

مقاله علمی-پژوهشی

## بررسی تأثیر تجزیه سری زمانی در شبیه‌سازی تبخیر روزانه مبتنی بر جنگل تصادفی

وحید پور قاسم<sup>۱</sup>، کیوان خلیلی<sup>۲\*</sup>، حسین رضایی<sup>۳</sup>، محمد ناظری تهرودی<sup>۴</sup>

تاریخ دریافت: ۱۴۰۴/۰۶/۲۰ تاریخ پذیرش: ۱۴۰۴/۰۷/۲۲

### چکیده

با توجه به اهمیت تبخیر از تشت در کشاورزی و منابع آب در اقلیم‌های مختلف و با توجه به تغییرات اقلیمی در سال‌های اخیر، در این مطالعه به بررسی تغییرات تبخیر از تشت و شبیه‌سازی آن با استفاده از تجزیه فرکانس در ایستگاه‌های تبخیرسنجی واقع در استان لرستان، غرب ایران پرداخته شده است. نتایج بررسی تغییرات مقادیر تبخیر از تشت در منطقه مورد مطالعه نشان داد که در ماه‌های سرد سال (اکتبر تا فوریه)، بیشتر ایستگاه‌ها روند کاهشی معناداری در تبخیر از تشت تجربه کرده‌اند، در حالی که در ماه‌های گرم‌تر مانند مارس و آوریل، روند افزایشی غالب بوده است. جهت شبیه‌سازی مقادیر تبخیر از تشت از مدل ترکیبی موجک-جنگل تصادفی استفاده شد. نتایج ارزیابی مدل یاد شده با معیارهای RMSE، NSE، WI و ضریب همبستگی نشان داد که این روش از دقت بالایی در فازهای آموزش و آزمایش برخوردار است. به‌ویژه، مدل توانست تغییرات فصلی و ناگهانی تبخیر را به خوبی شناسایی کند. اگرچه در برخی ایستگاه‌ها مانند پلدختر خطای نسبی بالاتری نسبت به سایر ایستگاه‌ها مشاهده شد، اما به طور متوسط (متوسط ۸ ایستگاه مورد مطالعه) میزان خطای ۲/۲۳ mm/day و ضریب نش-ساتکلیف بیش از ۰/۸ و شاخص ویلموت بیش از ۹۴ درصد در این مطالعه حاصل شد که با توجه به حدود اطمینان ۹۵ درصد شبیه‌سازی و همچنین واپولین پلات ارائه شده، عملکرد مدل تلفیقی قابل قبول ارزیابی شد. نتایج کلی حاکی از آن است که ترکیب تبدیل موجک و مدل جنگل تصادفی می‌تواند به‌عنوان یک ابزار کارآمد در پیش‌بینی تبخیر از تشت مورد استفاده قرار گیرد.

واژه‌های کلیدی: تبخیر از تشت، تجزیه مؤلفه‌ها، دابجیز، لرستان، موجک

### مقدمه

و حداکثر را به خوبی شبیه‌سازی کنند. در بین پارامترهای هواشناسی، تبخیر از تشت (PET) و پیش‌بینی آن به دلایل علمی و کاربردی متعددی در علوم آب و هواشناسی، کشاورزی، مدیریت منابع آب و مهندسی محیط‌زیست اهمیت دارد. تبخیر یکی از مؤلفه‌های اصلی چرخه آب است و برآورد دقیق آن برای مدیریت منابع آب، برنامه‌ریزی آبیاری و تعادل آب در حوضه‌های آبریز ضروری است (Dingman, 2015). پیش‌بینی تبخیر از تشت به‌عنوان یک شاخص ساده و قابل اندازه‌گیری، به مدل‌سازی تبخیر و تعرق واقعی (ET) در مقیاس‌های بزرگ کمک می‌کند. تبخیر از تشت یک جزء حیاتی در هیدرولوژی و اقلیم‌شناسی است، زیرا مستقیماً بر مدیریت منابع آب، شیوه‌های کشاورزی و پایداری اکولوژیکی تأثیر می‌گذارد. شبیه‌سازی و پیش‌بینی نرخ تبخیر از تشت برای درک و مدیریت چرخه‌های آب، به‌ویژه با توجه به تغییرات اقلیمی و افزایش کمبود آب، ضروری است. تبخیر از تشت معمولاً برای تخمین تبخیر و تعرق گیاهان مرجع (ET<sub>o</sub>) با استفاده از ضرایب تجربی (مانند ضریب تشت) به کار می‌رود. این داده‌ها برای برنامه‌ریزی آبیاری و بهینه‌سازی مصرف آب در کشاورزی حیاتی هستند (Allen et al., 1998). با توجه به تأثیرپذیری تبخیر از پارامترهای اقلیمی مانند دما، رطوبت، سرعت باد

برنامه‌ریزی دقیق و مدیریت قابل اعتماد منابع آب بدون پیش‌بینی دقیق پارامترهای هواشناسی و هیدرولوژیک امکان‌پذیر نیست. با وجود ماهیت تصادفی فرایندهای هواشناسی و هیدرولوژیک، توسعه مدل‌های قادر به توصیف چنین پدیده‌های پیچیده‌ای روزبه‌روز در حال پیشرفت است. از سوی دیگر، در سال‌های اخیر به دلیل تغییر الگوی بارش و تغییرات آب‌وهوایی، مقادیر حدی رویدادهای هواشناسی نیز افزایش یافته است (Zamani et al., 2018; Tahroudi et al., 2019; Ramezani et al., 2019; Ahmadi et al., 2022) که این امر نیاز به مدل‌هایی دارد که بتوانند مقادیر حداقل

۱ - دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران

۲- دانشیار، دانشگاه ارومیه، پژوهشکده مطالعات دریاچه ارومیه، ایران

۳- استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران

۴- استادیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه لرستان، خرم‌آباد، ایران

(\* نویسنده مسئول: Email: [k.khalili@urmia.ac.ir](mailto:k.khalili@urmia.ac.ir))

DOI: [10.22034/ijid.2025.546374.2627](https://doi.org/10.22034/ijid.2025.546374.2627)

تبخیر نشان داد (Sevgen et al., 2019). با تجزیه داده‌های اقلیمی به اجزای فرکانسی مختلف، موجک‌ها به مدل‌ها اجازه می‌دهند الگوهای گذرا و فصلی را که اغلب در رویکردهای مدل‌سازی سنتی نادیده گرفته می‌شوند، ثبت کنند. مطالعات مقایسه‌ای انجام شده بینش‌های مهمی در مورد عملکرد ANN، RF و سایر الگوریتم‌های یادگیری ماشین ارائه می‌دهند (Mohanty et al., 2010; Goyal et al., 2014). هر دو مطالعه از شاخص‌های آماری مانند خطای جذر میانگین مربعات (RMSE)، میانگین خطای مطلق (MAE) و ضرایب همبستگی برای ارزیابی دقت مدل استفاده کردند. نتایج به طور مداوم نشان داد که RF و ANN، به‌ویژه هنگامی که با تبدیل موجک ادغام می‌شوند، عملکرد بهتری در پیش‌بینی تبخیر از تشت در مقایسه با روش‌های سنتی دارند.

پاتیل و دکا توانایی تبدیل موجک را در بهبود دقت مدل‌های شبکه عصبی مصنوعی (ANN) و سیستم‌های رابط عصبی-فازی تطبیقی (ANFIS) جهت شبیه‌سازی تبخیر روزانه در مناطق مختلف هند ارزیابی کردند (Patil and Deka, 2017). عملکرد مدل‌های ترکیبی پیشنهادی با ANN، ANFIS و معادله هارگریوز که به طور مرسوم استفاده می‌شود، مقایسه شد. نتایج نشان داد که استفاده از تبدیل موجک به‌عنوان تکنیک پیش‌پردازش داده‌ها، کارایی مدل‌های ANN و ANFIS افزایش می‌یابد. مدل موجک-شبکه عصبی با  $RMSE = 0.632$  میلی‌متر در روز و  $R = 0.96$  به‌عنوان بهترین مدل برای تخمین تبخیر و تفرق روزانه در مناطق خشک شناخته شد. مطالعه مدل‌سازی پدیده‌های پیچیده از طریق بررسی کامل ادبیات و گسترش افق‌های تحقیقاتی می‌تواند پتانسیل مدل‌های دقیق و مناسب را افزایش دهد. در چند دهه گذشته، پیشرفت‌های قابل توجهی در توسعه مدل‌های هواشناسی و هیدرولوژیک با کارایی بالا در پیش‌بینی مشاهده شده است. در میان مدل‌های مختلف مفهومی و جعبه سیاه، مدل‌های مبتنی بر ترکیب موجک و هوش مصنوعی، مهم‌ترین مدل‌ها در شبیه‌سازی فرایندهای هیدرولوژیکی بوده‌اند (Nourani et al., 2014). مدل‌های مبتنی بر نظریه موجک می‌توانند با ادغام با مدل‌های مختلف مانند مدل‌های هوش مصنوعی، دقت شبیه‌سازی را افزایش دهند. رویکرد مدل‌سازی مبتنی بر شبکه عصبی مصنوعی در دو دهه گذشته توجه قابل توجهی را به خود جلب کرده است (Wu et al., 2009) و با موفقیت در زمینه‌های مختلف، مورد استفاده قرار گرفته است (Jain et al., 1999; Salas et al., 2000; Sivakumar et al., 2002; Nilson et al., 2006; Kisi and Cigizoglu, 2007; Darbandi and Pourhosseini, 2018; Meresa., 2019; Seifi and Riahi-Madvar, 2019; Noori et al., 2020; Hassanjabbar et al., 2022; Kalhori et al., 2022; Mirzaee and Sarraf, 2022).

زاخروف و همکاران یک مدل ترکیبی از تبدیل موجک را بر اساس مدل‌های داده‌محور و الگوریتم ژنتیک (GA) برای پیش‌بینی

و تابش خورشید، تغییرات در نرخ تبخیر می‌تواند نشان‌دهنده تغییرات آب‌وهوایی باشد (IPCC, 2021; Nazeri Tahroudi, 2025). بنابراین، پایش بلندمدت تبخیر از تشت به‌عنوان یک شاخص اقلیمی مورد استفاده قرار می‌گیرد. همچنین در مدل‌های هیدرولوژیک، تبخیر از تشت به‌عنوان داده ورودی برای شبیه‌سازی فرایندهای تبخیر از سطوح آب آزاد و خاک استفاده می‌شود (Singh et al., 2024). این مدل‌ها برای پیش‌بینی جریان رودخانه‌ها، خشکسالی و سیلاب ضروری هستند. از آنجا که اندازه‌گیری مستقیم تبخیر از دریاچه‌ها یا مخازن دشوار است، داده‌های تشت تبخیر برای کالیبراسیون مدل‌های تجربی و سنجش از دور (مانند الگوریتم‌های مبتنی بر ماهواره) استفاده می‌شوند (McMahon et al., 2013).

پیشرفت‌های اخیر در تکنیک‌های یادگیری ماشین، مانند جنگل تصادفی (RF)، شبکه‌های عصبی مصنوعی (ANN) و تبدیل موجک، راه‌های امیدوارکننده‌ای را برای افزایش دقت پیش‌بینی‌های تبخیر از تشت ارائه می‌دهند. جنگل تصادفی یک روش یادگیری گروهی قوی است که به دلیل دقت بالا و توانایی آن در مدیریت مجموعه داده‌های بزرگ با ویژگی‌های متعدد، محبوبیت زیادی کسب کرده است. گوپال و همکاران یک مطالعه مقایسه‌ای با استفاده از RF در کنار ANN، رگرسیون بردار پشتیبان حداقل مربعات (LS-SVR) و منطق فازی برای مدل‌سازی تبخیر روزانه تشت در آب و هوای نیمه‌گرمسیری انجام دادند. این مطالعه توانایی RF را در مدیریت مؤثر تعاملات پیچیده بین متغیرهای هواشناسی برجسته کرد و پتانسیل آن را به‌عنوان یک مدل قابل اعتماد برای شبیه‌سازی تبخیر تشت نشان داد (Goyal et al., 2014). موهانتی و همکاران با تأکید بیشتر بر کاربرد RF، روش‌های مختلف یادگیری ماشین را برای تخمین تبخیر تشت بررسی کردند و اثربخشی RF را در کنار K-نزدیک‌ترین همسایه‌ها و رگرسیون بردار پشتیبان تأیید کردند (Mohanty et al., 2010). نویسنندگان گزارش دادند که RF از مدل‌های خطی سنتی، به‌ویژه در مجموعه داده‌هایی با روابط غیرخطی قابل توجه، عملکرد بهتری داشته است که نشان‌دهنده مناسب بودن آن برای کاربردهای هیدرولوژیکی است.

