ۱/۲۶  | ۰/۸۳  | ۱/۲۱  |
|          | R <sup>2</sup> | ۰/۹۶۳        | ۰/۹۹۳ | ۰/۹۹۵ | ۰/۹۹۸ | ۰/۹۹۳ | ۰/۹۹۲ | ۰/۹۹۵ | ۰/۹۹۸ | ۰/۹۹۶ |
|          | MAPE(%)        | ۱۲/۷۱        | ۵/۶۹  | ۴/۵۶  | ۳/۲۶  | ۵/۷۹  | ۵/۷۳  | ۴/۵۴  | ۳/۱۷  | ۴/۳۷  |
|          | MBE            | -۰/۰۷        | ۰/۰۶  | -۰/۰۲ | -۰/۰۲ | -۰/۰۲ | ۰/۰۲  | -۰/۰۱ | ۰     | -۰/۰۳ |
| اهواز    | RMSE           | ۴/۴۰         | ۲/۱۲  | ۱/۷۷  | ۱/۲۹  | ۲/۳۰  | ۱/۳۳  | ۱/۸۸  | ۱/۲۸  | ۱/۳۱  |
|          | R <sup>2</sup> | ۰/۹۵۵        | ۰/۹۸۹ | ۰/۹۹۲ | ۰/۹۹۶ | ۰/۹۸۸ | ۰/۹۸۸ | ۰/۹۹۱ | ۰/۹۹۶ | ۰/۹۹۶ |
|          | MAPE(%)        | ۱۱/۴۴        | ۵/۴۱  | ۴/۴۰  | ۳/۲۲  | ۵/۴۵  | ۵/۴۶  | ۴/۴۴  | ۳/۱۸  | ۳/۱۸  |
|          | MBE            | -۰/۰۲        | -۰/۰۴ | -۰/۰۱ | ۰     | -۰/۰۵ | -۰/۰۵ | -۰/۰۱ | ۰     | ۰/۰۱  |
| بندرعباس | RMSE           | ۲/۷۸         | ۱/۶۳  | ۱/۴۰  | ۰/۹۹  | ۱/۶۴  | ۱/۷۰  | ۱/۴۹  | ۰/۹۹  | ۱/۰۹  |
|          | R <sup>2</sup> | ۰/۹۱۸        | ۰/۹۷۲ | ۰/۹۷۹ | ۰/۹۸۹ | ۰/۹۷۱ | ۰/۹۶۹ | ۰/۹۷۷ | ۰/۹۸۹ | ۰/۹۸۷ |
|          | MAPE(%)        | ۶/۴۹         | ۳/۷۸  | ۳/۱۶  | ۲/۱۶  | ۳/۷۷  | ۳/۹۹  | ۳/۲۸  | ۲/۲۴  | ۲/۴۲  |
|          | MBE            | ۰/۰۴         | ۰/۰۲  | ۰     | ۰/۰۳  | ۰     | ۰/۰۶  | ۰/۱   | ۰/۰۱  | ۰/۰۴  |
| رامسر    | RMSE           | ۲/۷۸         | ۱/۴۲  | ۱/۲۲  | ۰/۸۱  | ۱/۴۳  | ۱/۴۴  | ۱/۲۳  | ۰/۸۱  | ۰/۸۱  |
|          | R <sup>2</sup> | ۰/۸۷۶        | ۰/۹۶۸ | ۰/۹۷۶ | ۰/۹۸۹ | ۰/۹۶۷ | ۰/۹۶۷ | ۰/۹۷۶ | ۰/۹۸۹ | ۰/۹۸۹ |
|          | MAPE(%)        | ۱۰/۴۶        | ۵/۵۱  | ۴/۶۸  | ۳/۱۹  | ۵/۵۹  | ۵/۶۱  | ۴/۷۵  | ۳/۱۹  | ۳/۲۰  |
|          | MBE            | -۰/۰۲        | ۰/۰۲  | ۰     | ۰     | ۰/۰۲  | ۰/۰۴  | ۰/۰۱  | ۰     | ۰/۰۱  |

\*- واحد RMSE و MBE به میلی‌متر در هفته می‌باشد.



شکل ۳- پراکندگی به دست آمده از معادله پنمن مانیتث در مقابل مقادیر پیش‌بینی‌شده در مدل موجک-فازی عصبی برای بهترین مجموعه ورودی

زمانی توسط تبدیل موجک موجب افزایش دقت مدل‌های پیش‌بینی کننده می‌گردد. باچور و همکاران (۲۰۱۵)، با استفاده از روش <sup>۱</sup>MRVM و ترکیب آن با تبدیل موجک اقدام به پیش‌بینی تبخیر-تعرق مرجع برای ۱۶ روز آینده نمودند. نتایج آن‌ها نیز نشان داد که استفاده از تبدیلی موجک به عنوان یک روش پیش‌پردازش می‌تواند موجب افزایش دقت پیش‌بینی گردد.

