

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

### عصبی تطبیقی

مسعود کرباسی<sup>\*</sup><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 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 مورداستفاده نسبت به مدل ANFIS دارای توانایی و دقیق‌تری در پیش‌بینی تبخیر-تعرق هفتگی می‌باشد. همچنین نتایج نشان داد که استفاده از تأخیرهای زمانی سالانه در مدل ANFIS موجب افزایش دقیق‌تری در مدل موجک-ANFIS استفاده از تأخیرهای زمانی سالانه موجب افزایش دقیق‌تری در برخی موارد حتی موجب کاهش دقیق‌تری 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

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 ET<sub>0</sub> در ایستگاه‌های مختلف مناسب برای پیش‌بینی ET<sub>0</sub> در ایستگاه‌های 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 هر ایستگاه مقادیر ماهانه ET<sub>0</sub> 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 متحرك تلفیق شده فصلی را برای ایستگاه با جگاه موردنبرسی قرار دادند. نتایج نشان داد که مدل فوق قادر است مقادیر تبخیر-تعرق را در مقیاس‌های اشاره شده به خوبی پیش‌بینی کند. لاندراس و همکاران (۲۰۰۹) مدل ARIMA را جهت پیش‌بینی مقادیر هفتگی تبخیر-تعرق در شمال اسپانیا مورد ارزیابی قراردادند. نتایج آن‌ها نشان داد که مدل فوق نسبت به مقادیر متوسط بلندمدت دقت بالاتری را دارا هست. آزاد طلاتپه و همکاران (۱۳۹۲) عملکرد مدل‌های سری زمانی را در پیش‌بینی تبخیر-تعرق ماهانه در ایستگاه همدیدی ارومیه مورد ارزیابی قراردادند. نتایج آن‌ها نشان داد که مدل سری زمانی AR(11) دارای خطای کمتری نسبت با سایر مدل‌ها است. بهمنش و همکاران (۱۳۹۳) مدل‌های سری زمانی خطی را به همراه

ایران کشوری با متوسط ریزش‌های جوی ۲۵۰ میلی‌متر است و در زمرة مناطق خشک و نیمه‌خشک جهان طبقه‌بندی می‌گردد. محدودیت منابع آب و نبود آب باکیفیت مناسب از عمدۀ ترین 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 بهشت وابسته به پارامترهای اقلیمی است. در برنامه‌ریزی و مدیریت منابع آب برای آبیاری نیاز به تجزیه تحلیل متغیرهای هیدرولوژیکی نظری برash 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 مبتنى 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 موردنیاز بر اساس پیش‌بینی‌های Barsh و آب موردنیاز محصولات، تصمیم‌گیری‌ها را بر اساس زمان واقعی<sup>۱</sup> اعمال کنند. Barsh معمولاً در پیش‌بینی هوا از طریق پیش‌بینی وضعیت آب و هوا 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<sub>0</sub>) 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<sub>0</sub>) 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

<sup>۱</sup>Real-time

تحقیق خود از دو نوع شبکه عصبی مصنوعی<sup>۳</sup> MLP و RBF با تأخیرهای زمانی ۱، ۲، ۳ و ۴ هفته و ۱، ۲ و ۳ 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 (لاندراس 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 ذکر شده در چهار اقلیم مختلف ایران

## مواد و روش‌ها

### منطقه موردمطالعه

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 ذکر شده در جدول ۱

مدل غیرخطی دوسویه<sup>۱</sup> در پیش‌بینی مقادیر ماهانه تبخیر-تعرق در ایستگاه همدیدی ارومیه مورد مقایسه قراردادند. نتایج آنها نشان داد که مدل غیرخطی دوسویه توائیابی بیشتری در مدل سازی و پیش‌بینی مقادیر ماهانه تبخیر-تعرق مرجع در مقایسه با مدل خطی را دارد.