در زمینه تبخیر تشت، تحقیقات یو و همکاران بر اثربخشی ANN، به‌ویژه هنگامی که با تکنیک‌های پیش‌پردازش داده مانند تبدیل موجک ترکیب می‌شود، تأکید کرد. این ادغام امکان تجزیه داده‌های سری زمانی را فراهم می‌کند و ANN را قادر می‌سازد تا تغییرات کوتاه‌مدت و بلندمدت در میزان تبخیر را به طور مؤثرتری ثبت کند (Yu et al., 2016).

تکنیک‌های تبدیل موجک به‌عنوان ابزارهای ارزشمندی برای افزایش عملکرد مدل‌های یادگیری ماشین ظهور کرده‌اند. مطالعه سوچین و همکاران سودمندی ترکیب تبدیل موجک با ANN و سایر روش‌های یادگیری ماشین را برای بهبود دقت پیش‌بینی در نرخ

داد که از بین تمام مدل‌هایی که آزمایش شدند، ترکیب MODWT-SVM بهترین عملکرد را داشت که این نشان دهنده انتقال عمده عملکرد بهبود یافته نسبت به روش‌های سنتی است.

طبق مرور منابع، نتایج نشان داد که مدل موجک اغلب با مدل‌های شبکه عصبی مصنوعی ترکیب می‌شود و نتایج، برتری مدل ترکیبی موجک را در پیش‌بینی سری‌های زمانی هیدرولوژیک و هواشناسی نشان می‌دهد. در این مطالعه، سعی شد تأثیر تجزیه فرکانس ناشی از نظریه موجک بر نتایج شبیه‌سازی مدل جنگل تصادفی در مقیاس روزانه بررسی شود. بر این اساس، این مطالعه به دنبال توسعه مدل ترکیبی مبتنی بر نظریه موجک برای شبیه‌سازی تبخیر از تشت و شناسایی تناوب‌های موجود در داده‌ها در استان لرستان، غرب ایران با اقلیم‌های متفاوت است.

## مواد و روش‌ها

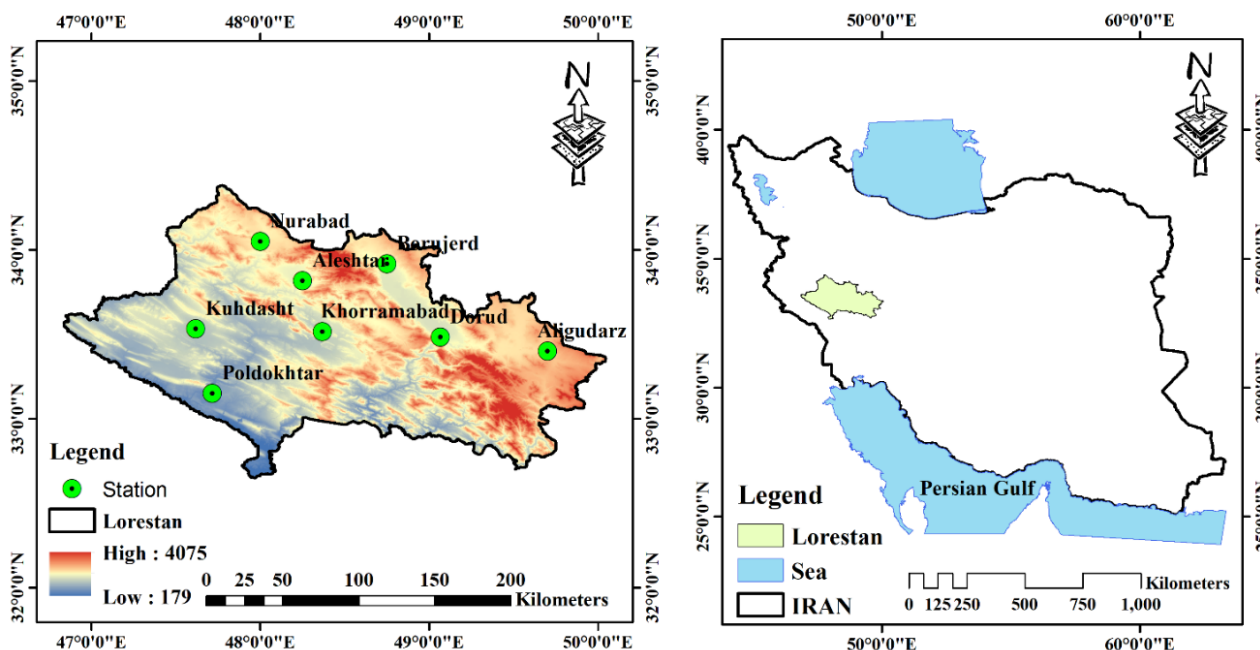
### منطقه مورد مطالعه

منطقه مورد مطالعه، ایستگاه‌های تبخیرسنجی در استان لرستان در غرب ایران می‌باشد. در این مطالعه از مقادیر تبخیر از تشت ایستگاه‌های موجود در استان لرستان (مجموع ۸ ایستگاه با پراکندگی مناسب) در مقیاس روزانه استفاده شده است. موقعیت جغرافیایی ایستگاه‌های مورد مطالعه به صورت شکل ۱ و مشخصات آماری داده‌های مورد مطالعه به صورت جدول ۱ ارائه شده است.

جریان روزانه یک رودخانه در شمال الجزایر توسعه دادند ( Zakhrouf et al., 2018). نتایج آنها نشان داد که عملکرد مدل مبتنی بر موجک بهتر از مدل‌های مرسوم است. باجیرائو و همکاران کارایی شبکه عصبی مصنوعی، موجک-شبکه عصبی مصنوعی، سیستم استنتاج عصبی-فازی تطبیقی و سیستم استنتاج عصبی-فازی تطبیقی-موجک را در شبیه‌سازی رواناب روزانه ارزیابی کردند ( Bajirao et al., 2021). نتایج نشان داد که مدل‌های ترکیبی با نظریه موجک عملکرد بهتری نسبت به مدل‌های ساده دارند.

السومائی با هدف بررسی چالش مدل‌سازی تبخیر از تشت روزانه در آب و هوای خشک، سه تکنیک یادگیری ماشین: درخت‌های رگرسیون، فرایندهای گاوسی و رگرسیون ماشین بردار پشتیبان را برای مدل‌سازی میزان تبخیر از تشت روزانه در دو ایستگاه هواشناسی در کویت به کار بردند (Alsumaiei, 2024). نتایج تحقیق آنها نشان داد که برای نرخ تبخیر روزانه از تشت که بیش از ۲۵ میلی‌متر در روز، در پیش‌بینی‌های مدل سوگیری مشاهده شد.

بنچابا و همکاران رویکرد جدیدی را پیشنهاد کردند که تبدیل موجک گسسته با حداکثر همپوشانی (MODWT) را با تکنیک‌های پیشرفته هوش مصنوعی (MODWT-جنگل تصادفی (MODWT-RF)، MODWT-XGBoost، MODWT-ماشین‌های بردار پشتیبان (MODWT-SVM) و MODWT-شبکه‌های عصبی تابع پایه شعاعی (MODWT-RBFNN)) برای مدل‌سازی تبخیر از تشت ترکیب می‌کند (Benchaiba et al., 2025). نتایج تحقیق آنها نشان



شکل ۱- موقعیت ایستگاه‌های مورد بررسی در استان لرستان

جدول ۱- خصوصیات آماری داده‌های مورد استفاده در ایستگاه‌های موجود در استان لرستان

ایستگاه	واریانس	ضریب چولگی	انحراف معیار	میانگین (mm/day)	کمینه (mm/day)	بیشینه (mm/day)
النگر	۱۷/۳	۰/۴	۴/۲	۴/۴	۰/۰	۴۴/۰
الیگودرز	۲۹/۶	۰/۴	۵/۴	۵/۶	۰/۰	۴۰/۰
بروجرد	۲۵/۰	۰/۵	۵/۰	۵/۲	۰/۰	۵۱/۵
دورود	۱۳/۷	۰/۲	۵/۶	۶/۲	۰/۰	۲۰/۳
خرم‌آباد	۲۳/۰	۰/۳	۴/۸	۵/۱	۰/۰	۲۰/۲
کوه‌دشت	۲۵/۱	۰/۴	۵/۰	۵/۴	۰/۰	۵۱/۱
نورآباد	۲۷/۴	۰/۴	۵/۲	۵/۲	۰/۰	۴۰/۴
پلدختر	۳۷/۶	۰/۲	۶/۱	۸/۱	۰/۰	۵۰/۰

### جنگل تصادفی (RF)

جنگل تصادفی (Random Forest) ترکیبی از چندین درخت تصمیم است که شامل نمونه‌های خودسازمان‌یافته‌ای از داده‌ها می‌شود (Friedman et al., 2001). در مدل جنگل،  $X_n$  یک بردار تصادفی که مستقل از بردارهای تصادفی  $X_1, X_2, \dots, X_{n-1}$  است، برای  $n$  امین درخت تولید می‌شود. همچنین، همه بردارها از توزیع یکسانی پیروی می‌کنند. رگرسیون درختی با استفاده از مجموعه آموزشی و محاسبات انجام‌شده، مجموعه‌ای از درختان  $X_n$  به تعداد  $n$  تولید می‌کند که به صورت زیر است (Breiman, 2001).

$$X_n = \{h_1(x), h_2(x), \dots, h_n(x)\} \quad (1)$$

$$h_n = h(x, X_n), x = \{x_1, x_2, \dots, x_p\} \quad (2)$$

در نهایت خروجی برای هر درخت به صورت زیر حاصل می‌شود:

$$y_1 = h_1(x), y_2 = h_2(x), \dots, y_n = h_n(x) \quad (3)$$

که  $y_n$  برابر با خروجی درخت  $n$ ام است. برای به دست آوردن خروجی نهایی، میانگین تمام درخت‌های پیش‌بینی شده محاسبه می‌شود (Breiman, 2001).

### تبدیل موجک (Wavelet Transforms)

نظریه موجک یک روش ریاضی است که از نظریه فوریه در قرن نوزدهم مشتق شده، اما حدود دو دهه است که مورد استفاده قرار می‌گیرد (Solgi et al., 2017). تبدیل موجک یک تبدیل ریاضی کارآمد در حوزه پردازش سیگنال است. موجک‌ها توابع ریاضی هستند که شکل مقیاس-زمانی سری‌های زمانی و توابع آن‌ها را برای تحلیل سری‌های زمانی شامل متغیرهای غیرساکن ارائه می‌دهند. تحلیل موجک بازه‌های زمانی طولانی‌تر برای اطلاعات با فرکانس پایین و بازه‌های زمانی کوتاه‌تر برای اطلاعات با فرکانس بالا فراهم می‌کند. این تحلیل قادر است جنبه‌های مختلف داده‌ها، نقاط شکست و ناپیوستگی‌هایی را نشان دهد که سایر روش‌های تحلیل سیگنال

ممکن است نتوانند آشکار کنند. تابع موجک دو ویژگی مهم یعنی نوسانی بودن و کوتاه‌مدت بودن را دارد. ضریب موجک را می‌توان در هر نقطه از سیگنال (b) و برای هر مقدار مقیاس (a) با معادله زیر محاسبه کرد (Mallat, 1989):

$$T(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \psi\left(\frac{t-b}{a}\right) f(t) dt \quad (4)$$

در معادله فوق،  $\psi$  تابع موجک،  $a$  مقیاس و  $b$  تابع انتقال است. با تغییر مقدار  $T$  مقادیر مختلفی برای  $a$  و  $b$  به دست می‌آید (Mallat, 1998; Solgi et al., 2017). متداول‌ترین توابع موجک، توابع موجک هار نامیده می‌شوند. تابع موجک هار ساده‌تر و یکی از اولین موجک‌هاست. تابع موجک دابچیز یکی از کارآمدترین توابع موجک در تشخیص ناپیوستگی‌های محلی در سیگنال‌ها می‌باشد (Daubechies, 1990). تابع موجک سیملت دارای ویژگی‌هایی مشابه خانواده دابچیز است. توابع  $Sym4$  و  $Sym6$  تقریباً متقارن بوده و در تشخیص آسیب کاربرد دارند. از دیگر توابع موجک می‌توان به گاوسی، مورله، مایر، کویف، مکزیکن هت و بیور (Gaussian, Morlet, Meyer, Coif, Mexicanhat and Bior) اشاره کرد (Solgi et al., 2017). در این مطالعه از دو سطح تجزیه نظریه موجک و موجک دابچیز ۴ استفاده شده است. این نوع موجک در مطالعات مختلف در حوزه هیدرولوژی و منابع آب مورد استفاده قرار گرفته است (Ekmekcioğlu et al., 2020; Nazeri Tahroudi and Mirabbasi, 2023).