لاندراس و همکاران (۲۰۰۹) تبخیر-تعرق مرجع هفتگی را با استفاده از دو مدل ARIMA و شبکه عصبی مصنوعی در شمال اسپانیا پیش‌بینی نمودند. مقدار خطای مطلق به‌دست‌آمده در مطالعه ایشان بین ۱۲ الی ۱۳ درصد بود. حال آنکه در مدل پیشنهادی موجک - ANFIS در تحقیق حاضر در تمامی ایستگاه‌های مورد بررسی، مقدار خطای مطلق کمتر از ۳/۲۵ درصد بوده است. مطلب فوق نشان‌دهنده برتری مدل موجک-ANFIS نسبت به دو مدل به‌کاربرده شده توسط لاندراس و همکاران (۲۰۰۹) است.

با توجه به جدول‌های ۳ و ۴، مقایسه مدل‌های فازی-عصبی و موجک-فازی عصبی نشان می‌دهد که پیش‌پردازش داده‌ها با استفاده از تبدیل موجک و استفاده از آن به عنوان ورودی مدل فازی-عصبی به مقدار قابل توجهی دقت مدل را در پیش‌بینی تبخیر-تعرق مرجع هفتگی افزایش داده است. نتیجه فوق توسط بسیاری از محققینی که مدل‌های هیبریدی بر پایه موجک را با مدل‌های بدون استفاده از موجک مقایسه کرده‌اند، گزارش شده است (آداموفسکی و چان، ۲۰۱۱، رامانا و همکاران، ۲۰۱۲ و نورانی و همکاران، ۲۰۱۴). کیشی و شیری (۲۰۱۲) با استفاده از مدل موجک-ANFIS تراز سطح آب زیرزمینی را به صورت ماهانه پیش‌بینی نمودند. نتایج ایشان نیز نشان داد که کاربرد تبدیل موجک گسسته به عنوان پیش‌پردازش داده‌ها موجب افزایش دقت مدل پیش‌بینی کننده گشته است. پارتال و کیشی (۲۰۰۷) نیز در پیش‌بینی بارندگی ماهانه با استفاده از مدل موجک-ANFIS به نتایج مشابهی دست یافتند. نتایج تحقیقات ذکر شده حاکی از آن است که پیش‌پردازش داده‌های سری

<sup>1</sup> Multivariate relevance vector machine

دو مدل موجک-ANFIS و ANFIS قادر هستند با دقت بالایی تبخیر-تعرق هفتگی را پیش‌بینی کنند. هرچند مدل ANFIS توانایی مدل‌سازی رفتارهای غیرخطی را دارا است، ولی با توجه به ویژگی‌های ناپایداری سری زمانی تبخیر-تعرق مرجع هفتگی، برای مدل‌سازی دقیق‌تر نیاز به پیش‌پردازش داده‌های ورودی به مدل است، زیرا تبدیل موجک با جدا نمودن سیگنال به فرکانس‌های بالا و پایین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. همچنین نتایج این تحقیق نشان داد که استفاده از تأخیرهای زمانی بیشتر از چهار هفته تأثیر چندانی بر دقت مدل‌های پیشنهادی ندارد و حتی در مدل بر پایه موجک موجب کاهش دقت نیز می‌گردد. مقایسه بین موجک‌های مادر مورد استفاده نیز نشان داد که موجک میر به دلیل پیچیدگی بالاتر و شباهت بیشتر به سری زمانی تبخیر-تعرق مرجع هفتگی می‌تواند، موجب افزایش دقت پیش‌بینی می‌گردد. از نتایج تحقیق حاضر می‌توان در برنامه‌ریزی آبیاری و استفاده بهینه آب در مناطق مورد مطالعه استفاده نمود.

### تشکر و قدردانی

از سازمان هواشناسی کشور به دلیل در اختیار قرار دادن داده‌های هواشناسی ایستگاه همدیدی تبریز، اهواز، بندرعباس و رامسر تشکر و قدردانی می‌گردد.

در مورد توجیه برتری مدل‌های بر پایه موجک می‌توان این‌گونه بیان کرد که سری زمانی هیدرولوژیکی پیچیده با استفاده از تبدیل موجک گسسته به چند سری زمانی ساده تجزیه می‌گردد، بنابراین برخی از ویژگی‌های سری زمانی اصلی نظیر دوره‌های روزانه، هفتگی، ماهانه و سالانه به وضوح بیشتری قابل مشاهده است. این برتری را می‌توان حتی در مدل‌های رگرسیونی موجک نیز مشاهده نمود. کیشی (۲۰۱۱)، پارتال (۲۰۱۵) و پاتیل و همکاران (۲۰۱۵) با استفاده از تبدیل موجک گسسته پارامترهای مرتبط با تبخیر-تعرق مرجع را تجزیه نموده و از آن‌ها به‌عنوان ورودی مدل‌های مختلف استفاده نمودند. نتایج آن‌ها نیز نشان داد که استفاده از تبدیل موجک در پیش‌پردازش داده‌های ورودی موجب افزایش دقت برآورد تبخیر-تعرق مرجع گشته است.