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 به دست آمده نشان داد که نتایج مدل پیشنهادی با نتایج معادله پنمن-مانیث دارای همبستگی بالایی هستند و مدل فوق قادر است با خطای مطلق یک میلی‌متر در روز تبخیر-تعرق مرجع را پیش‌بینی کند. تیان و همکاران (۲۰۱۰) و سیلو و همکاران (۲۰۱۲) نشان دادند که پیش‌بینی هواشناسی با استفاده از روش‌های عددی می‌تواند به عنوان راه کاری مناسب جهت پیش‌بینی تبخیر-تعرق در آینده مورداستفاده 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. تراکوچ 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 دو ساله استفاده نمودند. نتایج نشان داد که شبکه عصبی نوع RBF قادر است میزان تبخیر-تعرق مرجع ماهیانه را با اطمینان بالایی پیش‌بینی کند. لاندراس و همکاران (۲۰۰۹) با استفاده از شبکه‌های عصبی مصنوعی، تبخیر-تعرق مرجع هفتگی را پیش‌بینی کردند. آنها در

<sup>3</sup>Multi-Layer Perceptron

<sup>1</sup>Bilinear

<sup>2</sup>Radial Basis Function

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

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

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

جدول ۱- مشخصات ایستگاه‌های مورد مطالعه در بازه زمانی ۱۹۸۵-۲۰۱۰

ایستگاه	درجه	دقیقه درجه	دقیقه درجه	طول جغرافیایی	ارتفاع از سطح دریا (m)	متوسط دما (C)	متوسط بارش (mm)	اقلیم (آمیزه)
بندرعباس	۲۷	۱۳	۵۶	۲۲	۹/۸	۲۷	۱۷۶/۱	بیابانی گرم شدید
رامسر	۳۶	۵۴	۵۰	۴۰	-۲۰	۱۶/۱	۱۲۰/۶/۲	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

است) می‌باشدند. در رابطه (۱)،  $G$  شار گرمای خاک می‌باشد که مقدار آن برای دوره‌های روزانه و ده روز به طور نسبی پایین می‌باشد. بنابراین می‌توان از آن صرف نظر کرد (آلن و همکاران، ۱۹۹۸). در معادله ۱ فرض بر اینست که ارتفاع گیاه چمن مرجع  $12^{\circ}\text{C}$  متر و مقاومت سطحی آن  $70$  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.

## تبديل 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 یکتابع رفتار کند، بنابراین با توجه به رفتارهای موجی پدیده‌های هیدرولوژیک، قابلیت مدل‌سازی این پدیده‌ها توسعه 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

معادله پنمن-مانیتیث

به منظور برآورد مقدار  $ET_0$  روزانه (میلی‌متر بر روز) از روش پنمن-مانیتیث 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 متري 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  $e_a$  (فارشار بخار واقعی) از دمای نقطه شبنم و برای تعیین  $e_s$  (فارشار بخار اشباع) از حداقل 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 آبدو برای پوشش

گیاهی که برای گیاه چمن مرجع  $23^{\circ}\text{C}$  فرض می‌شود،  $\sigma$ : ثابت قانون استفان-بولتزمن،  $Z$ : ارتفاع از سطح دریا و  $R_a$ : تابش فرازمنی (که تابع زمان و موقعیت جغرافیایی

انتقال زمان بوده و وابسته به  $s_0$  می‌باشد.

### 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 آموزش پذیری 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 به عنوان ابزاری قدرتمند که قابلیت پیش‌بینی تتابع 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 به منظور 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  $A_1$  و  $B_1$  برچسب‌های زبانی هستند که به ترتیب با تابع 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 به کاررفته 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 اصلاح شده تبدیل می‌کند که این تبدیل موجک‌های اصلاح شده همان تبدیل موجک دختر می‌باشد. (معروفی و همکاران، ۱۳۹۲) تبدیلات موجک به دو نوع پیوسته و گسته تقسیم می‌شوند. تبدیل موجک پیوسته یک سیگنال  $x(t)$  به صورت 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،  $(s)$ : پارامتر مقیاس یا اتساع،  $\tau$ : پارامتر انتقال زمان،  $t$ : زمان و  $CWT$  علامت \* نشان‌دهنده مزدوج مختلط است. روش  $CWT$  سیگنال را به وسیله تعداد بیشمار و نامحدودی از پارامترهای مقیاس و انتقال تجزیه می‌کند. در این روش پارامترهای مقیاس و انتقال به صورت پیوسته تغییر می‌کنند. از این‌رو 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 گسته موجک (DWT) گردیده است (عبدالهی اسدآبادی و همکاران، ۱۳۹۳). شکل گسته تابع موجک به صورت 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،  $s_0$  ثابت گام اتساع،  $\tau_0$  ثابت