### معیارهای ارزیابی

در این مطالعه، از آماره‌های مختلفی از جمله جذر میانگین مربعات خطا (RMSE)، ضریب کارایی نش-ساتکلیف (NSE) و ضریب تعیین ( $R^2$ ) برای ارزیابی عملکرد مدل‌ها استفاده شده است. RMSE معیاری برای سنجش میزان خطای پیش‌بینی مدل، NSE شاخصی برای ارزیابی دقت مدل نسبت به میانگین داده‌ها و  $R^2$  نشان‌دهنده

کرد که در مقیاس ماهانه و در ماه‌های سرد سال (اکتبر تا فوریه) در بیشتر ایستگاه‌ها (به‌ویژه الشتر، الیگودرز، بروجرد، دورود و پلدختر) روند کاهشی معنادار ( $Z < -1.96$ ) در تبخیر از تشت مشاهده می‌شود. در ایستگاه خرم‌آباد و کوه‌دشت در دسامبر و ژانویه روند کاهشی معنادار نیست ( $Z$  نزدیک به صفر)، که احتمالاً ناشی از تأثیر عوامل محلی مانند وارونگی دمایی یا تغییرات رطوبتی است. در اکتبر روند تغییرات کاهشی در ایستگاه خرم‌آباد غیر معنی‌دار در سطح ۵ درصد و در سایر ایستگاه‌ها معنی‌دار گزارش شد. در November نیز روند تغییرات کاهشی در مقادیر تبخیر از تشت ماهانه در همه ایستگاه‌ها به غیر از ایستگاه الشتر و الیگودرز معنی‌دار در سطح ۵ درصد می‌باشد. در February، January، December یک از ایستگاه‌های مورد مطالعه در مقادیر تبخیر از تشت ماهانه مشاهده نشد.

در March، تمام ایستگاه‌ها (به‌جز پلدختر و نورآباد) روند افزایشی معنادار در تبخیر از تشت ماهانه را نشان می‌دهند که احتمالاً به دلیل افزایش دما و کاهش بارندگی در فصل است که مطابق با یافته‌های طبری و معروفی (Tabari and Marofi, 2011) و سروش و همکاران (Soroush et al., 2020) در بررسی روند تبخیر در ایران می‌باشد. در ماه April در همه ایستگاه‌های مورد مطالعه به غیر از بروجرد روند تغییرات تبخیر افزایشی می‌باشد که تغییرات افزایشی در ایستگاه‌های الشتر و نورآباد در سطح ۵ درصد معنی‌دار می‌باشد. عمده تغییرات تبخیر از تشت در ماه May در ایستگاه‌های مورد مطالعه کاهشی بوده ولی تغییرات سه ایستگاه خرم‌آباد، کوه‌دشت و نورآباد افزایشی است که تنها ایستگاه نورآباد در سطح ۵ درصد معنی‌دار گزارش شد. در June روند تغییرات تبخیر از تشت در ۶ ایستگاه از ۸ ایستگاه افزایشی و غیر معنی‌دار و در دو ایستگاه دیگر کاهشی می‌باشد. در July تغییرات تبخیر از تشت در ۵ ایستگاه از ۸ ایستگاه کاهشی گزارش شده است و تغییرات معنی‌دار در سطح ۵ درصد تنها در ایستگاه الیگودرز مشاهده شد. در ایستگاه خرم‌آباد در August بر خلاف سایر ایستگاه‌های مورد مطالعه تغییرات افزایشی در مقادیر تبخیر از تشت مشاهده شده است. در این ماه روند تغییرات تبخیر از تشت در سایر ایستگاه‌ها کاهشی می‌باشد (الشتر و بروجرد در سطح ۵ درصد معنی‌دار). در September نیز تغییرات تبخیر از تشت در همه ایستگاه‌ها کاهشی می‌باشد که احتمالاً به دلیل کاهش دما و افزایش رطوبت در آغاز پاییز است. در این بین تغییرات کاهشی در همه ایستگاه‌ها به غیر از خرم‌آباد و کوه‌دشت در سطح ۵ درصد معنی‌دار می‌باشد.

از عوامل مؤثر در تبخیر می‌توان دمای هوا، سرعت باد و رطوبت نسبی را در نظر گرفت. افزایش دما معمولاً تبخیر را افزایش می‌دهد، اما در برخی مناطق کاهش سرعت باد یا رطوبت ممکن است اثر معکوس داشته باشد. در ایستگاه‌هایی مانند پلدختر، کاهش سرعت باد

میزان انطباق مدل با داده‌های واقعی است. این معیارها به‌صورت گسترده در مطالعات هیدرولوژی و مدل‌سازی منابع آب مورد استفاده قرار می‌گیرند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (S_i - O_i)^2}{n-1}} \quad (5)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (S_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \quad (6)$$

$$R^2 = \left[ \frac{n(\sum_{i=1}^n S_i O_i) - (\sum_{i=1}^n S_i)(\sum_{i=1}^n O_i)}{\sqrt{[n\sum_{i=1}^n S_i^2 - (\sum_{i=1}^n S_i)^2][n\sum_{i=1}^n O_i^2 - (\sum_{i=1}^n O_i)^2]}} \right]^2 \quad (7)$$

که در آن،  $n$  برابر با تعداد داده‌ها،  $O_i$  برابر با مقادیر مشاهداتی،  $\bar{O}_i$  برابر با متوسط مقادیر مشاهداتی، و  $S_i$  برابر با مقادیر شبیه‌سازی شده و یا خروجی مدل می‌باشد (Nash and Sutcliffe, 1970; Raji et al., 2022).

همچنین در این مطالعه جهت بررسی روند تغییرات مقادیر مورد مطالعه از آزمون من-کندال اصلاح شده با حذف اثرات خودهمبستگی داخلی استفاده شد که جهت اطلاع از آماره‌های آن می‌توان به (Mann., 1945; Kendall., 1963; Hamed and Rao., 1998; Kumar et al., 2009; Khalili et al., 2016; Khozeynezhad and Tahroudi., 2019; Ahmadi et al., 2018; Tahroudi et al., 2019) مراجعه کرد. جهت شبیه‌سازی و اجرای مدل تلفیقی، ۸۰ درصد داده‌های مورد مطالعه جهت آموزش مدل و ۲۰ درصد نیز جهت آزمایش مدل استفاده شد.

## نتایج و بحث

### نتایج بررسی روند تغییرات مقادیر مورد مطالعه


قبل از تجزیه سری زمانی تبخیر از تشت در ایستگاه‌های مورد مطالعه، ابتدا روند تغییرات این پارامتر در مقیاس ماهانه و سالانه با استفاده از آزمون من-کندال اصلاح شده مورد ارزیابی قرار گرفت. نتایج بررسی روند تغییرات (آماره آزمون من-کندال اصلاح شده و شیب خط روند) مقادیر تبخیر از تشت در دو مقیاس ماهانه و سالانه به‌صورت شکل ۲ و جدول ۲ ارائه شد.

آزمون من-کندال اصلاح شده یکی از روش‌های ناپارامتریک برای شناسایی روند در داده‌های سری زمانی است. مقادیر مثبت  $Z$  نشان‌دهنده روند افزایشی و مقادیر منفی بیانگر روند کاهشی هستند. اگر مقدار  $Z$  بین  $-1/96$  تا  $+1/96$  باشد، روند از نظر آماری معنادار نیست (در سطح اطمینان ۹۵٪). با توجه به شکل ۲ می‌توان مشاهده

تشت در ایستگاه‌های یاد شده در سطح ۵ درصد معنی‌دار نمی‌باشد. در مقیاس سالانه روند کاهشی معنادار در ایستگاه‌های بروجرد، دورود و پلدختر رخ داده است ( $Z < -1.96$ ) که می‌تواند ناشی از کاهش سرعت باد، افزایش ابرناکی یا کاهش دمای میانگین سالانه باشد (Dinpashoh et al., 2011).

می‌تواند دلیل روند کاهشی تبخیر باشد. از طرفی افزایش رطوبت (به‌ویژه در ماه‌های سرد سال) می‌تواند تبخیر را کاهش دهد (Roderick and Farquhar, 2002; Shahidi et al., 2020).

در مقیاس سالانه روند تغییرات تبخیر از تشت در ایستگاه‌های خرم‌آباد، کوهدشت و نورآباد افزایشی و در سایر ایستگاه‌های مورد مطالعه کاهشی می‌باشد. تغییرات روند افزایشی در مقادیر تبخیر از



شکل ۲- آماره آزمون من-کندال اصلاح شده در بررسی روند تغییرات مقادیر تبخیر از تشت در ایستگاه‌های مورد مطالعه

جدول ۲- آماره شیب خط روند مقادیر تبخیر از تشت در ایستگاه‌های مورد مطالعه

مقیاس	پلدختر	نورآباد	کوهدشت	خرم‌آباد	دورود	بروجرد	الیگودرز	الشتر
October	-۹/۳۳	-۶/۲۴	-۳/۸۳	-۴/۳۵	-۴/۵۸	-۵/۹۴	-۴/۸۳	-۴/۰۷
November	-۵/۹۵	-۴/۹۲	-۲/۹۴	-۲/۸۳	-۵/۱۶	-۲/۸۴	-۲/۴۳	-۴/۱۲
December	-۱/۰۲	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰
January	-۲/۱۹	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰
February	-2.26	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰	۰/۰۰
March	-۶/۸۶	۰/۰۰	۰/۰۰	۱/۴۵	۰/۰۰	۱/۴۳	۱/۲۱	۰/۰۰
April	۱/۰۳	۹/۹۵	۵/۴۰	۶/۹۰	۲/۵۸	-۰/۲۷	۴/۰۲	۵/۲۹
May	-۲/۲۴	۱۳/۳۴	۳/۶۱	۲/۴۴	-۱/۴۶	-۱/۳۸	-۱/۰۶	-۰/۸۲
June	-۴/۴۰	۳/۰۲	۴/۷۵	۳/۱۰	۱/۷۹	-۱/۵۵	۰/۲۹	۰/۳۶
July	-۵/۳۵	۱/۰۳	۱/۴۲	۲/۱۲	-۰/۱۶	-۲/۴۰	-۲/۷۰	-۰/۱۶
August	-۵/۹۹	-۰/۵۶	-۱/۱۵	۱/۶۹	-۳/۰۷	-۴/۷۱	-۲/۷۱	-۳/۰۰
September	-۶/۶۶	-۴/۶۶	-۱/۵۴	-۰/۹۱	-۳/۶۱	-۵/۸۸	-۴/۴۱	-۴/۳۶
Annual	-۵۳/۴۱	۱۱/۶۳	۹/۱۳	۱۰/۱۴	-۱۷/۱۵	-۲۷/۱۴	-۱۴/۵۸	-۱۱/۴۸

مطالعات طبری و حسین‌زاده طلایی نیز در شمال غرب ایران کاهش تبخیر از تشت را گزارش کرده‌اند که با نتایج ایستگاه‌های دارای روند کاهش همخوانی دارد (Tabari and Hosseinzadeh, 2014). لئو و همکاران نیز در چین نشان دادند که افزایش تبخیر در مناطق خشک‌تر (مانند خرم‌آباد در این مطالعه) می‌تواند به دلیل کاهش بارندگی و افزایش دما باشد (Liu et al., 2004).

