

مقاله علمی-پژوهشی

پیش‌بینی دبی رودخانه با استفاده از روش ترکیبی حافظه طولانی- کوتاه‌مدت، تبديل موجک و تجزیه مدل تجربی در اقلیم نیمه‌خشک و مرطوب

کیومرث روشنگر^{۱*}، صادق عبدالزاده^۲

تاریخ دریافت: ۱۴۰۱/۱۱/۰۳ تاریخ پذیرش: ۱۴۰۲/۰۳/۰۶

چکیده:

کشور ایران با اقلیمی خشک و نیمه‌خشک باسیل‌های مخرب، خشک‌سالی و کم‌آبی روبرو است. خشک‌سالی و سیلاب‌ها می‌تواند محیط‌زیست، فعالیت‌های اقتصادی و اجتماعی را تحت تأثیر قرار دهد. بنابراین بررسی و پیش‌بینی دبی رودخانه‌ها و برنامه‌ریزی مدیریتی به منظور کنترل آن مخصوص مصرف آب در آینده بسیار ارزشمند است. در این پژوهش، تغییرات دبی رودخانه با استفاده از داده‌های آماری از سال ۲۰۰۱ تا ۲۰۲۰ مدل‌سازی شد. داده‌های آماری مربوط به ایستگاه‌های سینوپیک و هیدرومتر یک منطقه نیمه‌خشک در استان آذربایجان غربی شهرستان ارومیه و مرطوب در استان مازندران شهرستان آمل استفاده شد. از دوازده مدل زمانی تعریف شده برای شبکه LSTM (long short-term memory) یا به اختصار LSTM بهترین مدل مشخص شد. سپس مدل‌سازی LSTM بر پایه روش‌های پیش‌پردازندۀ تبدیل موجک گسسته (Discrete Wavelet Transform) به اختصار DWT و تجزیه مدل تجربی کامل (Complementary Ensemble Empirical Mode Decomposition CEEMD) انجام شد. نتایج حاصل نشان داد که مدل منتخب قابلیت و کارایی بالایی در تخمین میزان دبی رودخانه را دارد. از طرفی دیگر روش‌های پیش‌پردازندۀ باعث بهبود نتایج شدند. به طوری که در تبدیل موجک معیار ارزیابی DC مدل برتر در رودخانه نازلو از ۰/۹۳ به ۰/۹۵ و در رودخانه چالوس از ۰/۸۳ به ۰/۹۰ افزایش یافت. بهترین حالت ارزیابی برای داده‌های آزمون با استفاده از تبدیل موجک برای رودخانه نازلو در اقلیم نیمه‌خشک با معیارهای ارزیابی R=۰/۹۷۷ و RMSE=۰/۰۱۸ به دست آمد. همچنین با توجه به نتایج آنالیز حساسیت مشخص شد پارامتر دبی یک روز قبل، تأثیرگذارترین پارامتر در تخمین دبی روزانه است.

واژه‌های کلیدی: تبدیل موجک، تجزیه مدل تجربی، شبکه‌های عصبی مصنوعی، یادگیری عمیق، مدل‌سازی

برخوردار است. از طرفی باید اشاره نمود که رواناب رودخانه یک پدیده غیرخطی است و دارای تغییرات زمانی و مکانی گسترهای است، درنتیجه مدل‌سازی آن به سادگی امکان‌پذیر نیست (بهمنش و همکاران، ۱۳۹۳). در این راستا روش‌های هوش مصنوعی (AI) به طور گسترهای در مدل‌سازی و تخمین سری‌های زمانی غیرخطی در این نوع فرآیندها مورد استفاده قرار گرفته است (سیاری و همکاران، ۱۳۹۰؛ آذری و همکاران، ۱۳۹۲). در سال‌های اخیر هوش مصنوعی توانایی فراوانی در پیش‌بینی سری‌های زمانی هیدرولوژیکی از خود نشان داده‌اند. این روش‌ها چون بیشتر داده محور هستند، نیاز به دانش اولیه راجع به پدیده موردمطالعه ندارند و در حال حاضر هوش

مقدمه

یکی از نیازهای عمدۀ در طراحی پروژه‌های آبی و خاکی، مقدار دبی رودخانه‌ها است که جهت برآورد آن از روش‌های مختلف استفاده می‌شود. با توجه به بروز سیلاب‌های گوناگون و خطرهای ناشی از رخداد آن که جامعه انسانی و سازه‌های سر راه خود را تهدید می‌کند بنابراین بررسی و اطلاع از جریان رودخانه‌ها از اهمیت زیادی

۱- استاد گروه مهندسی آب، دانشکده عمران، دانشگاه تبریز، تبریز، ایران
۲- دانشجوی دکتری آب و سازه‌های هیدرولوژیکی، دانشکده عمران، دانشگاه تبریز، تبریز، ایران

(*) - نویسنده مسئول : ایمیل: kroshangar@yahoo.com
DOI: 20.1001.1.20087942.1402.17.4.8.8

تجزیه مد تجربی(EMD^۱) روشی کاملاً مؤثر استخراج سیگنال از داده‌ها است و برای تجزیه سیگنال در حوزه زمان-فرکانس کاربرد دارند. هوانگ و همکاران، برای پیش‌بینی جریان رودخانه سین در فرانسه از روش تجزیه مد تجربی استفاده کردند و سری زمانی دی را (Huang et al., 2009) به زیر سری‌های توابع مد ذاتی و باقیمانده تجزیه نمودند (GRNN^۲) مقایسه کردند و به این نتیجه رسیدند که روش ELM از عملکرد بهتری نسبت به دو روش دیگر برخوردار است (Yaseen et al., 2016). بابایی مقدم و همکاران (۱۳۹۵) میزان تغییرات دی در رودخانه شاهروд و قزل‌اوزن را مورد بررسی قراردادند. برای رسیدن به این هدف از چهار آزمون تحلیل روند شامل سن، من‌کنال، رگرسیون خطی و اسپیرمن استفاده شد. نتایج بدست آمده از همه آزمون‌ها در دوره‌های فصلی و سالانه مشابه بود. نتایج همه آزمون‌ها کاهش معنادار دی رودخانه‌های قزل‌اوزن و شاهرود را نشان داد. لیما و همکاران، به پیش‌بینی دی روزانه دو رودخانه در کانادا با استفاده از روش ELM پرداختند که نتایج آن‌ها نشان از توانایی این روش در پیش‌بینی جریان داشت (Lima et al., 2016). تائورمینا و همکاران، به انتخاب متغیرهای ورودی جهت پیش‌بینی دی روزانه با استفاده از الگوریتم ذرات بهینه پرداختند و با استفاده از روش ELM مدل‌سازی پارش-رواناب رودخانه کنتاکی را بررسی کردند. نتایج نشان دهنده زمان اجرای کمتر و دقت بالا در مدل‌سازی بود (Taormina et al., 2015).