خوشبندی جایگزین می‌تواند مرکز خوشبندی را در مجموعه داده‌ها با سرعت بالایی پیدا کند. خوشبندی جایگزین برای اولین بار توسط چیو (۱۹۹۴) پیشنهاد گردید. در این روش تمامی نقاط داده به عنوان کاندیدای مرکز خوشبندی 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 آورده. اگر تعداد زیادی نقاط در همسایگی مرکز خوشبندی باشند، نقطه فوق (مرکز خوشبندی) دارای چگالی بیشتری خواهد بود. بعد از خوشبندی، مقدار چگالی برای تمامی نقاط محاسبه می‌شود و نقطه‌ای که دارای بیشترین مقدار چگالی است ( $D_{c1}$ ) به عنوان مرکز خوشبندی اول ( $x_{c1}$ ) انتخاب می‌شود. بنابراین مقدار چگالی در بقیه نقاط  $x_i$  برابر خواهد بود با:

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

که در اینجا  $r_b$  یک عدد مثبت است که مقدار آن ۱.۵ $r_a$  است. در نقاط داده در نزدیکی مرکز خوشبندی اول، مقدار چگالی نقاط داده‌ها به میزان قابل توجهی دارای کاهش خواهد بود. بنابراین مرکز خوشبندی بعدی که به عنوان نقطه با بیشترین چگالی خواهد بود از مرکز خوشبندی اول دارای فاصله خواهد بود. این فرایند تا زمانی پیدا می‌کند تا تعداد کافی مرکز خوشبندی به دست آید (چیو، 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 خوشبندی جایگزین جهت ایجاد سیستم فازی مورداستفاده 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

$\mu_{A_i}$  و  $\mu_{B_i}$  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 ۱ 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 ۱ در این لایه مشارکت قانون ۱ 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 مدلکه 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- خوشبندی جایگزین<sup>۲</sup> و ۳- خوشبندی 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، خوشبندی داده‌های ورودی و خروجی است. خوشبندی داده‌ها را از یک مجموعه بزرگ به چندین گروه که دارای بیشترین تشابه هستند تقسیم می‌کند.

### خوشبندی جایگزین

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

<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 پمنمانیت 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 پمنمانیت و پیش‌بینی می‌باشد.

## نتایج و بحث

### داده‌های ورودی به مدل‌ها

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

### نتایج مدل ANFIS

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

استفاده از زیرسی‌های به دست آمده از تبدیل موجک گسته است. بدین منظور، ابتدا سری زمانی اصلی با استفاده از تبدیل موجک گسته به زیرسی‌های 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 زیرسی‌های تقریب A<sub>1</sub>, A<sub>2</sub>, D<sub>1</sub>...D<sub>n</sub> که n سطح تجزیه می‌باشد، به عنوان 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 گسته 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 Int تابع جز صحیح می‌باشد.

معیارهای آماری برای مقایسه مدل‌ها به منظور 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>1</sup>Approximation  
<sup>2</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 پراکندگی مقادیر به دست آمده از معادله پسمن مانیث و پیش‌بینی شده حاصل از بهترین مجموعه ورودی را برای ایستگاه‌های موردن بررسی نشان می‌دهد. لاندراس و همکاران (۲۰۰۹) مقدار خطای مطلق به دست آمده از مدل‌های ARIMA و شبکه عصبی مصنوعی را در پیش‌بینی هفتگی تبخیر-تعرق مرجع بین ۱۲ الی ۱۳ درصد گزارش نمودند که به جز ایستگاه بندرعباس که خطای مطلق ۹/۱۱ درصد بوده است در بقیه ایستگاه‌ها مدل ANFIS نتایج ضعیف‌تری را ارائه نموده است.

۴/۰۶ RMSE 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 ۵/۶۴ RMSE میلی‌متر در هفته و  $R^2 = ۰/۹۲۶$  دارای عملکردی بهتری نسبت به سایر مجموعه ورودی‌ها است. در ایستگاه بندرعباس مجموعه ورودی شش با ۳/۹۵ RMSE میلی‌متر در هفته و  $R^2 = ۰/۸۳۶$  دارای عملکردی بهتری است. در ایستگاه رامسر مجموعه ورودی نه با ۳/۹۶ RMSE میلی‌متر در هفته و  $R^2 = ۰/۷۴۹$  دارای عملکردی بهتری نسبت به سایر مجموعه ورودی‌ها است. یافته فوق با نتایج لاندراس 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