### نتیجه‌گیری

پیش‌بینی تبخیر-تعرق مرجع و بالطبع آن نیاز آبی گیاهان مختلف می‌تواند کمک برای مدیریت منابع آب کشور باشد. در تحقیق حاضر عملکرد دو مدل موجک-ANFIS و ANFIS در پیش‌بینی تبخیر-تعرق مرجع هفتگی در چهار ایستگاه همدیدی تبریز، اهواز، بندرعباس و رامسر که دارای اقلیم‌های متفاوت هستند، مورد ارزیابی قرار گرفت. نتایج این تحقیق نشان داد که

### فهرست منابع

۱. آزاد طلا تپه ن. بهمنش ج. و منتصری م. ۱۳۹۱. پیش‌بینی تبخیر-تعرق پتانسیل با استفاده از مدل‌های سری زمانی نشریه آب و خاک (علوم و صنایع کشاورزی). ۲۷(۱): ۲۲۳-۲۱۳
۲. بهمنش ج. آزاد طلا تپه ن. منتصری م. و بشارت س. ۱۳۹۳. ارزیابی مدل‌های سری زمانی خطی و غیر خطی بیلینیر در پیش‌بینی تبخیر-تعرق گیاه مرجع در ایستگاه سینوپتیک ارومیه. نشریه پژوهش آب در کشاورزی. ۲۸(۱): ۸۵-۹۶
۳. حسن‌زاده ی. کردانی ع. و فاخری‌فرد ا. ۱۳۹۱. پیش‌بینی خشکسالی با استفاده از الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی-موجکی. فصلنامه علمی-پژوهشی آب و فاضلاب، ۲۳(۸۳): ۴۸-۵۹.
۴. رجایی ط. و ابراهیمی ه. ۱۳۹۳. مدل‌سازی نوسانات های ماهانه آب زیرزمینی به وسیله تبدیل موجک و شبکه عصبی پویا. مجله مدیریت آب و آبیاری. ۴(۱): ۸۷-۷۳.

۵. شفائی م، فاخری فرد ا. دربندی ص. و قربانی. م.ع. ۱۳۹۲. پیش‌بینی جریان روزانه رودخانه با استفاده از مدل هیبرید موجک و شبکه عصبی، مطالعه موردی ایستگاه هیدرومتری ونیار در حوضه آبریز آجی چای. فصلنامه علمی پژوهشی مهندسی آبیاری و آب. ۴(۱۴): ۱۱۳-۱۲۸
۶. شیروانی ا. و هنر ت. ۱۳۹۰. کاربرد مدل‌های سریهای زمانی برای پیش‌بینی تبخیر-تعرق در ایستگاه باجگاه. مجله پژوهش آب ایران. ۵(۸): ۱۴۲-۱۳۵
۷. طوفانی پ. مساعدی ا. و فاخری فرد ا، ۱۳۹۰. پیش‌بینی بارندگی با استفاده مستقیم از نظریه موجک. نشریه آب و خاک. ۲۵(۵): ۱۲۲۶-۱۲۱۷.
۸. عبداللهی اسدآبادی س. دین پژوه ی. و میرعباسی ر. ۱۳۹۲. پیش‌بینی دبی متوسط روزانه جریان رودخانه بهشت آباد با استفاده از آنالیز موجک. نشریه آب و خاک. ۲۸(۳): ۵۳۴-۵۴۵.
۹. فولادمند ح. ۱۳۸۹. پیش‌بینی ماهانه تبخیر-تعرق پتانسیل گیاه مرجع در استان فارس. مجله دانش آب و خاک. ۲۰(۴): ۱۵۷-۱۶۹.
۱۰. قهرمان ن. و قره خانی ا. ۱۳۹۰. ارزیابی مدل‌های تصادفی سری زمانی در برآورد تبخیر از تشت. مجله پژوهش آب در کشاورزی. ۲۵(۱): ۷۵-۸۱.
۱۱. معروفی ص. امیرمادی ک. و پارسافر ر. ۱۳۹۲. پیش‌بینی جریان روزانه با استفاده از شبکه‌های عصبی مصنوعی و عصبی-موجکی (مطالعه موردی: رودخانه باراندوزچای). نشریه دانش آب و خاک. ۲۳(۳): ۹۳-۱۰۳.
۱۲. مؤمنی ب. عباس پلنگی ج. و اقدسی ب. ۱۳۹۰. تخمین تراز آب زیرزمینی با استفاده از شبکه‌های عصبی مصنوعی. چهارمین کنفرانس مدیریت منابع آب، دانشگاه صنعتی امیرکبیر تهران.
13. Adamowski, J. and Chan, H.F., 2011. A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*, 407(1):28-40.
14. Adamowski, J., & 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*, 390(1-2): 85-91.
15. Araghi, A., Baygi, M. M., Adamowski, J., Malard, J., Nalley, D., and Hasheminia, S. M. 2015. Using wavelet transforms to estimate surface temperature trends and dominant periodicities in Iran based on gridded reanalysis data. *Atmospheric Research*, 155: 52-72.
16. Bachour, R., Maslova, I., Ticlavilca, A., Walker, W., & McKee, M. 2015. Wavelet-multivariate relevance vector machine hybrid model for forecasting daily evapotranspiration. *Stochastic Environmental Research and Risk Assessment*, 29(2):1-15.
17. Chiu, S.L., 1994. Fuzzy model identification based on cluster estimation. *Journal of intelligent and Fuzzy systems*, 2(3):267-278.
18. Jang, J.S.R., 1993. ANFIS: adaptive-network-based fuzzy inference system. *Systems, Man and Cybernetics, IEEE Transactions on*, 23(3):665-685.
19. Karimi, S., Kisi, O., Shiri, J. and Makarynskyy, O. 2015. A Wavelet and Neuro-fuzzy Conjunction Model to Forecast Air Temperature Variations at Coastal Sites. *The International Journal of Ocean and Climate Systems*. 6(4):159-172.
20. Kisi, O. 2010. Wavelet regression model for short-term streamflow forecasting. *Journal of Hydrology*, 389(3-4): 344-353.
21. Kisi, O. 2008. The potential of different ANN techniques in evapotranspiration modelling. *Hydrological Processes*, 22(14): 2449-2460.