میرزا نیا و همکاران (۱۴۰۰) در پژوهشی نشان دادند که موجک باعث بهبود نتایج و پیش‌بینی در مدل‌سازی بارش-رواناب شده است. کیشی و کوبنر، با بررسی داده‌های سه ایستگاه رودخانه غزل ایرماق ترکیه و به کارگیری شبکه عصبی چندلایه پرسپترون، الگوریتم نیوتون و روش RBF^۳ نشان دادند که روش شبکه عصبی بهتر از روش رگرسیون بوده و می‌تواند به عنوان روشی مناسب برای پیش‌بینی دی-اصل به کاربرده شود (Kisi and Çobaner, 2009).

بهزادی و همکاران، در مطالعه‌ای، توسعه عملکرد روش‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی را برای پیش‌بینی یک روز جلوتر رواناب موردنظری قراردادند و نتایج نشان داد که روش ماشین بردار پشتیبان از روش شبکه عصبی مصنوعی سریع‌تر و دقیق‌تر از خود نشان داده است (Behzad et al., 2009).

مطالعات انجام شده نشان دادند که ترکیب تبدیل موجک و ماشین بردار پشتیبان در پیش‌بینی دی جریان ماهانه به نتایج با دقت بالاتری (Kisi and Shiri, 2011) نسبت به ماشین بردار پشتیبان منجر می‌شود.

در پژوهشی به منظور تخمین جریان چند رودخانه غیردانئمی واقع در حوضه‌های آبریز نیمه‌خشک کشور قبرس، نتایج نشان داد که روش تلفیقی شبکه عصبی و آنالیز موجک یک روش مؤثر در تخمین (Adamowski and Sun, 2010). کیشی و سیمت، توانایی ترکیب موجک با روش برنامه‌ریزی ژنتیک را در مقایسه با مدل برنامه‌ریزی ژنتیکی به اثبات رساندند (Kisi and Cimen, 2011).

برنامه‌نویسی ژنتیکی خطی(LGP^۴) و مدل ترکیبی موجک شبکه عصبی مصنوعی را برای پیش‌بینی جریان ماهانه دو ایستگاه پی‌درپی موردمطالعه قراردادند و به این نتیجه رسیدند که بر اساس مدل مرجع و مجموعه داده‌های ورودی و خروجی، روش صریح LGP با عملگرهای محاسباتی هم نتایج بهتری نسبت به مدل WANN از خود نشان داده است (Danandeh Mehr et al., 2013).

- 6- Ensemble Empirical Mode Decomposition
 7- Radial Basis Function
 8- Linear Genetic Programming

مصنوعی ابزاری کارآمد برای مدل‌سازی بر روی انبوهی از داده‌های دینامیکی و غیرخطی می‌باشد.

یاسین و همکاران، دی ماهانه رودخانه دجله را با استفاده از روش یادگیری قدرتمند (ELM^۵) پیش‌بینی کردند و نتایج این روش جدید را با رگرسیون بردار پشتیبان(SVR^۶) و شبکه عصبی عمومی (GRNN^۷) مقایسه کردند و به این نتیجه رسیدند که روش ELM از عملکرد بهتری نسبت به دو روش دیگر برخوردار است (Yaseen et al., 2016). میزان تغییرات دی در رودخانه شاهرود و قزل‌اوزن را مورد بررسی قراردادند. برای رسیدن به این هدف از چهار آزمون تحلیل روند شامل سن، من‌کنال، رگرسیون خطی و اسپیرمن استفاده شد. نتایج بدست آمده از همه آزمون‌ها در دوره‌های فصلی و سالانه مشابه بود. نتایج همه آزمون‌ها کاهش معنادار دی رودخانه‌های قزل‌اوزن و شاهرود را نشان داد. لیما و همکاران، به پیش‌بینی دی روزانه دو رودخانه در کانادا با استفاده از روش ELM پرداختند که نتایج آن‌ها نشان از توانایی این روش در پیش‌بینی جریان داشت (Lima et al., 2016).

به انتخاب متغیرهای ورودی جهت پیش‌بینی دی روزانه با استفاده از الگوریتم ذرات بهینه پرداختند و با استفاده از روش ELM مدل‌سازی پارش-رواناب رودخانه کنتاکی را بررسی کردند. نتایج نشان دهنده زمان اجرای کمتر و دقت بالا در مدل‌سازی بود (Taormina et al., 2015).

ژو و همکاران، از مدل رگرسیون فرآیند گاووسی برای تخمین چند ماه بعد دی رودخانه استفاده کردند و نتیجه گرفتند که روش GPR^۸ با داشتن کمترین میزان خطأ و بیشترین همیستگی عملکرد مناسبی دارد (Zhu et al., 2019).

روش مبتنی بر کرنل رگرسیون بردار پشتیبان (GPR) استفاده کردند (Choy and Chan, 2003). با وجود توانایی بالای روش‌های هوشمند در تخمین پدیده‌های هیدرولوژیکی نظری دی جریان، برخی اوقات این روش‌ها منجر به نتیجه دلخواه و مناسب نمی‌شوند و نیاز به افزایش دقت این مدل‌ها است. وجود ویژگی‌هایی نظری نویز، غیرخطی و غیرایستا بودن در بسیاری از پدیده‌های هیدرولوژیکی، به خصوص برآورد دی جریان، موجب پیچیدگی بیشتر این پدیده‌ها گشته و از طرف دیگر با توجه به داده گرا بودن این مدل‌ها، کیفیت و ویژگی خود این داده‌ها نیز از اهمیت بالایی برخوردار هستند (Danandeh Mehr et al., 2017).