متغیرهای ورودی	متغیرهای خروجی
۱ ET <sub>t-1</sub>	ET <sub>t</sub>
۲ ET <sub>t-1,ET<sub>t-2</sub></sub>	ET <sub>t</sub>
۳ ET <sub>t-1,ET<sub>t-2,ET<sub>t-3</sub></sub></sub>	ET <sub>t</sub>
۴ ET <sub>t-1,ET<sub>t-2,ET<sub>t-3,ET<sub>t-4</sub></sub></sub></sub>	ET <sub>t</sub>
۵ ET <sub>t-1,ET<sub>t-2,ET<sub>t-52</sub></sub></sub>	ET <sub>t</sub>
۶ ET <sub>t-1,ET<sub>t-2,ET<sub>t-52,ET<sub>t-104</sub></sub></sub></sub>	ET <sub>t</sub>
۷ ET <sub>t-1,ET<sub>t-2,ET<sub>t-3,ET<sub>t-52</sub></sub></sub></sub>	ET <sub>t</sub>
۸ ET <sub>t-1,ET<sub>t-2,ET<sub>t-3,ET<sub>t-4,ET<sub>t-52</sub></sub></sub></sub></sub>	ET <sub>t</sub>
۹ ET <sub>t-1,ET<sub>t-2,ET<sub>t-3,ET<sub>t-4,ET<sub>t-52,ET<sub>t-104</sub></sub></sub></sub></sub></sub>	ET <sub>t</sub>

نتایج مدل هیبریدی موجک-ANFIS در sym10، sym6 و sym2 (dmey<sup>۵</sup>) مورد بررسی و ارزیابی قرار گرفت. مؤلفه‌های تجزیه شده 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

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

<sup>۵</sup> Meyer

<sup>۱</sup> Haar

<sup>۲</sup> Daubechies

<sup>۳</sup> Coiflet

<sup>۴</sup> Symlet

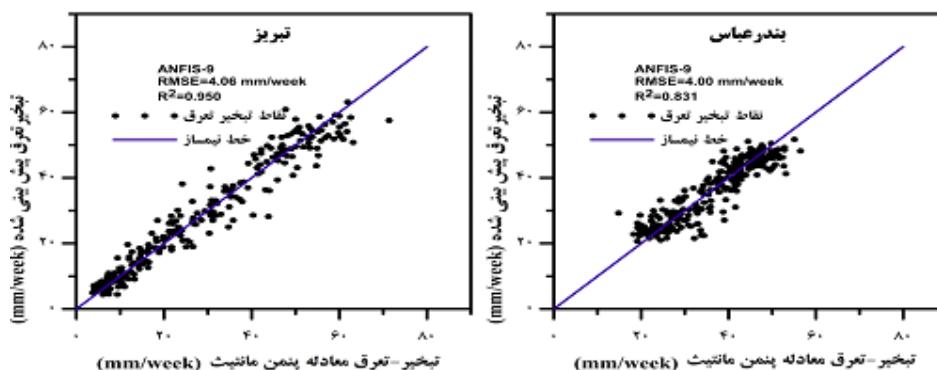
هیدرولوژیکی از موجک‌های مادر خانواده دابچیز (db1-) و db10 استفاده شده است (عراقی و همکاران، ۲۰۱۵) و نورانی و همکاران، ۲۰۱۴). دلیل افزایش دقت در موجک میر را می‌توان به دلیل پیچیدگی بالا و شباهت به سیگنال تبخیر-تعرق مرجع هفتگی، مرتبط دانست. در تحقیق حاضر نیز با توجه به اینکه این موجک در تمامی ایستگاه‌ها بهترین عملکرد را دارا می‌باشد، بنابراین در بقیه مجموعه‌های ورودی موجک میر مورد استفاده قرار گرفت.