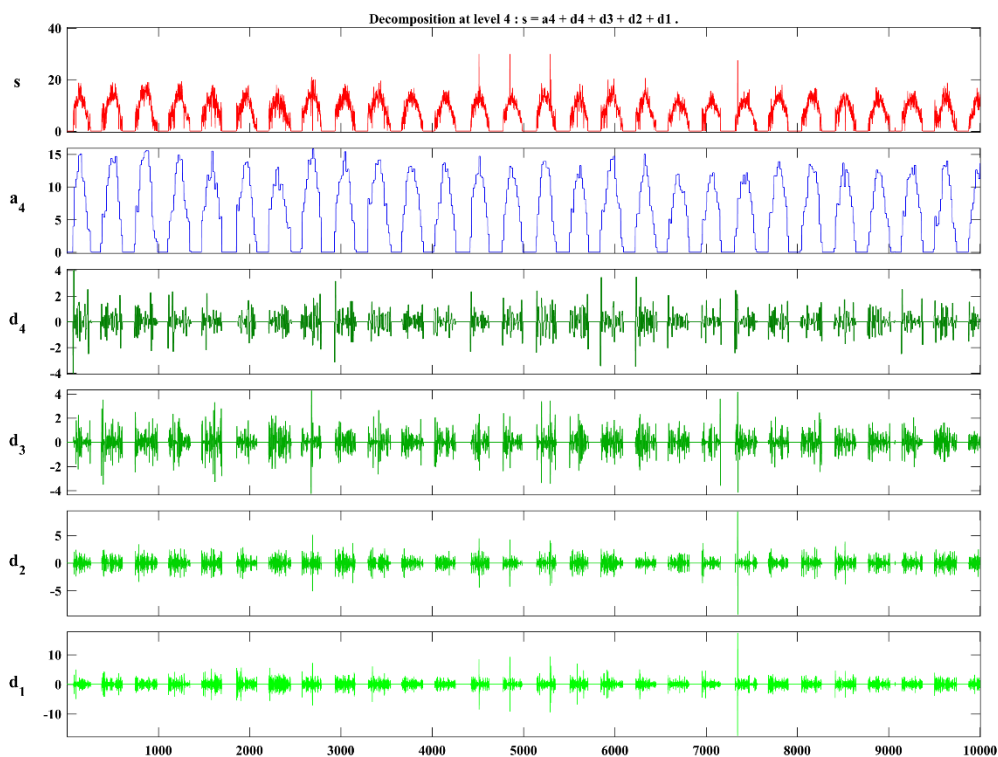
به طور کلی نتایج بررسی روند تغییرات تبخیر از تشت نشان داد که ایستگاه‌های کوهستانی (مانند بروجرد و نورآباد) روندهای متفاوتی نسبت به ایستگاه‌های کم‌ارتفاع (مانند خرم‌آباد و پلدختر) نشان می‌دهند. با توجه به جدول ۲ نیز می‌توان مشاهده کرد که شیب خط روند در ماه‌های مختلف مقادیر متفاوتی را ارائه می‌کند، در مقیاس سالانه بیشترین تغییرات کاهش برای ایستگاه پلدختر با کاهش ۵۳/۴۱ میلی‌متر به ازای هر سال می‌باشد و بیشترین افزایش ۹/۱۳ و ۱۰/۱۴ و ۱۱/۶۳ میلی‌متر به ازای هر سال به ترتیب در ایستگاه‌های کوهدشت، خرم‌آباد و نورآباد رخ داده است.

#### نتایج تجزیه مقادیر تبخیر از تشت مبتنی بر تئوری موجک

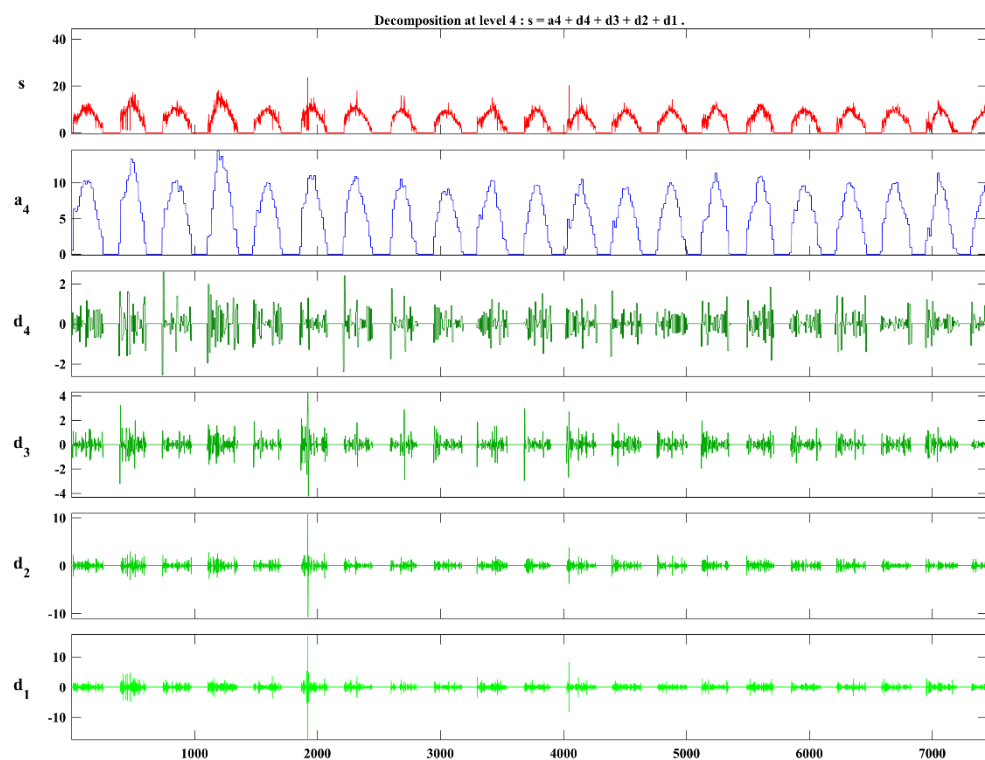
مقادیر روزانه تبخیر از تشت در ایستگاه‌های مورد مطالعه با استفاده از تئوری موجک در سطح تجزیه ۴ با در نظر گرفتن موجک دابچیز تجزیه شده و نتایج به صورت شکل‌های ۳ تا ۱۰ قابل مشاهده می‌باشد. در این سطح تجزیه هر سری زمانی تبخیر از تشت در مقیاس روزانه به یک Approximate و ۴ Detail تجزیه می‌شود. تحلیل موجک یک ابزار قدرتمند در پردازش سیگنال‌های غیرایستا

(غیرساکن) است که امکان بررسی هم‌زمان مؤلفه‌های فرکانسی و زمانی را فراهم می‌کند. برخلاف تبدیل فوریه که فقط اطلاعات فرکانسی ارائه می‌دهد، موجک‌ها با قابلیت مقیاس‌پذیری (Scale) و انتقال (Shift)، ساختارهای چند مقیاسی داده‌ها را آشکار می‌سازند. موجک Daubechies به دلیل متعامد بودن با ضریب فشردگی بالا و Compact Support انتخاب شد. موجک db4 به دلیل پشتیبانی فشرده، تغییرات ناگهانی (مثلاً تبخیر ناشی از طوفان‌های گردوغبار) را بهتر از موجک‌های با پایه طولانی (مثل Haar) تشخیص می‌دهد (Mallat, 2009). این موجک دارای ۴ ضریب فیلتر است که تعادل مناسبی بین Smoothness و حساسیت زمانی ایجاد می‌کند. در این روش، داده‌های تبخیر از تشت به ۴ سطح تفکیک می‌شوند:


۱. سطح ۱ (D1) که جزئیات با فرکانس بالا (نویز یا تغییرات کوتاه‌مدت) را نشان می‌دهد.
  ۲. سطح ۲ (D2) که جزئیات با فرکانس متوسط را استخراج می‌کند.
  ۳. سطح ۳ (D3) نیز جزئیات با فرکانس پایین را نشان می‌دهد.
  ۴. و در نهایت سطح ۴ (D4) که جزئیات نوسانات در مقیاس بزرگ را استخراج می‌کند.
  ۵. Approximation که مؤلفه‌ی پایه (روند بلندمدت) در سری زمانی است.
- این تجزیه کمک می‌کند تا روند بلندمدت (Approximation) از نوسانات کوتاه‌مدت (D1-D4) جدا شده و الگوهای فصلی و غیرخطی در داده‌های تبخیر شناسایی گردد.




شکل ۳- نتایج تجزیه مقادیر روزانه تبخیر از تشت با استفاده از تئوری موجک در ایستگاه الیگودرز (محور افقی: تعداد داده‌ها)



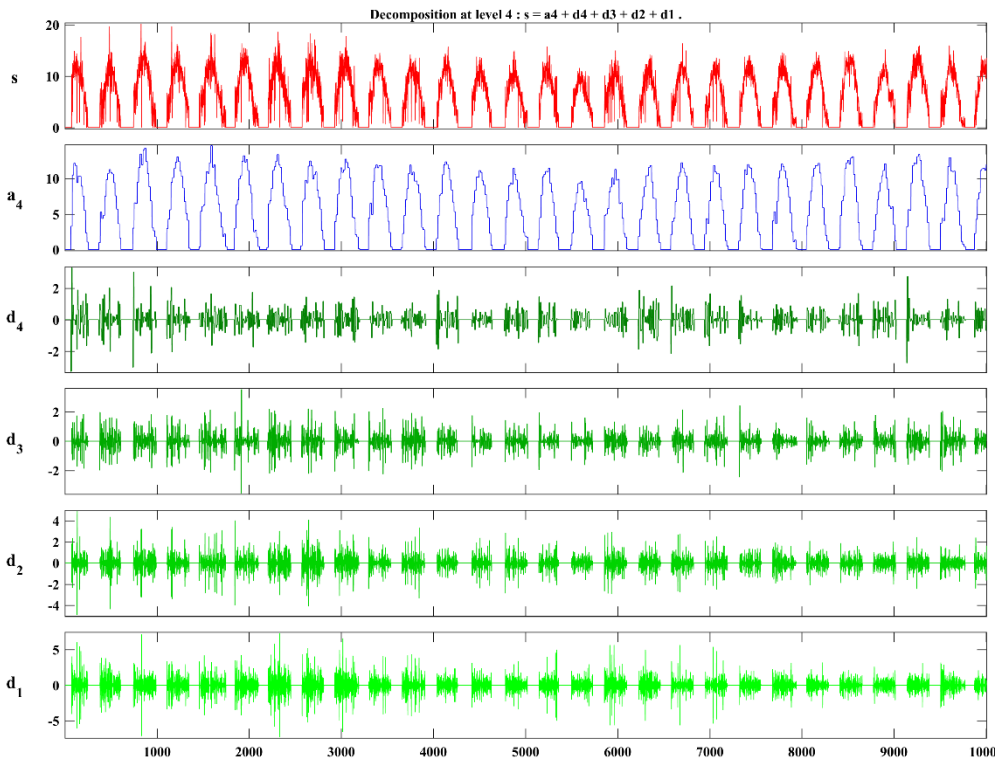
شکل ۴- نتایج تجزیه مقادیر روزانه تبخیر از تشت با استفاده از تئوری موجک در ایستگاه الشتر (محور افقی: تعداد داده‌ها)




شکل ۵- نتایج تجزیه مقادیر روزانه تبخیر از تشت با استفاده از تئوری موجک در ایستگاه بروجرد (محور افقی: تعداد داده‌ها)




شکل ۶- نتایج تجزیه مقادیر روزانه تبخیر از تشت با استفاده از تئوری موجک در ایستگاه دورود (محور افقی: تعداد داده‌ها)




شکل ۷- نتایج تجزیه مقادیر روزانه تبخیر از تشتت با استفاده از تئوری موجک در ایستگاه خرم‌آباد (محور افقی: تعداد داده‌ها)



شکل ۸- نتایج تجزیه مقادیر روزانه تبخیر از تشتت با استفاده از تئوری موجک در ایستگاه کوه‌دشت (محور افقی: تعداد داده‌ها)



شکل ۱۰- نتایج تجزیه مقادیر روزانه تبخیر از تشت با استفاده از تئوری موجک در ایستگاه نورآباد (محور افقی: تعداد داده‌ها)



شکل ۱۱- نتایج تجزیه مقادیر روزانه تبخیر از تشت با استفاده از تئوری موجک در ایستگاه پلدختر (محور افقی: تعداد داده‌ها)

### نتایج شبیه‌سازی مقادیر تبخیر از تشت در ایستگاه‌های مورد

#### مطالعه با استفاده از رویکرد Wavelet-RF

در این مطالعه عملکرد رویکرد Wavelet-RF در شبیه‌سازی مقادیر تبخیر از تشت با استفاده از چهار معیار ارزیابی اعم از جذر میانگین مربعات خطا (RMSE)، ضریب کارایی نش-ساتکلیف (NSE)، شاخص ویلموت (WI) و ضریب همبستگی (Correlation) مورد بررسی قرار گرفته است. در فاز آموزش مقادیر آماره‌های یاد شده به صورت جدول ۳ ارائه شده است.