از این‌رو پژوهشگران در سال‌های اخیر، از روش‌های پیش‌پردازش زمانی استفاده کردند. روش تبدیل موجک(DWT^۹) و

- 1- Extreme Learning Machine
 2- Support Vector Regression
 3- General Regression Neural Network
 4- Gaussian Process Regression
 5- Discrete Wavelet Transform

سال‌های قبل خیلی دشوار هست. با توجه به مطالعات صورت گرفته در این زمینه بارش و دما بیشترین تأثیر را بر مقدار جریان رودخانه‌ها، رواناب، خشک‌سالی و سیلاب دارد. (سیاری و همکاران، ۱۳۹۰؛ آذری و همکاران، ۱۳۹۲). لذا از اطلاعات موجود دو ایستگاه جهت مقایسه، پارامترهای موردنظر انتخاب گردید. از حافظه طولانی-کوتاه مدت برای مدل‌سازی دبی جریان رودخانه در دو منطقه استفاده شد. دو نوع دیگر مدل‌سازی هم بدون پیش‌پردازش داده‌ها و هم پس از تجزیه داده‌های سری زمانی با استفاده از تبدیل موجک و تجزیه مد تجزیه انجام شد. و نتایج باهم مقایسه گردید. منطقه موردمطالعه و همچنین مشخصات ایستگاه‌ها و پارامترهای اندازه‌گیری شده در شکل ۱ و جدول ۱ آورده شده است.

تبدیل موجک (DWT): تبدیل موجک ابزاری مؤثر برای استخراج اطلاعات داده با تجزیه سیگنال اصلی به حوزه‌های فرکانس پایین و فرکانس بالا است (Yadav and Eliza., 2017). موجک Wavelet (یکسری از توابع ریاضی است که جهت تجزیه سیگنال پیوسته به مؤلفه‌های فرکانسی آن به کار می‌رود که سطح تفکیک هر مخلفه برابر با مقیاس آن است. موجک‌ها (که به عنوان موجک مادر شناخته می‌شوند) نمونه‌های انتقال‌یافته و مقیاس شده یک تابع (موجک مادر) با طول متأهی و نوسانی شدیداً میرا هستند. تابع موجک تابعی است که دو ویژگی مهم نوسانی بودن و کوتاه‌مدت بودن را دارد (Roushangar and Ghasempour., 2020).

(x) تابعی موجک است اگر و فقط اگر تبدیل فوریه آن ($\Psi(\omega)$) شرط زیر را ارضاء کند (Lau and Weng., 1995) :

$$\int_{-\infty}^{+\infty} \frac{|\Psi(\omega)|}{|\omega|^2} d\omega < +\infty \quad (1)$$

این شرط با عنوان شرط پذیرفتگی برای موجک (x) Ψ شناخته می‌شود. (x) Ψ تابع موجک مادر است. (رابطه ۲) که ضرایب a و b در آن نقش انتقال و مقیاس سیگنال موردنظر را دارند (Lau and Weng., 1995).

$$\varphi_{a,b}(x) = \frac{1}{\sqrt{a}} \Psi\left(\frac{x-b}{a}\right) \quad (2)$$

تابع موجک دارای انواع بسیاری هستند که مهم‌ترین و پرکاربردترین آن‌ها شامل هار، مولت، کلاه مکزیکی، سیملت، گوسین است. تبدیل موجک پیوسته به عنوان روش جایگزین تبدیل فوریه زمان-کوتاه ارائه گردید و هدف آن، فائق آمدن بر مشکلات مربوط به تفکیک پذیری در تبدیل فوریه زمان-کوتاه است. در عمل اکثر سری‌های زمانی هیدرولوژیکی به صورت گستته در زمان‌هایی مشخص اندازه‌گیری می‌شوند. بنابراین کاربرد موجک گستته می‌تواند تناسب بهتری با این نوع سری زمانی داشته باشد. تبدیل موجک گستته در عمل همان تبدیل موجک پیوسته است (نسخه گستته

همکاران، ابتدا با استفاده از آزمون ناپارامتریک من-کندا، روند سری‌های زمانی تغییرات سالیانه رسوب از خروجی ۷ ایستگاه اصلی حوضه در هند را تحلیل کردند. سپس روندهای غیرخطی در این سری‌ها را با استفاده از تجزیه مد تجزیه (EMD) استخراج کردند. نتایج مطالعه تحلیل روند، کاهش تغییرات رسوب در ۵ حوضه از ۷ حوضه در هند را علی‌رغم افزایش میزان بارش‌ها در سه حوضه از آن-ها نشان داد (Adarsh et al., 2016). همچنین در مطالعه‌ای نشان دادند مدل ترکیبی موجک-شبکه عصبی مصنوعی در سری‌های زمانی هیدرولوژیکی دارای دقت بالاتری نسبت به مدل ساده شبکه عصبی مصنوعی است (Alizadeh et al., 2017).

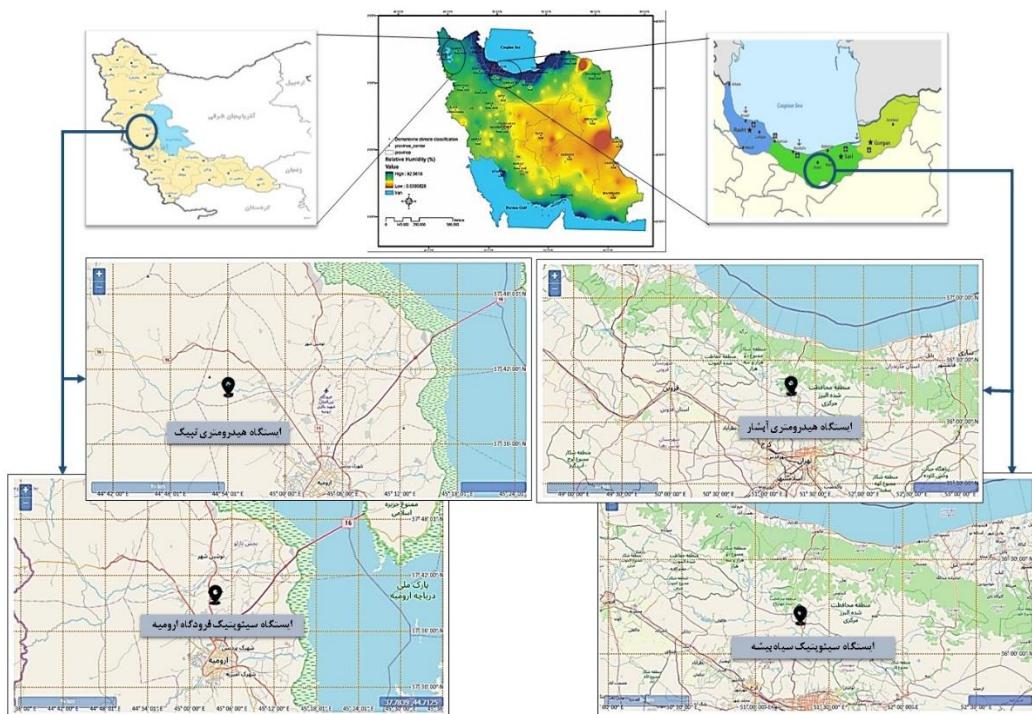
هدف اصلی این مطالعه، مدل‌سازی و پیش‌بینی دبی رودخانه با استفاده از روش ترکیبی DWT، LSTM و CEEMD در دو اقلیم نیمه‌خشک و مرطوب است. به منظور دستیابی به این اهداف از داده‌های اقلیمی حداکثر و حداقل دما، بارش و ساعت‌آفتابی و دبی جریان رودخانه استفاده شده است. جهت بررسی کارایی روش‌های به کاررفته دو نوع مدل‌سازی هم بدون پیش‌پردازش داده‌ها و هم پس از تجزیه داده‌های سری زمانی موردنظری قرارگرفته است. با توجه به تغییرات احتمالی مختلف افزایش یا کاهش دبی رودخانه‌ها تحت تأثیر تغییرات اقلیمی، ارزیابی تغییرات اقلیمی و اثرات جانبی احتمالی آن بر فرآیندهای هیدرولوژیکی در مناطق مختلف کمک بسیار مهمی به برنامه‌ریزان و مدیران منابع آب برای مقابله با این چالش‌ها در آینده است.