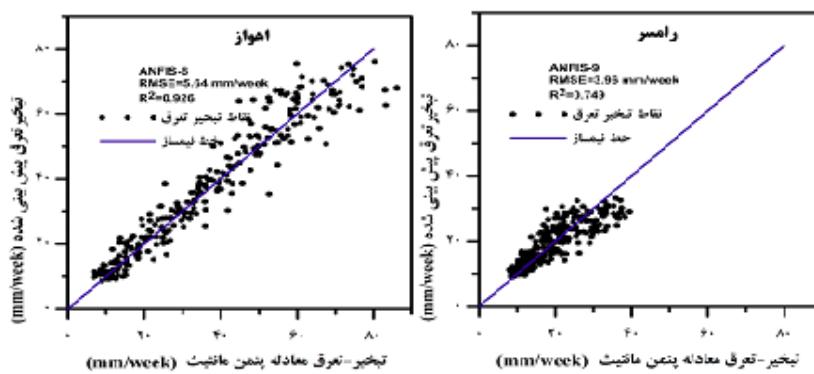
مورد ارزیابی قرار گرفت. شکل ۲ تأثیر نوع موجک مادر را بر عملکرد مدل موجک- فازی عصی نشان می‌دهد. با توجه به شکل ۲ موجک میر (dmey) در مقایسه با سایر موجک‌ها دارای عملکرد بهتری می‌باشد. طوفانی و همکاران (۱۳۹۰) در پیش‌بینی بارندگی، رجایی و ابراهیمی (۱۳۹۳) در پیش‌بینی نوسانات سطح آب زیرزمینی و شعیب و همکاران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

جدول ۳- نتایج پیش‌بینی تبخیر-تعرق مرجع هفتگی با مدل ANFIS برای داده‌های صحبت سنگی

مجموعه ورودی										معیارهای آماری	ایستگاه
۹	۸	۷	۶	۵	۴	۳	۲	۱			
۴/۰۶	۴/۲۲	۴/۳۳	۴/۱۶	۴/۳۸	۴/۰۳	۴/۷۲	۴/۷۴	۴/۶۴	RMSE	تبریز	
۰/۹۵۰	۰/۹۴۶	۰/۹۴۳	۰/۹۴۸	۰/۹۴۲	۰/۹۳۸	۰/۹۳۳	۰/۹۳۳	۰/۹۳۴	$R^2$		
۱۴/۰۵	۱۴/۹۴	۱۵/۰۹	۱۴/۴۵	۱۵/۳۹	۱۶/۰۳	۱۶/۳۵	۱۶/۴۵	۱۶/۱۶	MAPE(%)		
۰/۰۳	۰/۰۳	۰/۰۱	.	.	۰/۱۷	۰/۱۵	۰/۱۵	۰/۱۹	MBE		
۵/۶۶	۵/۸۶	۵/۸۸	۵/۶۴	۵/۸۴	۶/۴۹	۶/۵۳	۶/۵۰	۶/۵۸	RMSE	اهواز	
۰/۹۲۶	۰/۹۲۰	۰/۹۱۹	۰/۹۲۶	۰/۹۲۱	۰/۹۰۲	۰/۹۰۱	۰/۹۰۲	۰/۸۹۹	$R^2$		
۱۳/۴۳	۱۳/۸۷	۱۳/۹۴	۱۳/۷۶	۱۴/۰۶	۱۶/۰۱	۱۶/۰۵	۱۶/۴۵	۱۶/۴۱	MAPE(%)		
-۰/۴۵	-۰/۳۳	-۰/۳۳	-۰/۴۵	-۰/۳۳	-۰/۱۶	-۰/۱۶	-۰/۱۴	-۰/۱۵	MBE		
۴/۰۰	۴/۱۴	۴/۱۰	۳/۹۵	۴/۰۹	۴/۲۷	۴/۲۵	۴/۲۴	۴/۳۹	RMSE	بندرعباس	
۰/۸۳۱	۰/۸۱۹	۰/۸۲۲	۰/۸۲۶	۰/۸۲۳	۰/۸۰۹	۰/۸۱۱	۰/۸۱۱	۰/۷۹۸	$R^2$		
۹/۲۲	۹/۷۲	۹/۶۴	۹/۱۱	۹/۵۹	۹/۷۸	۹/۷۶	۹/۷۶	۱۰/۱۹	MAPE(%)		
۰/۳۶	۰/۳۷	۰/۳۹	۰/۱۹	۰/۲۲	۰/۲۵	۰/۱۸	۰/۲۵	۰/۴۵	MBE		
۳/۹۶	۴/۰۴	۴/۰۱	۳/۹۹	۴/۰۷	۴/۱۸	۴/۱۵	۴/۲۱	۴/۴۶	RMSE	رامسر	
۰/۷۴۹	۰/۷۴۱	۰/۷۴۴	۰/۷۴۶	۰/۷۳۷	۰/۷۲۳	۰/۷۲۶	۰/۷۱۹	۰/۶۸۴	$R^2$		
۱۵/۲۸	۱۵/۷۷	۱۵/۷۷	۱۵/۲۸	۱۵/۸۹	۱۶/۴۹	۱۶/۵۲	۱۶/۶۶	۱۷/۸۸	MAPE(%)		
۰/۱۵	۰/۱۷	۰/۱۷	۰/۲۳	۰/۲۳	۰/۲۶	۰/۲۴	۰/۳۱	۰/۳۳	MBE		