جهت شبیه‌سازی مقادیر تبخیر از تشت در ایستگاه‌های مورد مطالعه با استفاده از رویکرد تلفیقی Wavelet-RF، در ابتدا سیگنال‌های تجزیه شده مبتنی بر تئوری موجک با استفاده از مدل RF شبیه‌سازی شده و در دو فاز آموزش و آزمایش مورد بررسی قرار می‌گیرد. شبیه‌سازی بدین صورت است که تمام سیگنال‌های تجزیه شده با استفاده از تئوری موجک و همچنین با در نظر گرفتن سایر سیگنال‌های تجزیه شده در دو فاز آموزش و آزمایش شبیه‌سازی شده و در نهایت با تجمیع سیگنال‌های تجزیه شده مقادیر اصلی حاصل می‌شود.

جدول ۳- نتایج ارزیابی مدل Wavelet-RF در شبیه‌سازی مقادیر تبخیر از تشت در ایستگاه‌های مورد مطالعه در فاز آموزش

ایستگاه	Correlation	WI	NSE	RMSE (mm/day)
الشر	۰/۹۷	۰/۹۸	۰/۹۴	۱/۰۵
الیگودرز	۰/۹۶۹	۰/۹۸۲	۰/۹۳۴	۱/۴۱۱
بروجرد	۰/۹۵۹	۰/۹۷۵	۰/۹۱۳	۰/۵۱۷
دورود	۰/۹۷۰	۰/۹۸۲	۰/۹۳۷	۱/۴۰۶
خرم‌آباد	۰/۹۶۴	۰/۹۷۸	۰/۹۲۲	۰/۳۳۲
کوه‌دشت	۰/۹۶۸	۰/۹۸۰	۰/۹۳۰	۱/۳۱۸
نورآباد	۰/۹۷۶	۰/۹۸۶	۰/۹۵۰	۰/۱۶۳
پلدختر	۰/۹۷۶	۰/۹۸۰	۰/۹۳۴	۱/۵۶۴

مشابه که از ترکیب موجک (Wavelet) و سایر مدل‌ها برای پیش‌بینی تبخیر استفاده کرده‌اند، معمولاً مقادیر NSE بین ۰/۸۵ تا ۰/۹۵ و همبستگی بین ۰/۸۹ تا ۰/۹۹ گزارش کردند (Qasem et al., 2019).

به طور کلی در فاز آموزش مقادیر NSE، WI و  $R^2$  در همه موارد بسیار بالا هستند، که نشان می‌دهد مدل Wavelet-RF برای پیش‌بینی تبخیر از تشت در مناطق مختلف قابل اعتماد است. این موضوع نشان می‌دهد که ترکیب تبدیل موجک (برای استخراج ویژگی‌های زمانی-فرکانسی) و جنگل تصادفی (برای مدل‌سازی غیرخطی) یک روش بهینه برای شبیه‌سازی تبخیر باشد، چرا که می‌تواند هم تغییرات سری زمانی و هم روابط پیچیده بین متغیرها را شناسایی کند. با توجه به نتایج ارائه شده در فاز آموزش و تأیید نتایج در این فاز، عملکرد مدل‌ها در فاز آزمایش نیز بررسی شده که نتایج به صورت شکل ۱۱ ارائه شده است.

با توجه به شکل ۱۱ می‌توان مشاهده کرد که مقادیر RMSE بین ۱/۸۶ (الشر) تا ۲/۹۱ (پلدختر) میلی‌متر بر روز متغیر است. ایستگاه پلدختر بالاترین خطا را در فاز آموزش دارد که ممکن است ناشی از پیچیدگی شرایط اقلیمی یا نویز در داده‌های این ایستگاه

با توجه به جدول ۳ میتوان مشاهده کرد که کمترین RMSE مربوط به ایستگاه الشر (۱/۰۵ mm/day) و بیشترین مقدار مربوط به پلدختر (۱/۵۶ mm/day) است. تفاوت RMSE بین ایستگاه‌ها ممکن است ناشی از تفاوت در کیفیت داده‌های ورودی یا شرایط اقلیمی خاص هر منطقه باشد. همچنین نتایج نشان داد که بر اساس آماره NSE در تمام ایستگاه‌ها این شاخص در فاز آموزش بالاتر از ۰/۹۱ است که نشان‌دهنده تطابق بسیار خوب مدل با داده‌های واقعی است. بهترین عملکرد مربوط به نورآباد (۰/۹۵) و کمترین مقدار مربوط به بروجرد (۰/۹۱۳) است. شاخص WI (Willmott Index) شاخصی بین ۰ تا ۱ که هرچه به ۱ نزدیک‌تر باشد، نشان‌دهنده توافق بهتر بین داده‌های شبیه‌سازی شده و واقعی است. بر اساس جدول ۳، تمام ایستگاه‌ها WI بالاتر از ۰/۹۷ دارند که نشان‌دهنده دقت بسیار بالای مدل در فاز آموزش است. بهترین نتیجه در نورآباد (۰/۹۸۶) و کمترین مقدار در بروجرد (۰/۹۷۵) مشاهده می‌شود. بر اساس ضریب همبستگی نیز می‌توان مشاهده کرد که تمام ایستگاه‌ها ضریب همبستگی بالای ۰/۹۵ دارند که نشان‌دهنده رابطه خطی قوی است. با توجه به جدول ۳، بالاترین مقدار همبستگی در نورآباد و پلدختر (۰/۹۷۶) و کمترین در بروجرد (۰/۹۵۹) دیده می‌شود. مطالعات

را با دقت مناسبی پیش‌بینی کند. البته در برخی موارد (مثلاً حول روز ۱۵۰۰)، خط شبیه‌سازی شده با تأخیر نسبت به داده واقعی واکنش نشان می‌دهد. این احتمالاً به دلیل تأخیر در یادگیری روابط پیچیده بین متغیرهای ورودی است، اما با توجه به مقادیر آماره‌های ارزیابی مدل، می‌توان نتیجه گرفت که مدل به‌طور کلی قابل اعتماد است. ضریب  $NSE = 0.79$  نشان‌دهنده این است که مدل حدود ۷۹٪ از تغییرات داده واقعی را توضیح می‌دهد که قابل قبول است.

**ایستگاه کوه‌دشت:** نتایج شبیه‌سازی مقادیر تبخیر از تشت نشان داد که مدل توانسته نوسانات فصلی را به‌خوبی شناسایی کند و همبستگی واضح بین دو خط در بیشتر دوره‌ها نشان می‌دهد که مدل توانسته تغییرات بلندمدت را به‌خوبی دنبال کند. همچنین می‌توان مشاهده کرد که مدل Wavelet-RF در تغییرات ناگهانی در روزهای ۴۰۰-۵۰۰ و ۱۲۰۰-۱۳۰۰ به خوبی به تغییرات سریع پاسخ داده است. همچنین می‌توان مشاهده کرد که دقت مدل در مقادیر متوسط برای مقادیر تبخیر از تشت ۵ تا ۱۵ میلی‌متر دقت بسیار خوبی دارد. اما در برخی موارد نیز (در روزهای ۱۱۰۰-۱۰۰۰) واکنش مدل با تأخیر همراه بوده است و همچنین می‌توان مشاهده کرد که برای تبخیرهای کمتر از ۵ میلی‌متر، مدل تمایل به بیش‌برآورد دارد که می‌توان به‌عنوان محدودیت از این مدل یاد کرد. به‌طور کلی نتایج بیانگر عملکرد خوب مدل در پیش‌بینی تغییرپذیری داده‌ها در ایستگاه کوه‌دشت است که آماره‌های مختلف این موضوع را تایید می‌کنند.

**ایستگاه نورآباد:** همانند دو ایستگاه یاد شده، هماهنگی استثنایی در روند کلی داده‌ها قابل مشاهده می‌باشد و همچنین مدل به‌خوبی تغییرات فصلی را شناسایی کرده است. قدرت شبیه‌سازی مبتنی بر Wavelet-RF در مقادیر حدی (روزهای ۳۰۰~ و ۱۳۰۰~) بسیار مناسب ارزیابی می‌شود. این موضوع نشان دهنده دقت و کارایی مناسب مدل Wavelet-RF در شبیه‌سازی مقادیر تبخیر از تشت می‌باشد و لزوم تجزیه مویک جهت شناسایی سیگنال‌های مختلف را بیان می‌کند.

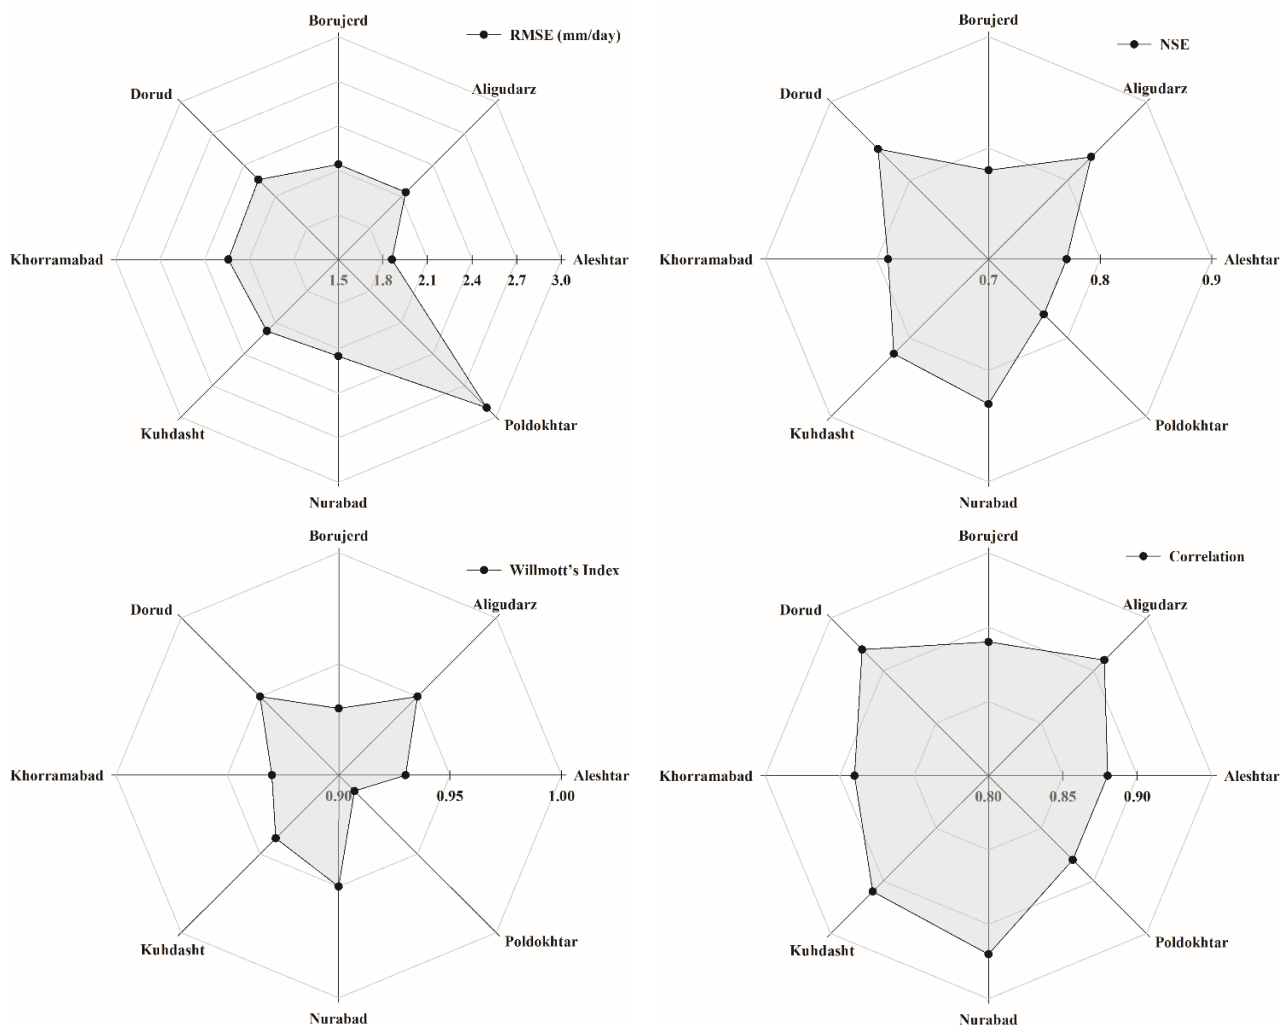
**ایستگاه پلدختر:** در این ایستگاه گستره تبخیر روزانه ۰ تا ۲۲ میلی‌متر وسیع‌تر از سایر ایستگاه‌های مورد بحث تا کنون می‌باشد. در این ایستگاه نیز روند کلی و روند فصلی به خوبی توسط مدل شناسایی شده است و هماهنگی در زمان وقوع قله‌ها و دره‌ها به خوبی وجود دارد. در این ایستگاه نیز می‌توان مشاهده کرد که مدل توانسته به سرعت تطابق پیدا کند و تغییرات ناگهانی را به خوبی پوشش دهد. دقت در مقادیر حدی برای مقادیر بالای ۲۰ میلی‌متر، خطا کمی افزایش می‌یابد که می‌تواند به دلیل ویژگی‌های اقلیمی ایستگاه باشد که نسبت به سایر ایستگاه‌های مورد مطالعه اقلیم گرم‌تری دارد. به‌طور کلی نتایج نشان می‌دهد که اگرچه مدل در این ایستگاه با چالش‌هایی روبرو است، ولی عملکرد قابل قبول مدل قابل مشاهده می‌باشد.