22. Kişi, Ö. 2011. Evapotranspiration modeling using a wavelet regression model. *Irrigation science*, 29(3):241-252.
23. Kisi, O. and Shiri, J. 2012. Wavelet and neuro-fuzzy conjunction model for predicting water table depth fluctuations. *Hydrology Research*, 43(3):286-300.
24. Landaras, G., Ortiz-Barredo, A., & López, J. J. 2009. Forecasting weekly evapotranspiration with ARIMA and artificial neural network models. *Journal of Irrigation and Drainage Engineering*, 135(3): 323-334.
25. Luo, Y., Chang, X., Peng, Sh., Khan, Sh., Wang, W., Zheng, Q., Cai, X. 2014. Short-term forecasting of daily reference evapotranspiration using the Hargreaves-Samani model and temperature forecasts. *Agricultural Water Management*. 136: 42-51.
26. Nourani, V., Hosseini Baghanam, A., Adamowski, J., & Kisi, O. 2014. Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review. *Journal of Hydrology*, 514(1): 358-377.
27. Partal, T. and Kişi, Ö. 2007. Wavelet and neuro-fuzzy conjunction model for precipitation forecasting. *Journal of Hydrology*, 342(1):199-212.
28. Partal, T., 2015. Comparison of wavelet based hybrid models for daily evapotranspiration estimation using meteorological data. *KSCE Journal of Civil Engineering*. :1-9.
29. Patil, A.P. and Deka, P.C. 2015. Performance evaluation of hybrid Wavelet-ANN and Wavelet-ANFIS models for estimating evapotranspiration in arid regions of India. *Neural Computing and Applications*. 3(7):1-11.
30. Ramana, R.V., Krishna, B., Kumar, S.R. and Pandey, N.G. 2013. Monthly rainfall prediction using wavelet neural network analysis. *Water resources management*, 27(10):3697-3711.
31. Shoaib, 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*, 527, :326-344.
32. Silva, D., Meza, F., Varas, E., 2010. Estimating reference evapotranspiration (ET<sub>0</sub>) using numerical weather forecast data in central Chile. *J. Hydrol.* 382 (1-4):64-71.
33. Tabari H, Marofi S, Sabziparvar AA .2010. Estimation of daily pan evaporation using artificial neural network and multivariate non-linear regression. *Irrigation Sci* 28(5):399-406
34. Tabari, H., Marofi, S., Amini, A., Talaei, P. H., & Mohammadi, K. 2011. Trend analysis of reference evapotranspiration in the western half of Iran. *Agricultural and Forest Meteorology*, 151(2): 128-136.
35. Tian, D., Martinez, C.G. 2012. Forecasting reference evapotranspiration using retrospective forecast analogs in the South-eastern United States. *J. Hydrometeorol.* 1(3):1874-1892.
36. 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.