مواد و روش‌ها

موقعیت و ویژگی‌های منطقه موردمطالعه: منطقه موردمطالعه در این پژوهش شامل دو منطقه با دو اقلیم مرطوب و نیمه‌خشک در کشور ایران است که بر اساس نقشه پهنه‌بندی بوم‌اقلیم شناسی کشور تعیین شد (شنی‌زند و همکاران، ۱۳۹۳). منطقه یک در استان آذربایجان غربی (شهرستان ارومیه) در اقلیم نیمه‌خشک و منطقه دو در استان مازندران (شهرستان آمل) در اقلیم مرطوب قرارگرفته است. داده‌های مورداستفاده جهت پیش‌بینی جریان رودخانه در هر منطقه از نوع ایستگاه هیدرومتر یک که شامل پارامتر دمی جریان است و ایستگاه سینوپتیک که شامل پارامترهای دمای حداکثر و حداقل، بارش و تابش خورشیدی است، استفاده شده است. داده‌های اندازه‌گیری شده مربوط به ۲۰۱۱ تا ۲۰۲۰ است. در این پژوهش علاوه بر پارامترهای یادشده می‌توان از سایر پارامترهایی نظیر رطوبت، دمای تر، دمای نقطه شبنم، نم نسبی و میزان ابرناکی و غیره نیز همزمان استفاده نمود ولی به علت عدم اندازه‌گیری این نوع پارامترها در ایستگاه‌های موردنظر و در صورت وجود این پارامترها کمیت و کیفیت پایین داشته و امکان دسترسی به آن‌ها برای

زمانی کمتر دارا است.

شده آن) که در آن یکسری موجک از تبدیل موجک پیوسته نمونه گرفته است و سامانه های کامپیوتری قابلیت محاسبه آن را با هزینه



شکل ۱ - موقعیت منطقه مورد مطالعه

جدول ۱ - مشخصات ایستگاهها و پارامترهای اقلیمی به صورت روزانه برای دوره آماری ۲۰۰۱ تا ۲۰۲۰

اقلیم	نام ایستگاه	نوع ایستگاه	رودخانه	آبیگاه میانگین	حداکثر	حداقل	واحد	پارامتر	عرض جغرافیایی	طول جغرافیایی	ایستگاه	تپیک
هیدرومتریک	نیمه خشک چای	فرودگاه ارومیه	سینوپتیک	۹/۰۷	۱۳۳	-	m³/s	دبي (Q)	۳۷°۴۱'۰۰"	۴۴°۵۴'۰۰"	آسوان	نیمه خشک چای
نیمه خشک چای	آبشار	آبشار	هیدرومتریک	۱۸/۸۲	۳۹/۹	-۷/۲	°C	دماي حداکثر (Tmax)			آسوان	آبشار
مرطوب چالوس	سیاهبیشه آمل	سیاهبیشه آمل	سینوپتیک	۵/۳۱	۲۳/۷	-۱۸/۲	°C	دماي حداقل (Tmin)	۳۷°۴۰'۱۳"	۴۵°۰'۳۵۹"	آسوان	سینوپتیک
مرطوب چالوس	آبشار	آبشار	هیدرومتریک	۳۰۶/۵۶	۴۴۳/۶۸	۱۶۵/۲۷	(mm)	بارش (P)			آسوان	آبشار
مرطوب چالوس	آبشار	آبشار	هیدرومتریک	۸/۰۹	۱۴/۵	-	j/m²	تابش خورشیدی (S)			آسوان	آبشار
مرطوب چالوس	آبشار	آبشار	هیدرومتریک	۸/۹	۶۰	-۰/۶۳	m³/s	دبي (Q)	۳۶°۱۹'۵۰."	۵۱°۱۸'۲۱"	آسوان	آبشار
مرطوب چالوس	سیاهبیشه آمل	سیاهبیشه آمل	سینوپتیک	۱۵/۵۹	۳۵/۴	-۷/۴	°C	دماي حداکثر (Tmax)			آسوان	سینوپتیک
مرطوب چالوس	سیاهبیشه آمل	سیاهبیشه آمل	سینوپتیک	۶/۴۹	۳۲/۴	-۱۷	°C	دماي حداقل (Tmin)	۳۶°۱۵'۰۰"	۵۱°۱۸'۰۰"	آسوان	سینوپتیک
مرطوب چالوس	سیاهبیشه آمل	سیاهبیشه آمل	سینوپتیک	۶۰۷/۱۹	۸۶۸/۹۸	۴۰۰/۵۹	(mm)	بارش (P)			آسوان	سینوپتیک
مرطوب چالوس	سیاهبیشه آمل	سیاهبیشه آمل	سینوپتیک	۵/۲۸	۱۴/۶	-	j/m²	تابش خورشیدی (S)			آسوان	سینوپتیک

آن نوعی توصیف زمان-مقیاس از سیگنال گسسته با استفاده از فیلترهای دیجیتال ارائه می‌گردد. تبدیل موجک، حاصل شباهت

اصول تبدیل موجک گسسته به روشنی تحت عنوان کدینگ زیر باند بر می‌گردد که در سال ۱۹۷۶ سنگ بنای اولیه آن گذارده شد و در