لازم به ذکر است که این ایستگاه اقلیم گرم‌تری نسبت به سایر ایستگاه‌های مورد مطالعه دارد. ایستگاه الشتر کمترین خطا را نشان می‌دهد که نشانگر تطابق بهتر مدل با داده‌های این منطقه است. مقادیر NSE در فاز آزمایش بین ۰/۷۷ تا ۰/۸۴ متغیر است. ایستگاه دورود (۰/۸۴) و الیگودرز (۰/۸۳) بهترین عملکرد را دارند، در حالی که دو ایستگاه پلدختر و الشتر (۰/۷۷) کمترین مقدار NSE را در فاز آزمایش نشان می‌دهند. مقادیر بالای ۰/۷۵ برای آماره NSE در فاز آزمایش نشان‌دهنده عملکرد قابل قبول مدل Wavelet-RF هستند. در خصوص شاخص WI (شاخص ویلموت) در فاز آزمایش، تمام ایستگاه‌ها WI بالاتر از ۰/۹۲ دارند که نشان‌دهنده توافق خوب بین داده‌های پیش‌بینی شده و واقعی است.

به طور کلی نتایج نشان داد که در فاز آزمایش مدل Wavelet-RF در ایستگاه‌های دورود، الیگودرز و نورآباد بهترین عملکرد را دارد (NSE بیش از ۰/۸۳، WI بیش از ۰/۹۵ و  $R^2$  بیش از ۰/۹۱). ایستگاه پلدختر ضعیف‌ترین عملکرد را نشان می‌دهد (بالاترین RMSE و کمترین NSE) ولی در عین حال با توجه به آماره‌های مورد مطالعه عملکرد قابل قبولی ارائه کرد. به‌طور کلی، مدل در مرحله آزمایش از دقت قابل قبولی برخوردار است.

با مقایسه مدل پیشنهادی در شبیه‌سازی مقادیر تبخیر از تشت می‌توان مشاهده کرد که در فاز آزمایش در تمام ایستگاه‌ها، RMSE افزایش و NSE نسبت به فاز آموزش کاهش یافته است. این امر طبیعی است، زیرا مدل در مرحله آموزش با داده‌های مشاهداتی تطابق بهتری دارد و در عدم حضور داده‌های مشاهداتی کمی تغییرات این آماره‌ها در فاز آزمایش طبیعی است. به‌عنوان مثال، مقادیر RMSE در ایستگاه الشتر از ۱/۰۵۳ میلی‌متر در روز (آموزش) به ۱/۸۶ میلی‌متر بر روز (آزمایش) افزایش یافته و آماره NSE از ۰/۹۳۸ به ۰/۷۷ کاهش یافته است. در نهایت با تأیید آماره‌های ارزیابی مدل در فاز آموزش و آزمایش، شبیه‌سازی مقادیر تبخیر از تشت (میلی‌متر بر روز) در فاز آزمایش به‌صورت شکل ۱۲ ارائه شد که خطوط قرمز مقادیر شبیه‌سازی شده و خطوط مشکی مقادیر مشاهداتی را نشان می‌دهد. با توجه به شکل ۱۲ می‌توان تطابق بسیار خوب بین مقادیر مشاهداتی و شبیه‌سازی شده با استفاده از مدل Wavelet-RF را مشاهده کرد. مدل پیشنهادی به خوبی توانسته است مقادیر کمینه و بیشینه داده‌های مشاهداتی شده را پوشش دهد.

**ایستگاه خرم‌آباد:** در تمامی ایستگاه‌های مورد مطالعه می‌توان تطابق کلی در روند تغییرات را مشاهده کرد که نشان دهنده تشخیص روند تغییرات توسط مدل Wavelet-RF است. مدل یاد شده توانسته روند کلی (افزایش/کاهش) تبخیر را در اکثر دوره‌ها به‌خوبی شبیه‌سازی کند. به طور مثال در ایستگاه خرم‌آباد در برخی پیک‌ها (مثلاً حول روز ۱۰۰۰)، مدل موفق شده مقادیر حداکثر تبخیر از تشت



شکل ۱۱- نتایج آماره‌های ارزیابی مدل در شبیه‌سازی تبخیر از تشت در ایستگاه‌های مورد مطالعه

با استفاده از مدل پیشنهادی به‌خوبی شناسایی و شبیه‌سازی شده است. دقت شبیه‌سازی شبیه به ایستگاه الیگودرز بوده ولی آماره نش نسبت به ایستگاه الیگودرز کمتر می‌باشد. نقاط حدی به خوبی شناسایی شده همچنین نقاط کمینه نیز مشابه با تغییرات مشاهده‌ای شناسایی شده است. مدل Wavelet-RF در ایستگاه بروجرد به سطح عملکرد بسیار مطلوبی دست یافته است.

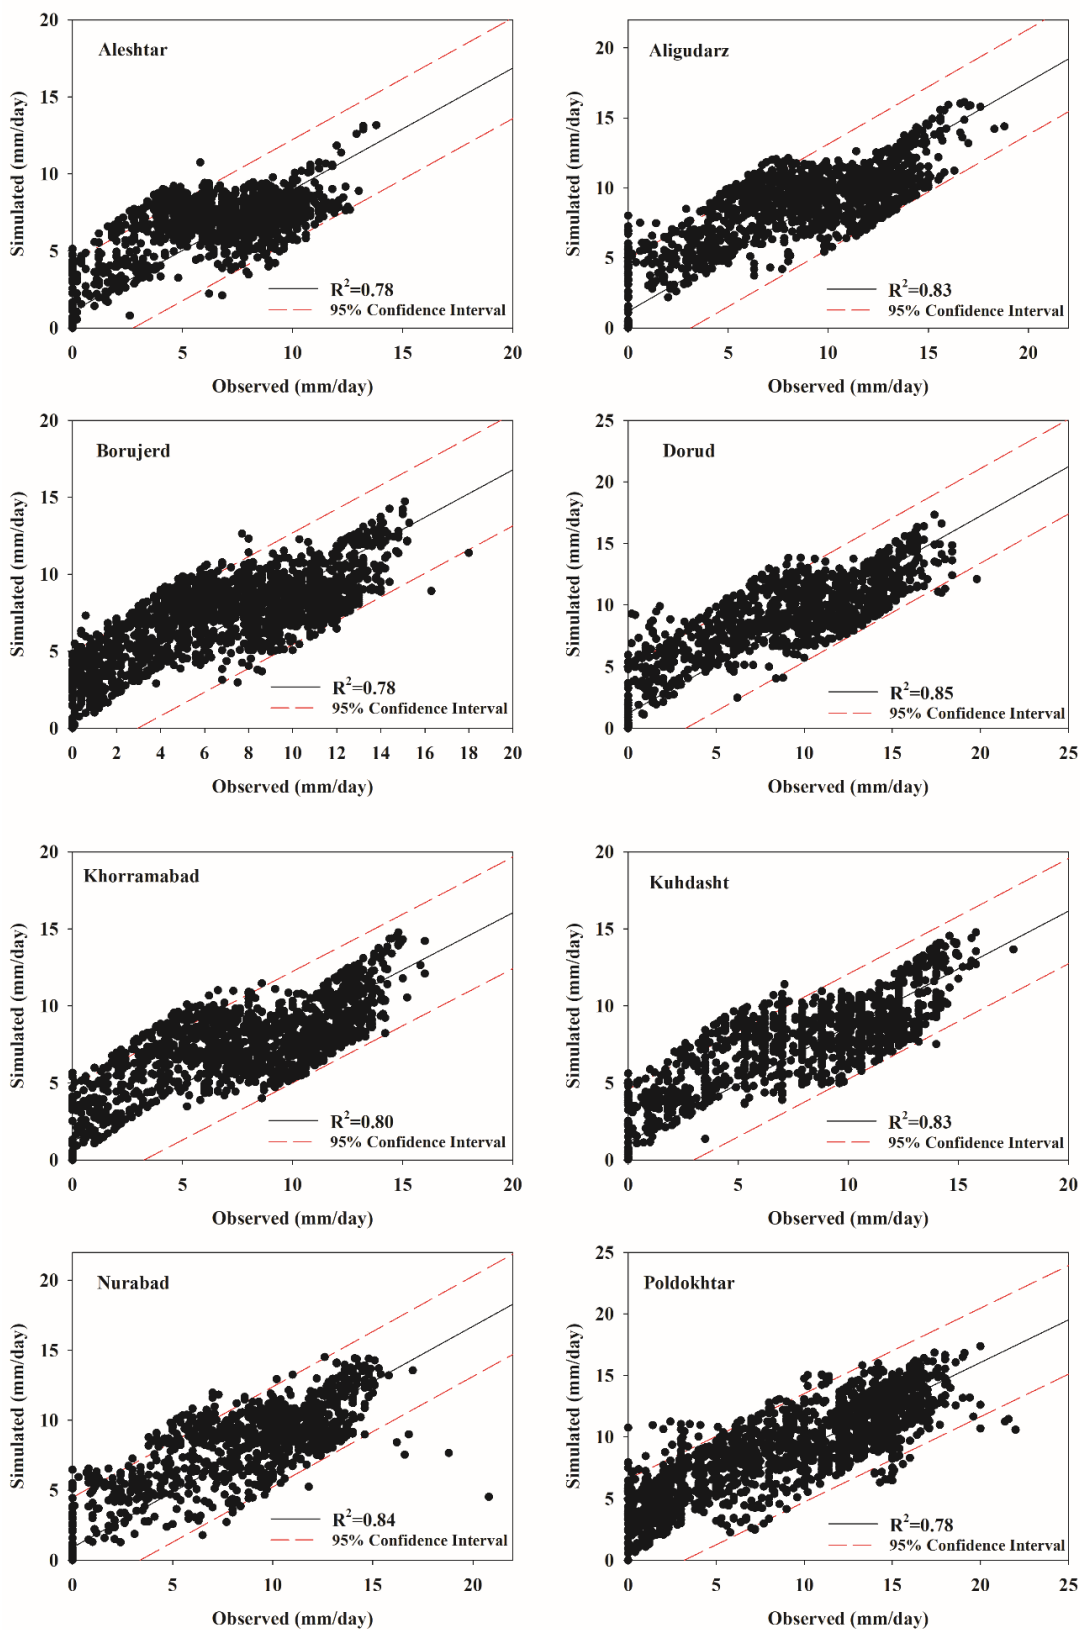
به طور کلی با بررسی عملکرد مدل Wavelet-RF در شبیه‌سازی مقادیر تبخیر از تشت در ایستگاه‌های مورد مطالعه نتایج نشان داد که تطابق فوق‌العاده با الگوهای فصلی (دقت  $> 90\%$  در شناسایی چرخه‌ها)، پاسخگویی سریع به تغییرات ناگهانی و پایداری بالا در شرایط اقلیمی مختلف از خصوصیات مدل یاد شده می‌باشد. Patil and Deka (2017) نیز با بررسی توانایی تئوری موجک با مدل‌های شبکه عصبی مصنوعی در برآورد تبخیر و تعرق روزانه همبستگی

**ایستگاه الشتر:** مقادیر مشاهده‌ای و شبیه‌سازی شده تبخیر از تشت در این ایستگاه نیز همانند ایستگاه پلدختر نسبت به سایر ایستگاه‌های مورد مطالعه از مقادیر NSE کمتری برخوردار است و همان‌طور که مشاهده می‌شود، در برخی مقادیر حدی دقت مناسبی را ارائه نکرده است، گرچه این دقت و میزان خطا نیز قابل قبول می‌باشد. به طور کلی روند تغییرات روزانه و فصلی به خوبی شناسایی شده و مدل در این ایستگاه به سطح مطلوبی از دقت رسیده است.