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

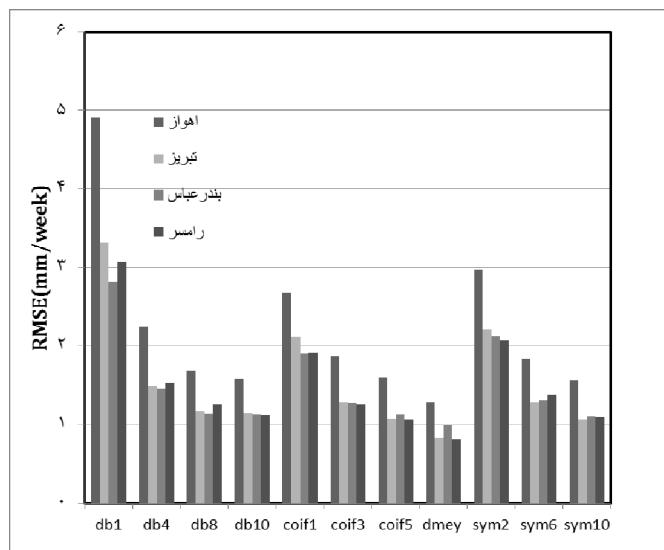




شکل ۱- پراکندگی به دست آمده از معادله پنمن مانیث در مقابل مقادیر پیش‌بینی شده در داده‌های صحت سنجی در مدل فازی-عصبی برای بهترین مجموعه ورودی

قرار می‌گیرند. در ایستگاه رامسر مجموعه ورودی‌های ۴، ۸ و ۹ با  $0.81$  میلی‌متر در هفته و ضریب  $R^2 = 0.989$  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  $2/16$  درصد برای داده‌های صحت سنجی بهترین عملکرد را در بین ایستگاه‌های موردمطالعه داشته است. مقدار خطای مطلق در ایستگاه‌های اهواز، رامسر و تبریز به ترتیب  $3/18$  و  $3/19$  و  $3/26$  می‌باشد. شکل ۳ نیز نمودار پراکندگی به دست آمده از معادله پنمن مانیث و پیش‌بینی شده 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 صحت سنجی در چهار ایستگاه همدیدی موردمطالعه نشان می‌دهد. در ایستگاه تبریز مجموعه ورودی ۴ بهترین نتیجه را با  $0.82$  میلی‌متر در هفته و ضریب  $R^2 = 0.998$  بهترین نتیجه را ارائه کرده است. مجموعه ورودی‌های ۸ و ۹ در رتبه‌های بعدی قرار می‌گیرند. در ایستگاه اهواز مجموعه ورودی ۸ با  $1/28$  RMSE میلی‌متر در هفته و ضریب  $R^2 = 0.996$  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  $0.99$  RMSE میلی‌متر در هفته و ضریب  $R^2 = 0.989$  بهترین عملکرد را در پیش‌بینی تبخیر-تعرق مرجع هفتگی داشته‌اند. مجموعه ورودی‌های ۹ و ۳ در رتبه‌های بعدی