استفاده از جنبه‌های مشت آماری نویز سفید که توزیع متوازن در حوزه فرکانس دارد، اثر نویز متناوب از روند تجزیه حذف می‌شود. در روش تجزیه مد تجربی یکپارچه کامل (CEEMD^۳) نویز سفید به صورت دوتایی (یکی مشت و دیگری منفی) به داده اصلی اضافه می‌شود تا دو سری IMF مجموع ساخته شود. بنابراین ترکیبی متشکل از داده اصلی و نویز اضافی داریم که مجموع IMF‌ها برابر سیگنال اصلی (Wu and Huang, 2004)

حافظه طولانی - کوتاه‌مدت (LSTM): یادگیری عمیق،

رده‌ای از الگوریتم‌های یادگیری ماشین است که از چندین لایه برای استخراج ویژگی‌های سطح بالا از ورودی خام استفاده می‌کنند (Deng and Yu, 2014) یک شبکه عصبی مکرر (RNN^۴) کلاسی از شبکه‌های عصبی مصنوعی هستند که در آن اتصالات مابین گره‌هایی از یک در امتداد یک دنباله زمانی می‌باشند و سبب می‌شود تا الگوریتم بتواند رفتار پویایی موقعی را به نمایش بگذارد. برخلاف شبکه‌های عصبی رویه‌جلو، شبکه‌های عصبی مکرر می‌توانند از وضعیت درونی خود برای پردازش دنباله ورودی‌ها استفاده کنند (Graves et al., 2008 ; Sak et al., 2014 ; 2008). حافظه طولانی-کوتاه‌مدت یک معماری شبکه عصبی بازگشتی (یک شبکه عصبی مصنوعی) است که در سال ۱۹۹۷ میلادی توسط سپه‌خوارایتر و یورگن اشمیده‌بور ارائه شد و بعداً در سال ۲۰۰۰ میلادی توسط فیلیکس ژرس و دیگران (Gers et al., 2000 ; Hochreiter and Beydouod داده شد (Amirat et al., 2018) (Hochreiter and 1997) یک سلول RNN توالی $X = [x_1, x_2, x_3, \dots, x_n]$ با طول متغیر را به عنوان ورودی دریافت می‌کند و در هر گام زمانی، حالت مخفی ht خود را توسط رابطه ۵ بهروزرسانی می‌کند.

$$\begin{cases} 0 & t = 0 \\ \varphi(h_{t-1}, x_t) & \text{otherwise} \end{cases} \quad (5)$$

که در آن φ تابع غیرخطی مانند تابع سیگموید، xt ورودی شبکه در زمان t ، ht حالت مخفی در زمان $t-1$ ، x_t حالت مخفی در یک واحد تأخیر زمانی است (Chung et al., 2014). عنصر اصلی شبکه LSTM سلول حالت است. شبکه LSTM این توانایی را دارد که اطلاعات جدیدی را به سلول حالت اضافه یا اطلاعات آن را حذف کند. این کار توسط ساختارهایی به نام گیت انجام می‌شود. گیتها مسیر ورودی اطلاعات هستند. آن‌ها از یک لایه شبکه عصبی سیگموید به همراه یک عملگر ضرب نقطه به نقطه تشکیل شده‌اند. خروجی لایه سیگموید عددی بین صفر و یک است که نشان می‌دهد

سنجه (کورولیشن) بین محتوای فرکانسی (مقیاسی) سیگنال و تابع موجک در مقیاس‌های مختلف است (Adamowski et al., 2009). تجزیه کردن سری‌های زمانی با استفاده از فیلترهای مشخص (موجک و توابع مقیاس گذاری شده) دو نوع زیر سری را به وجود می‌آورند؛ بردارهای تقریبی یا باقیمانده و بردارهای جزئیات. این ضرایب حاصل از در هم پیچیدن سری زمانی اصلی با فیلتر پایین-گذر همان تابع مقیاس گذاری است و فیلتر بالا گذر همان تابع موجک است. تابع تبدیل موجک قابلیت تجزیه سری زمانی به چندین زیر سری زمانی با مقیاس‌های مختلف را دارد و با بررسی زیر سری‌های زمانی متجه از سری زمانی کلی، رفتار کوچک مقیاس و بزرگ مقیاس یک فرآیند هیدرولوژیکی را آنالیز می‌کند. روابطی که بیشتر برای تخمین سطح تجزیه مورداستفاده قرار می‌گیرد به صورت زیر است:

$$L = \int \left[\log(N) \right], L = \frac{\log\left(\frac{N}{2p-1}\right)}{\log 2} \quad (3)$$

که در آن L سطح تجزیه، N تعداد نقاط داده در سری زمانی و p برابر بازمان محو شونده برای موجک مادر انتخاب شده است (Chou., 2014).

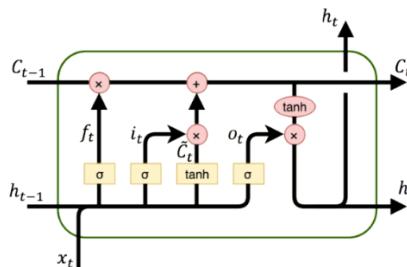
روش تجزیه مد تجربی (EMD): روش تجزیه مد تجربی (EMD) روشی برای تجزیه سیگنال‌های گوناگون است که این عمل در فرآیندی تحت عنوان غربال کردن صورت می‌گیرد. طی این فرآیند سیگنال اصلی به تعدادی مختلفه با محتوای بسامدی متفاوت تجزیه می‌شود. روش EMD طبق رابطه ۴ سیگنال اصلی (x) را به تعدادی مذاتی (IMF) تجزیه می‌کند (Amirat et al., 2018) :

$$x(n) = \sum_{i=1}^n c_i(x) + r_n(x) \quad (4)$$

که ($r_n(x)$ همان مختلفه باقی مانده، بعد از n تعداد IMFs و $c_i(x)$ است. یک داده ممکن است در یک زمان دارای چندین مذاتی باشد. این مدهای نوسانی، تابع‌های مذاتی (IMF) نام دارند و دارای دو شرایط هستند: ۱) در کل داده‌ها، تعداد نقاط فرین (اکسترم) و نقاط صفر باهم برابر و یا حداقل دارای یک واحد اختلاف هستند، ۲) در هر نقطه میانگین پوش برآراش داده شده بر نقاط بیشینه محلی و پوش برآراش داده شده بر نقاط کمینه محلی باید صفر باشد. به علت وجود تناوب و نویز در سیگنال‌ها، در برخی موارد به علت اختلاط مدها؛ توزیع حوزه زمان-فرکانس دچار انقطاع می‌شود و عملکرد EMD دچار نقض می‌گردد (چون میانگین IMF‌ها حالتی نامشخص به خود می‌گیرد). چهت رفع این ایجاد، روشی متفاوت با عنوان روش تجزیه مد تجربی یکپارچه (EEMD^۵) پیشنهاد شد. در روند تجزیه سازی آن، حجم محدودی از نویز سفید وارد سیگنال اصلی می‌شود. با

گیت فراموشی، گیت ورودی و گیت خروجی. درنهایت، شکل نهایی سلول LSTM به صورت شکل ۲ خواهد بود و معادلات مربوط به عملکرد گیتها و سلول حالت در رابطه ۶ آورده شده است.