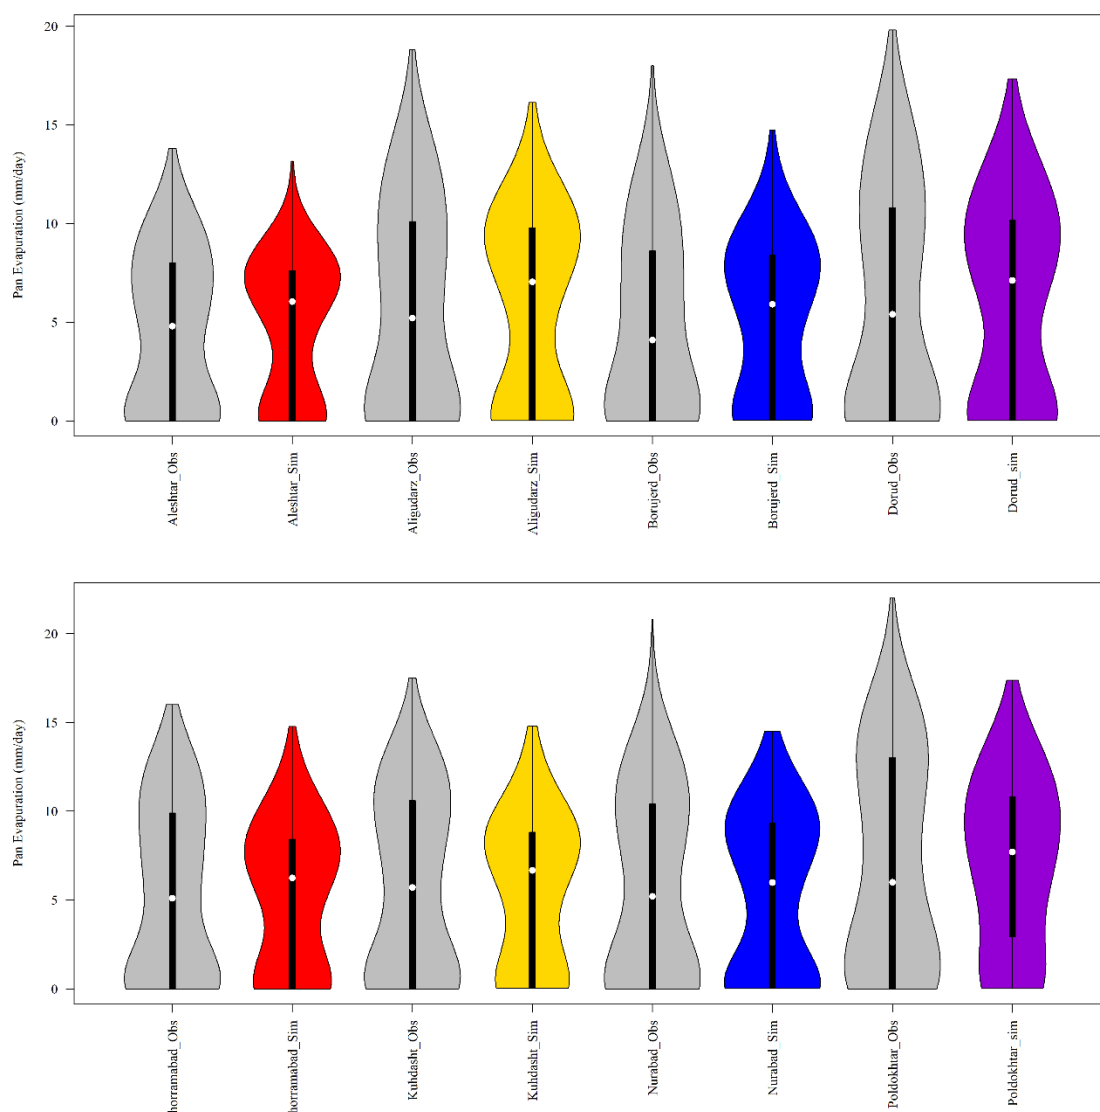
**ایستگاه الیگودرز:** یکی از ایستگاه‌های دارای دقت و عملکرد بسیار خوب در شبیه‌سازی مقادیر تبخیر از تشت با استفاده از مدل Wavelet-RF ایستگاه الیگودرز می‌باشد. در این ایستگاه پیش‌بینی بیک‌های فصلی با دقت بالایی انجام شده است و زمان وقوع بیک‌ها نیز به خوبی شناسایی شده است.

**ایستگاه بروجرد:** نوسانات فصلی و روزانه نیز در این ایستگاه





شکل ۱۳- منحنی‌های ۱-۱ شبیه‌سازی تبخیر از تشت در مقیاس روزانه با استفاده از مدل Wavelet-RF در فاز آزمایش



شکل ۱۴- وایولین پلات مقادیر مشاهداتی و شبیه‌سازی شده در بررسی قطعیت شبیه‌سازی تبخیر از تشت در مقیاس روزانه با استفاده از مدل Wavelet-RF در فاز آزمایش

ایستگاه‌های مورد بررسی از الگوی فصلی و منطقه‌ای مشخصی پیروی می‌کند. در مقیاس ماهانه، بیشترین کاهش معنادار (با مقادیر Z منفی و کمتر از -۱.۹۶) در ماه‌های سرد (اکتبر تا فوریه) رخ داده است. در ایستگاه‌های الشتر، الیگودرز، بروجرد، دورود، خرم‌آباد، کوهدشت، نورآباد و پلدختر شیب روند کاهش به ترتیب -۱۱.۵، -۱۴.۵، -۲۷.۱، -۱۷.۱، +۱۰.۱، +۹.۲، +۱۱.۶ و -۵۳.۴ میلی‌متر در سال بوده است. این تغییرات احتمالاً تحت تأثیر افزایش دما و کاهش بارندگی در فصل گرم است، که با یافته‌های مطالعات پیشین در ایران (Liu et al., 2004) و دیگر مناطق خشک (Tabari and Marofi, 2011) همخوانی دارد.

از طرفی، نتایج مدل ترکیبی Wavelet-RF در شبیه‌سازی تبخیر

شکل ۱۳ و ۱۴ در کنار سایر معیارهای ارزیابی مدل نشان می‌دهند که تجزیه سری زمانی و تلفیق آن با جنگل تصادفی می‌تواند عملکرد قابل قبولی در شبیه‌سازی مقادیر تبخیر از تشت ارائه کند. نتایج بررسی مدل تلفیقی با تئوری موجک نشان داد که تجزیه مبتنی بر توابع موجک به طور قابل توجهی می‌تواند سیگنال‌های مختلف یک رویداد هواشناسی را شبیه‌سازی کرده و این موضوع سبب بهبود نتایج و افزایش قطعیت مدل می‌شود که این نتیجه با یافته‌های احمدی و مداح (۲۰۲۱) نیز مطابقت دارد.

### نتیجه‌گیری

نتایج این مطالعه نشان داد که روند تغییرات تبخیر از تشت در

- Iran. Meteorological Applications. 25(2): 314-321.
- Allen, R. G., Pereira, L. S., Raes, D. and Smith, M. 1998. Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. Fao, Rome. 300(9): D05109.
- Alsumaiei, A. A. 2024. Modeling high pan evaporation losses using support vector machine, gaussian processes, and regression tree models. Journal of Hydrologic Engineering. 29(5): 04024029.
- Bajirao, T. S., Kumar, P., Kumar, M., Elbeltagi, A. and Kuriqi, A. 2021. Potential of hybrid wavelet-coupled data-driven-based algorithms for daily runoff prediction in complex river basins. Theoretical and Applied Climatology. 145(3): 1207-1231.
- Benchaiba, L., Moussouni, A., Zeghmar, A. and Maaliou, A. 2025. Wavelet and AI-based reservoir evaporation modeling for optimized water management: A case study of Koudiat Acerdoun Dam. Theoretical and Applied Climatology. 156(4): 1-28.
- Breiman, L. 2001. Random Forests. Machine Learning 45(1): 5-32.
- Darbandi, S. and Pourhosseini, F. A. 2018. River flow simulation using a multilayer perceptron-firefly algorithm model. Applied Water Science. 8(3): 1-9.
- Daubechies, I. 1990. The wavelet transform, time-frequency localization and signal analysis. IEEE Transactions on Information Theory. 36(5): 961-1005.
- Dingman, S. L. 2015. Physical hydrology. Waveland press.
- Dinpashoh, Y., Jhajharia, D., Fakheri-Fard, A., Singh, V. P. and Kahya, E. 2011. Trends in reference crop evapotranspiration over Iran. Journal of Hydrology. 399(3-4): 422-433.
- Ekmekcioğlu, Ö., Başakın, E. E. and Özger, M. 2022. Tree-based nonlinear ensemble technique to predict energy dissipation in stepped spillways. European Journal of Environmental and Civil Engineering. 26(8): 3547-3565.
- Friedman, J., Hastie, T. and Tibshirani, R. 2001. The elements of statistical learning (Vol. 1, No. 10). New York: Springer series in statistics.
- Goyal, M., Bharti, Birendra., Quilty, John M., Adamowski, J. and Pandey, A.. 2014. Modeling of daily pan evaporation in sub tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS. Expert Syst. Appl. 41: 5267-5276. <http://doi.org/10.1016/j.eswa.2014.02.047>
- Hamed, K. H. and Rao, A. R. 1998. A modified Mann-Kendall trend test for autocorrelated data. Journal of hydrology. 204(1-4): 182-196.
- Hassanjabbar, A., Nezaratian, H. and Wu, P. 2022. Climate change impacts on the flow regime and water quality indicators using an artificial neural network (ANN): a case study in Saskatchewan, Canada. Journal of Water and Climate Change. 13(8): 3046-3060.
- IPCC. 2021. Climate change 2021: The physical science
- از تشت عملکرد بسیار خوبی داشت. در فاز آموزش، RMSE بین ۱/۰۵ (الشت) تا ۱.۵۶ (پلدختر) میلی‌متر در روز متغیر بود و ضریب NSE در تمام ایستگاه‌ها بالای ۰/۹۱ (با بیشینه ۰/۹۵ در نورآباد) نشان‌دهنده دقت بالای مدل بود. در فاز آزمایش، اگرچه خطاها افزایش یافتند (RMSE بین ۱/۸۶ تا ۲/۹۱ میلی‌متر)، اما مقادیر NSE بیش از ۰/۷۷ و WI بیش از ۰/۹۲ حاکی از قابلیت اطمینان مدل در شرایط واقعی هستند. به‌ویژه، مدل در ایستگاه‌های دورود (NSE=۰/۸۴) و الیگودرز (NSE=۰/۸۳) بهترین عملکرد را داشت، در حالی که پلدختر (NSE=۰/۷۷) به دلیل پیچیدگی شرایط اقلیمی، بیشترین خطا را نشان داد.
- به‌طور کلی نتایج نشان داد که عملکرد مدل با ترکیب تبدیل موجک (برای استخراج ویژگی‌های زمانی-فرکانسی) و جنگل تصادفی (برای مدل‌سازی غیرخطی) با دقت بالای ۹۰٪ در شناسایی نوسانات فصلی، یک روش بهینه برای پیش‌بینی تبخیر از تشت در منطقه مورد مطالعه است. با توجه به کاهش تبخیر در برخی ایستگاه‌ها (به‌ویژه در مناطق کوهستانی)، برنامه‌ریزی برای مدیریت منابع آب باید این روندها را در نظر بگیرد. همچنین، مدل Wavelet-RF می‌تواند به‌عنوان ابزاری دقیق در پیش‌بینی تبخیر برای کشاورزی و مدیریت مخازن آب مورد استفاده قرار گیرد. این نتایج نه‌تنها درک بهتری از تغییرپذیری تبخیر تحت تأثیر تغییرات اقلیمی ارائه می‌دهد، بلکه نشان می‌دهد که ادغام روش‌های هوشمند محاسباتی با تحلیل‌های آماری می‌تواند راه‌حلی مؤثر برای مدل‌سازی پدیده‌های هیدرولوژیکی باشد. همچنین با توجه به کارایی مناسب مدل ترکیبی Wavelet-RF پیشنهاد می‌شود که این روش در سایر مطالعات هیدرولوژیکی نیز به کار گرفته شود.