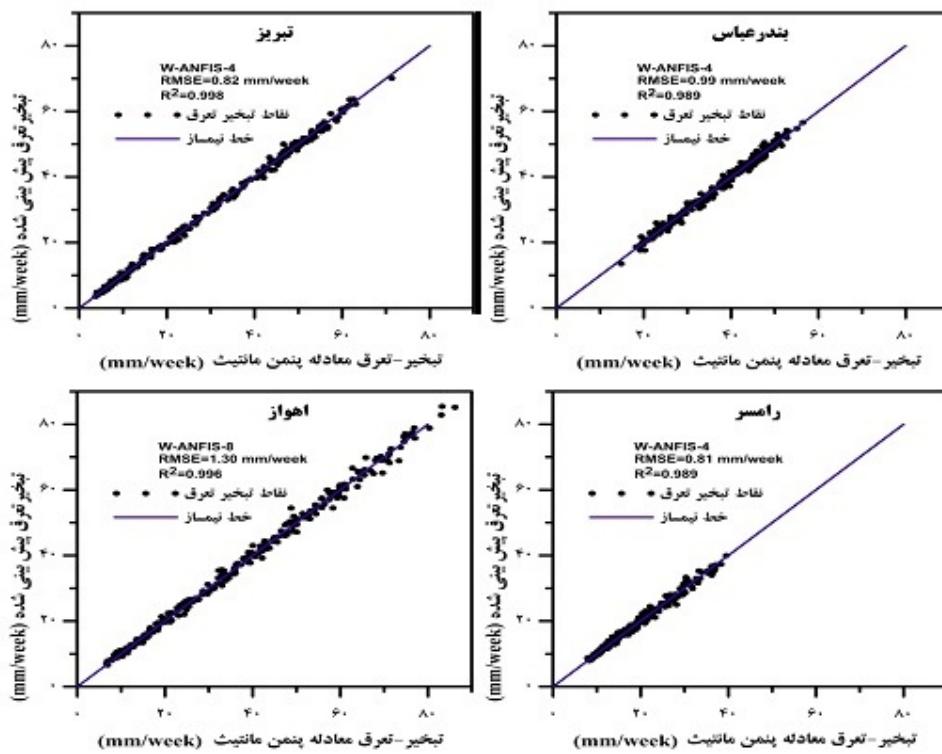


شکل ۲ - بررسی تأثیر نوع موجک بر عملکرد مدل موجک-فازی عصبی در ایستگاه‌های مورد مطالعه

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

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

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



شکل ۳- پراکندگی به دست آمده از معادله پنمن ماتنیت در مقابل مقادیر پیش‌بینی شده 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 MRVM<sup>1</sup> 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 تبدیل موجک به عنوان یک روش پیش‌پردازش می‌تواند موجک 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 به دست آمده 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 به کاربرده 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 کرداند، گزارش شده است (آداموفسکی و چان، ۲۰۱۱، راما 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 گستته 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 بالای تبخیر-تعرق هفتگی را پیش‌بینی کنند. هرچند مدل ANFIS توانایی مدل‌سازی رفتارهای غیرخطی را دارد، ولی با توجه به ویژگی‌های نایستایی 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 مورداستفاده 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 هواسناسی کشور به دلیل در اختیار قرار دادن داده‌های هواسناسی 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 گستته 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 گستته پارامترهای مرتبط با تبخیر-تعرق مرجع را تجزیه نموده و از آن‌ها به عنوان ورودی مدل‌های مختلف استفاده نمودند. نتایج آن‌ها نیز نشان داد که استفاده از تبدیل موجک در پیش‌پردازش داده‌های ورودی موجک افزایش دقت برآورده تبخیر-تعرق مرجع گشته است.

### نتیجه‌گیری

پیش‌بینی تبخیر-تعرق مرجع و بالطبع آن نیاز آب 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

- آزاد طلاتپه ن. بهمنش ج. و منتظری م. ۱۳۹۱. پیش‌بینی تبخیر-تعرق پتانسیل با استفاده از مدل‌های سری زمانی نشریه آب و خاک (علوم و صنایع کشاورزی). ۲۷(۱): ۲۲۳-۲۱۳.
- بهمنش ج. آزاد طلاتپه ن. منتظری 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.
- حسن‌زاده‌ی. 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.
- رجایی ط. و ابراهیمی ه. ۱۳۹۳. مدل‌سازی نوسانات های ماهانه آب زیرزمینی به وسیله تبدیل موجک و شبکه عصبی پولیا. 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 موردنی ایستگاه هیدرومتری ونیار در حوضه آبریز آجی چای. فصلنامه علمی پژوهشی مهندسی آبیاری و آب. ۱۴(۱): ۱۱۳-۱۲۸.
۶. شیروانی ا. و هنر ت. ۱۳۹۰. کاربرد مدل‌های سریهای زمانی برای پیش‌بینی تبخیر-تعرق در ایستگاه باجگاه. مجله پژوهش آب ایران. ۱۴(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 پژوهی. 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. امیرمرادی ک. و پارسافر ر. ۱۳۹۲. پیش‌بینی جریان روزانه با استفاده از شبکه‌های عصبی مصنوعی و عصبی-موجکی (مطالعه موردنی: 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. Landeras, 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., Aeini, 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.
35. Tian, D., Martinez, C.G. 2012. Forecasting reference evapotranspiration using retro-spective 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.