چه مقدار از ورودی باید به خروجی ارسال شود. مقدار صفر یعنی هیچ اطلاعاتی نباید به خروجی ارسال شود درحالی که مقدار یک یعنی تمام ورودی به خروجی ارسال شود. LSTM دارای سه گیت برای کنترل مقدار سلول حالت است (Graves and Schmidhuber, 2005)



شکل ۲- شکل نهایی سلول LSTM

آماری استفاده گردید که عبارت اند از: ضریب همبستگی بین مقادیر مشاهداتی و محاسباتی (R) ، ضریب تبیین که همبستگی بین مقادیر پیش‌بینی شده و واقعی را نشان می‌دهد و یکی از معیارهای مهم ارزیابی قابلیت یک مدل است(DC) و ریشه میانگین مربعات خطایها که بیانگر میزان انحراف بین مقادیر پیش‌بینی شده است($RMSE$) . هرچه مقادار R و DC برای یک مدل به یک نزدیک‌تر و مقادار $RMSE$ کوچک‌تر باشد به معنی مطلوب بودن آن مدل است. روابط این پارامترهای آماری به صورت زیر است:

$$DC = 1 - \frac{\sum_{i=1}^N (1_o - \bar{1}_p)^2}{\sum_{i=1}^N (1_o - \bar{1}_o)^2} \quad (7)$$

$$R = \frac{\sum_{i=1}^N (1_o - \bar{1}_o) \times (1_p - \bar{1}_p)}{\sqrt{\sum_{i=1}^N (1_o - \bar{1}_o)^2} \times \sqrt{\sum_{i=1}^N (1_p - \bar{1}_p)^2}} \quad (8)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (1_o - 1_p)^2}{N}} \quad (9)$$

در روابط بالا: $\bar{1}_o$ مقدار اندازه‌گیری شده، $\bar{1}_p$ متوسط مقدار اندازه‌گیری شده، 1_o مقدار پیش‌بینی شده، 1_p متوسط مقدار پیش‌بینی شده و N تعداد داده‌ها است.

نتایج و بحث

تعریف مدل‌های ورودی: در مطالعه حاضر جهت مدل‌سازی

$$\begin{aligned} f_i &= \sigma(W_f x_i + U_f h_{t-1} + b_f) \\ i_t &= \sigma(W_i x_i + U_i h_{t-1} + b_i) \\ o_t &= \sigma(W_o x_i + U_o h_{t-1} + b_o) \\ c_t &= \sigma_h(W_c x_i + U_c h_{t-1} + b_c) \\ c_i &= f_i \odot c_{t-1} + i_t \odot c_t \\ h_t &= o_t \odot \sigma_h(c_t) \end{aligned} \quad (6)$$

در روابط بالا، x_t بردار ورودی، h_t بردار حالت مخفی یا بردار خروجی نهایی، f_t بردار فعال‌ساز گیت فراموشی، i_t بردار فعال‌ساز گیت ورودی، o_t بردار فعال‌ساز گیت خروجی، c_t بردار فعال‌ساز ورودی سلول، W_{t-1} بردار فعال‌ساز خروجی سلول، W_t بردار حالت سلول، W_z و W_o ماتریس‌های وزنی قابل یادگیری بین ورودی و بردارهای مربوطه، U_{t-1} و U_o ماتریس‌های وزنی قابل یادگیری بین خروجی و بردارهای مربوطه با یک واحد تأخیر زمانی، b_z و b_o بردارهای بایاس، b و b_h تابع فعال‌ساز سیگموید و تاثرانت هیپربولیک، σ ضرب نقطه‌ای دو بردار را نشان می‌دهد.

نمایلیزه کردن داده‌ها: یکی از مراحل اصلی در استفاده از روش‌های هوشمند پیش‌پردازش داده‌ها است . با توجه به دامنه وسیع داده‌های ورودی و به منظور افزایش دقت و سرعت مدل‌سازی، داده‌های موردادستفاده در این تحقیق با استفاده از رابطه ۷ در بازه $(0/1)$ نرمال شده‌اند و درنهایت مجموع داده‌های فوق برای مدل‌سازی به کار گرفته شده‌اند.

$$X_{istd} = 0.1 + 0.9 \times \left(\frac{X_i - X_{min}}{X_{max} - X_{min}} \right) \quad (7)$$

که در آن x_{min} کمترین داده و x_{max} بیشترین داده از نظر مقدار است (Roushangar and Shahnazi., 2019).

معیارهای ارزیابی: به منظور ارزیابی دقت و کارایی مدل از طریق مقایسه داده‌های مشاهداتی و شبیه‌سازی شده ، از سه پارامتر

1- Correlation Coefficient

2- Coefficient of Determination

3- Root Mean Squar Error

مدل‌سازی‌ها پس از نرم‌الیزه کردن داده‌ها ابتدا سری‌های زمانی توسط تبدیل موجک و تجزیه یکپارچه مدل تجربی کامل به زیر سری‌های LSTM تجزیه گردیده و سپس این زیر سری‌ها به عنوان ورودی مدل استفاده شد. جدول ۲ بیان گر مدل‌های زمانی تعریف شده است. لازم به توضیح است که داده‌های سری زمانی دبی جریان از سال ۲۰۰۱ تا ۲۰۱۴ به عنوان داده‌های آموزش و بقیه داده‌ها (۲۰۱۴ تا ۲۰۲۰) به عنوان داده‌های آزمون مورد استفاده قرار گرفته‌اند.