## تعارض منافع

هیچگونه تعارض منافع توسط نویسندگان وجود ندارد.

## منابع

- Ahmadi, F. and Maddah, M. A. 2021. Development of Wavelet-Kstar Algorithm Hybrid Model for the Monthly Precipitation Prediction (Case Study: Synoptic Station of Ahvaz). Iranian Journal of Soil and Water Research. 52(2): 409-420.
- Ahmadi, F., Nazeri Tahroudi, M., Mirabbasi, R. and Kumar, R. 2022. Spatiotemporal analysis of precipitation and temperature concentration using PCI and TCI: a case study of Khuzestan Province, Iran. Theoretical and Applied Climatology: 1-18.
- Ahmadi, F., Nazeri Tahroudi, M., Mirabbasi, R., Khalili, K. and Jhajharia, D. 2018. Spatiotemporal trend and abrupt change analysis of temperature in

- Mirzaee, N. and Sarraf, A. 2022. Application of data fusion models in river flow simulation using signals of large-scale climate, case study: Jiroft Dam Basin. *Watershed Engineering and Management*. 13(4): 672-689.
- Mohanty, S., Jha, M., Kumar, Ashwani. and Sudheer, K. 2010. Artificial Neural Network Modeling for Groundwater Level Forecasting in a River Island of Eastern India. *Water Resources Management*. 24: 1845-1865 . <http://doi.org/10.1007/S11269-009-9527-X>
- Nash, J. E. and Sutcliffe, J. V. 1970. River flow forecasting through conceptual models part I—A discussion of principles. *Journal of Hydrology*. 10(3): 282-290.
- Nazeri Tahroudi, M. 2025. Comprehensive global assessment of precipitation trend and pattern variability considering their distribution dynamics. *Scientific Reports*. 15(1): 22458.
- Nazeri Tahroudi, M. and Mirabbasi, R. 2023. Frequency decomposition associated with machine learning algorithms and copula modeling for river flow prediction. *Stochastic Environmental Research and Risk Assessment*. 37(8): 2897-2918.
- Nazeri Tahroudi, M., Khashei Siuki, A. and Ramezani, Y. 2019. Redesigning and monitoring groundwater quality and quantity networks by using the entropy theory. *Environmental monitoring and assessment*. 191:1-17.
- Nilsson, P., Uvo, C. B. and Berndtsson, R. 2006. Monthly runoff simulation: Comparing and combining conceptual and neural network models. *Journal of Hydrology*. 321(1-4): 344-363.
- Noori, N., Kalin, L. and Isik, S. 2020. Water quality prediction using SWAT-ANN coupled approach. *Journal of Hydrology*. 590: 125220.
- Nourani, V., Baghanam, A. H., Adamowski, J. and Kisi, O. 2014. Applications of hybrid wavelet-artificial intelligence models in hydrology: a review. *Journal of Hydrology*. 514: 358-377.
- Patil, A. P. and Deka, P. C. 2017. Performance evaluation of hybrid Wavelet-ANN and Wavelet-ANFIS models for estimating evapotranspiration in arid regions of India. *Neural Computing and Applications*. 28: 275-285.
- Qasem, S. N., Samadianfard, S., Kheshtgar, S., Jarhan, S., Kisi, O., Shamshirband, S. and Chau, K. W. 2019. Modeling monthly pan evaporation using wavelet support vector regression and wavelet artificial neural networks in arid and humid climates. *Engineering Applications of Computational Fluid Mechanics*. 13(1): 177-187.
- Raji, M., Tahroudi, M. N., Ye, F. and Dutta, J. 2022. Prediction of heterogeneous Fenton process in treatment of melanoidin-containing wastewater using data-based models. *Journal of Environmental Management* 307: 114518.
- Ramezani, Y., Tahroudi, M. N. and Ahmadi, F. 2019. Analyzing the droughts in Iran and its eastern basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press.
- Jain, S. K., Das, A. and Srivastava, D. K. 1999. Application of ANN for reservoir inflow prediction and operation. *Journal of Water Resources Planning and Management*. 125(5): 263-271.
- Kalhari, M., Ashofteh, P. S., Moghadam, S. H. and Singh, V. P. 2022. Investigating the effect of uncertainty of AOGCM-TAR and AOGCM-AR5 climate change models on river runoff. *Arabian Journal of Geosciences*. 15(13): 1-16.
- Kendall, M. G. 1963. The advanced theory of statistics: in 3 volumes. C. Griffin.
- Khalili, K., Tahoudi, M. N., Mirabbasi, R. and Ahmadi, F. 2016. Investigation of spatial and temporal variability of precipitation in Iran over the last half century. *Stochastic environmental research and risk assessment*. 30: 1205-1221.
- Khozeymehnezhad, H. and Nazeri Tahroudi, M. 2019. Annual and seasonal distribution pattern of rainfall in Iran and neighboring regions. *Arabian Journal of Geosciences*. 12: 1-11.
- Khozeymehnezhad, H. and Tahroudi, M. N. 2019. Annual and seasonal distribution pattern of rainfall in Iran and neighboring regions. *Arabian Journal of Geosciences*. 12(8):271.
- Kisi, O. and Kerem Cigizoglu, H. 2007. Comparison of different ANN techniques in river flow prediction. *Civil Engineering and Environmental Systems*. 24(3): 211-231.
- Kumar, S., Merwade, V., Kam, J. and Thurner, K. 2009. Streamflow trends in Indiana: effects of long term persistence, precipitation and subsurface drains. *Journal of Hydrology*. 374(1-2): 171-183.
- Liu, B., Xu, M., Henderson, M. and Gong, W. 2004. A spatial analysis of pan evaporation trends in China, 1955–2000. *Journal of Geophysical Research: Atmospheres*. 109(D15).
- Mallat, S. 1999. A wavelet tour of signal processing. Elsevier. Academic Press.
- Mallat, S. G. 1989. Multiresolution approximations and wavelet orthonormal bases of  $L^2(R)$ . *Transactions of the American Mathematical Society*. 315(1): 69-87.
- Mann, H. B. 1945. Nonparametric tests against trend. *Econometrica: Journal of the econometric society*. 245-259.
- McMahon, T. A., Peel, M. C., Lowe, L., Srikanthan, R. and McVicar, T. R. 2013. Estimating actual, potential, reference crop and pan evaporation using standard meteorological data: a pragmatic synthesis. *Hydrology and Earth System Sciences*. 17(4): 1331-1363.
- Meresa, H. 2019. Modelling of river flow in ungauged catchment using remote sensing data: application of the empirical (SCS-CN), artificial neural network (ANN) and hydrological model (HEC-HMS). *Modeling Earth Systems and Environment*. 5(1): 257-273.

- Soroush, F., Fathian, F., Khabisi, F. S. H. and Kahya, E. 2020. Trends in pan evaporation and climate variables in Iran. *Theoretical and Applied Climatology*. 142: 407-432.
- Tabari, H. and Marofi, S. 2011. Changes of pan evaporation in the west of Iran. *Water Resources Management*. 25: 97-111.
- Tabari, H. and Talaee, P. H. 2014. Sensitivity of evapotranspiration to climatic change in different climates. *Global and Planetary Change*. 115: 16-23.
- Tahroudi, M. N., Khalili, K., Ahmadi, F., Mirabbasi, R. and Jhahharia, D. 2019. Development and application of a new index for analyzing temperature concentration for Iran's climate. *International Journal of Environmental Science and Technology*. 16(6): 2693-2706.
- Wu, Cl., Chau, K. W. and Li, Y. S. 2009. Methods to improve neural network performance in daily flows prediction. *Journal of Hydrology*. 372(1-4): 80-93.
- Yu, Ruiyun., Yang, Yu., Yang, Leyou., Han, Guangjie. and Move, Oguti Ann. 2016. RAQ-A Random Forest Approach for Predicting Air Quality in Urban Sensing Systems. *Sensors (Basel, Switzerland)*. 16 . <http://doi.org/10.3390/s16010086>
- Zakhrouf, M., Bouchelkia, H., Stamboul, M., Kim, S. and Heddami, S. 2018. Time series forecasting of river flow using an integrated approach of wavelet multi-resolution analysis and evolutionary data-driven models. A case study: Sebaou River (Algeria). *Physical Geography*. 39(6): 506-522.
- Zamani, R., Mirabbasi, R., Nazeri, M., Meshram, S. G. and Ahmadi, F. 2018. Spatio-temporal analysis of daily, seasonal and annual precipitation concentration in Jharkhand state, India. *Stochastic Environmental Research and Risk Assessment*. 32(4): 1085-1097.
- neighboring countries using copula functions. *Idojaras*. 123(4): 435-453.
- Roderick, M. L. and Farquhar, G. D. 2002. The cause of decreased pan evaporation over the past 50 years. *science*, 298(5597). 1410-1411.
- Seifi, A. and Riahi-Madvar, H. 2019. Improving one-dimensional pollution dispersion modeling in rivers using ANFIS and ANN-based GA optimized models. *Environmental Science and Pollution Research*. 26(1): 867-885.
- Sevgen, E., Kocaman, S., Nefeslioglu, H. A. and Gokceoglu, C. 2019. A Novel Performance Assessment Approach Using Photogrammetric Techniques for Landslide Susceptibility Mapping with Logistic Regression, ANN and Random Forest. *Sensors (Basel, Switzerland)*. 19 . <http://doi.org/10.3390/s19183940>
- Shahidi, A., Ramezani, Y., Nazeri-Tahroudi, M. and Mohammadi, S. 2020. Application of vector autoregressive models to estimate pan evaporation values at the Salt Lake Basin, Iran. *Időjárás*. 124(4).
- Singh, V. P., Singh, R., Paul, P. K., Bisht, D. S. and Gaur, S. 2024. Hydrological Processes Modelling and Data Analysis. *Water Science and Technology Library*, 127.
- Sivakumar, B., Jayawardena, A. W. and Fernando, T. M. K. G. 2002. River flow forecasting: use of phase-space reconstruction and artificial neural networks approaches. *Journal of Hydrology*. 265(1-4): 225-245.
- Solgi, A., Pourhaghi, A., Bahmani, R. and Zarei, H. 2017. Pre-processing data using wavelet transform and PCA based on support vector regression and gene expression programming for river flow simulation. *Journal of Earth System Science*. 126(5): 1-17.

## Investigating the Effect of Time Series Decomposition on Simulation of Daily Evaporation Based on Random Forest

V. Pourghasem<sup>1</sup>, K. Khalili<sup>2\*</sup>, H. Rezaie<sup>3</sup>, M. Nazeri Tahroudi<sup>4</sup>

Received: Sep.11, 2025

Accepted: Oct.14, 2025

### Abstract

Given the importance of pan evaporation in agriculture and water resources across different climates, and considering the climatic changes in recent years, this study investigates the variations in pan evaporation and simulates it using frequency decomposition at evaporation stations located in Lorestan Province, western Iran. The results of examining the changes in pan evaporation values in the study area showed that during the cold months of the year (October to February), most stations experienced a significant decreasing trend in pan evaporation, whereas in warmer months such as March and April, an increasing trend was predominant. A hybrid Wavelet-Random Forest model was used to simulate the pan evaporation values. The evaluation results of this model using RMSE, NSE, WI, and correlation coefficient criteria indicated that this method has high accuracy in both training and testing phases. Specifically, the model was able to effectively identify seasonal and sudden changes in evaporation. Although a higher relative error was observed at some stations, such as Poldokhtar, compared to other stations, on average (across the 8 studied stations), an error rate of 2.23 mm/day, a Nash-Sutcliffe coefficient of over 0.8, and a Willmott index of over 94% were achieved in this study. Considering the 95% confidence intervals of the simulation and the provided violin plot, the performance of the hybrid model was assessed as acceptable. The overall results indicate that the combination of Wavelet transform and the Random Forest algorithm can be used as an effective tool for predicting pan evaporation.

**Keywords:** Component decomposition, Lorestan, Pan Evaporation, Residual series

1- M.Sc. Student, Department of Water Engineering, Urmia University, Urmia, Iran

2- Associate Professor, Urmia Lake Research Institute, Urmia University, Urmia, Iran

3- Professor, Department of Water Engineering, Urmia University, Urmia, Iran

4- Assistant Professor, Department of Water Engineering, Lorestan University, Khorramabad, Iran

(\*- Corresponding Author Email: k.khalili@urmia.ac.ir)