دبی جریان به صورت زمانی از پارامترهای دمای حداکثر(T_{max}) و حداقل(T_{min}) بارش($P(t)$ ، تابش خورشیدی($S(t)$ و دبی($Q(t)$) استفاده شده است. اندیس t تأخیر زمانی در هریک از پارامترها بر حسب روز را نشان می‌دهد. به این ترتیب که دبی یک روز تابع پارامترهای هواشناسی در همان روز و یا چند روز قبل و همچنین تابع دبی یک روز قبل خود است. این مدل‌سازی در دو رودخانه در دو اقلیم نیمه‌خشک و مرطوب مورد ارزیابی قرار گرفته است. در تمامی

جدول ۲- مدل‌های زمانی تعریف شده

مدل	ورودی	هدف
Q(I)	$T_{min}(t), T_{max}(t), P(t), S(t)$	$Q(t)$
Q(II)	$T_{min}(t), T_{min}(t-1), T_{max}(t), T_{max}(t-1), P(t), S(t)$	$Q(t)$
Q(III)	$T_{min}(t), T_{max}(t), P(t), P(t-1), S(t)$	$Q(t)$
Q(IV)	$T_{min}(t), T_{max}(t), P(t), P(t-1), P(t-2), S(t)$	$Q(t)$
Q(V)	$T_{min}(t), T_{max}(t), P(t), P(t-1), P(t-2), P(t-3), S(t)$	$Q(t)$
Q(VI)	$T_{min}(t), T_{max}(t), P(t), P(t-1), P(t-2), P(t-3), P(t-4), S(t)$	$Q(t)$
Q(VII)	$T_{min}(t), T_{max}(t), P(t), S(t), S(t-1)$	$Q(t)$
Q(VIII)	$T_{min}(t), T_{max}(t), P(t), S(t), S(t-1), S(t-2)$	$Q(t)$
Q(IX)	$T_{min}(t), T_{max}(t), P(t), S(t), S(t-1), S(t-2), S(t-3)$	$Q(t)$
Q(X)	$T_{min}(t), T_{max}(t), P(t), P(t-1), P(t-2), P(t-3), S(t), Q(t-1)$	$Q(t)$
Q(XI)	$T_{min}(t), T_{max}(t), P(t), P(t-1), P(t-2), P(t-3), S(t), S(t-1), S(t-2), Q(t-1)$	$Q(t)$
Q(XII)	$T_{min}(t), T_{max}(t), P(t), P(t-1), P(t-2), P(t-3), S(t), S(t-1), Q(t-1)$	$Q(t)$

در جدول ۲ پارامترهای $T_{min}(t), T_{max}(t), P(t), S(t)$ و $Q(t)$ به ترتیب تابش خورشیدی، بارش، دمای حداکثر و دبی رودخانه با (t) به صورت روزانه هست و پارامترهای یادشده با (t-1)، (t-2)، (t-3) به ترتیب تأخیر زمانی یک و دو و سه روز هست.

به روزهای قبل تعریف گردید و کارایی روش حافظه طولانی - کوتاه مدت موردنظری قرار گرفت. بنابراین این مدل‌ها با روش LSTM آنالیز گردید و نتایج حاصله از تحلیل مدل‌ها در جدول ۳ و ۴ نشان داده شد.

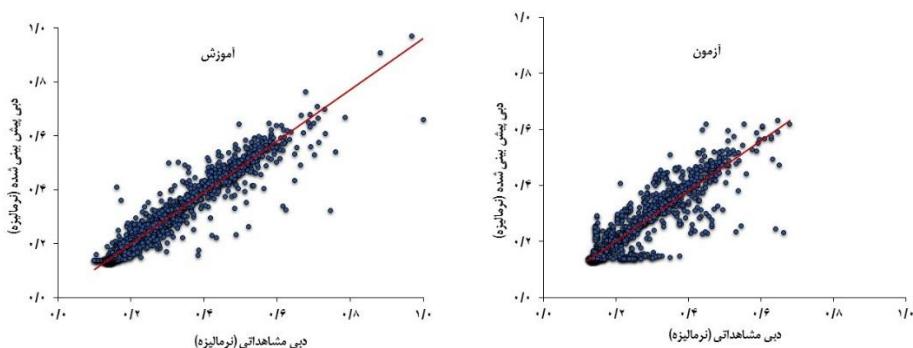
نتایج به دست آمده برای مدل LSTM بدون تجزیه داده‌ها: جهت تخمین میزان جریان رودخانه بر اساس سری زمانی اصلی و بدون تجزیه آن به چندین زیر سری، دوازده مدل بر اساس داده‌های روزانه دمای حداکثر، دمای حداقل، بارش، تابش خورشیدی و دبی مربوط

جدول ۳- نتایج ارزیابی مدل‌سازی زمانی رودخانه چالوس (منطقه مرطوب)

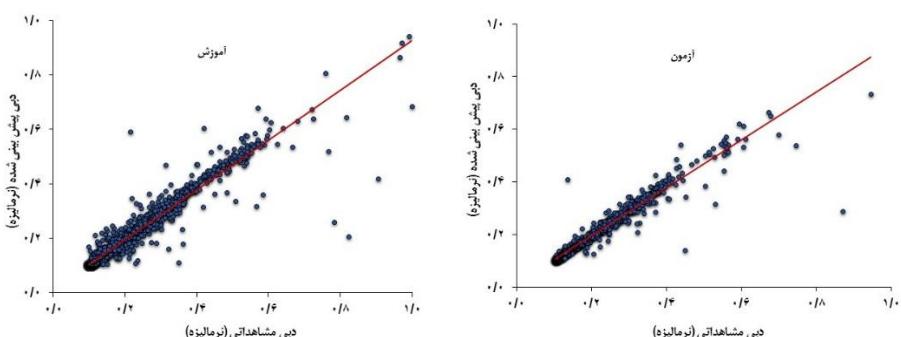
مدل	آموزش			آزمون		
	RMSE	DC	R	RMSE	DC	R
I	.۰/۰۹	.۰/۱۷۹	.۰/۴۴۴	.۰/۰۹	.۰/۲۸۱	.۰/۵۳۵
II	.۰/۰۹۱	.۰/۱۵۶	.۰/۴۵۹	.۰/۰۹۲	.۰/۲۵۵	.۰/۵۲
III	.۰/۰۹	.۰/۱۸۴	.۰/۴۳۸	.۰/۰۸۹	.۰/۳	.۰/۵۵۳
IV	.۰/۰۹	.۰/۱۷۳	.۰/۴۴۲	.۰/۰۸۹	.۰/۳۰۵	.۰/۵۵۸
V	.۰/۰۸۹	.۰/۱۹۱	.۰/۴۵	.۰/۰۸۶	.۰/۳۳۷	.۰/۵۸۵
VI	.۰/۰۹۱	.۰/۱۵۷	.۰/۴۲۴	.۰/۰۸۶	.۰/۳۵	.۰/۶۰۲
VII	.۰/۰۸۷	.۰/۲۳۳	.۰/۴۹۳	.۰/۰۸۷	.۰/۳۳۳	.۰/۵۸
VIII	.۰/۰۸۵	.۰/۲۶۵	.۰/۵۲۱	.۰/۰۸۳	.۰/۳۸۴	.۰/۶۲۹
IX	.۰/۰۸۸	.۰/۲۰۶	.۰/۵۰۶	.۰/۰۸۱	.۰/۴۱۷	.۰/۶۵۳
X	.۰/۰۰۴	.۰/۸۳۷	.۰/۹۱۷	.۰/۰۲۳	.۰/۹۵۳	.۰/۹۷۶
XI	.۰/۰۴	.۰/۸۳۳	.۰/۹۱۶	.۰/۰۲۴	.۰/۹۴۷	.۰/۹۷۶
XII	.۰/۰۴	.۰/۸۳۶	.۰/۹۱۶	.۰/۰۲۴	.۰/۹۴۹	.۰/۹۷۶

جدول ۴- نتایج ارزیابی مدل سازی زمانی رودخانه نازلو (منطقه نیمه خشک)

آزمون	آموزش			مدل		
	RMSE	DC	R		RMSE	DC
.۰/۰۷۶	.۰/۲۴۹	.۰/۵۱۸	.۰/۰۷۳	.۰/۳۰۲	.۰/۵۵۱	I
.۰/۰۷۸	.۰/۲۲۸	.۰/۵	.۰/۰۷۱	.۰/۳۳۸	.۰/۵۸۴	II
.۰/۰۷۵	.۰/۲۷	.۰/۵۴۸	.۰/۰۷۳	.۰/۳۱۱	.۰/۵۵۸	III
.۰/۰۷۴	.۰/۲۹۷	.۰/۵۵۳	.۰/۰۷۲	.۰/۳۲۴	.۰/۵۷۳	IV
.۰/۰۷۶	.۰/۳۰۳	.۰/۵۵۱	.۰/۰۷۱	.۰/۳۴۷	.۰/۶۰۱	V
.۰/۰۷۵	.۰/۲۸	.۰/۵۴۲	.۰/۰۷	.۰/۳۵۶	.۰/۶۰۱	VI
.۰/۰۷۸	.۰/۲۱۵	.۰/۵۰۶	.۰/۰۷۱	.۰/۳۴۷	.۰/۵۹	VII
.۰/۰۷۸	.۰/۲۲۹	.۰/۵۰۹	.۰/۰۶۸	.۰/۳۹	.۰/۶۲۵	VIII
.۰/۰۷۷	.۰/۲۴۲	.۰/۵۲۷	.۰/۰۶۶	.۰/۴۳۵	.۰/۶۶۲	IX
.۰/۰۲۳	.۰/۹۳۱	.۰/۹۶۵	.۰/۰۲۱	.۰/۹۴۱	.۰/۹۷۱	X
.۰/۰۲۶	.۰/۹۱	.۰/۹۵۵	.۰/۰۱۸	.۰/۹۵۴	.۰/۹۷۶	XI
.۰/۰۲۷	.۰/۹۰۳	.۰/۹۵۳	.۰/۰۱۹	.۰/۹۵۲	.۰/۹۷۶	XII



شکل ۳. نتایج مرحله آموزش و آزمودن مدل برتر (X) در رودخانه چالوس



شکل ۴- نتایج مرحله آموزش و آزمودن مدل برتر (X) در رودخانه نازلو چای

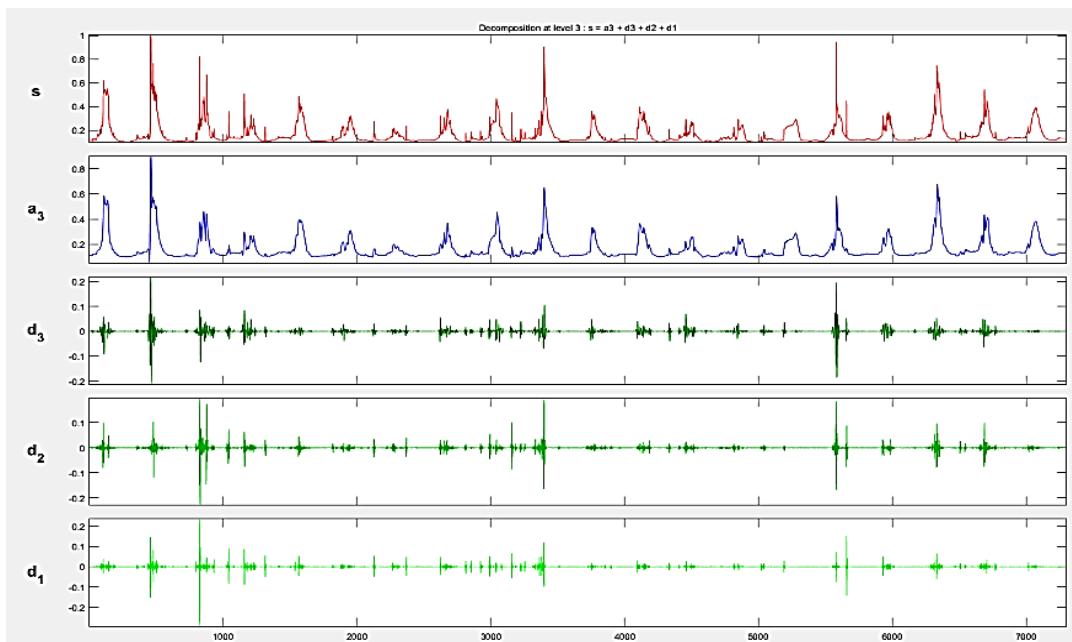
مربوط به اقلیم نیمه خشک از نتایج مربوط به اقلیم مرطوب به مراتب بهتر است. نتایج مربوط به دو رودخانه برای داده های آموزش و آزمون در شکل ۳ و ۴ نشان داده شده است.

نتایج به دست آمده برای مدل LSTM پس از تجزیه داده ها: در این قسمت با استفاده از دو روش تجزیه یکپارچه مد تجربی کامل و تبدیل موجک گسسته ابتدا سری های زمانی تجزیه گردید و سپس زیر

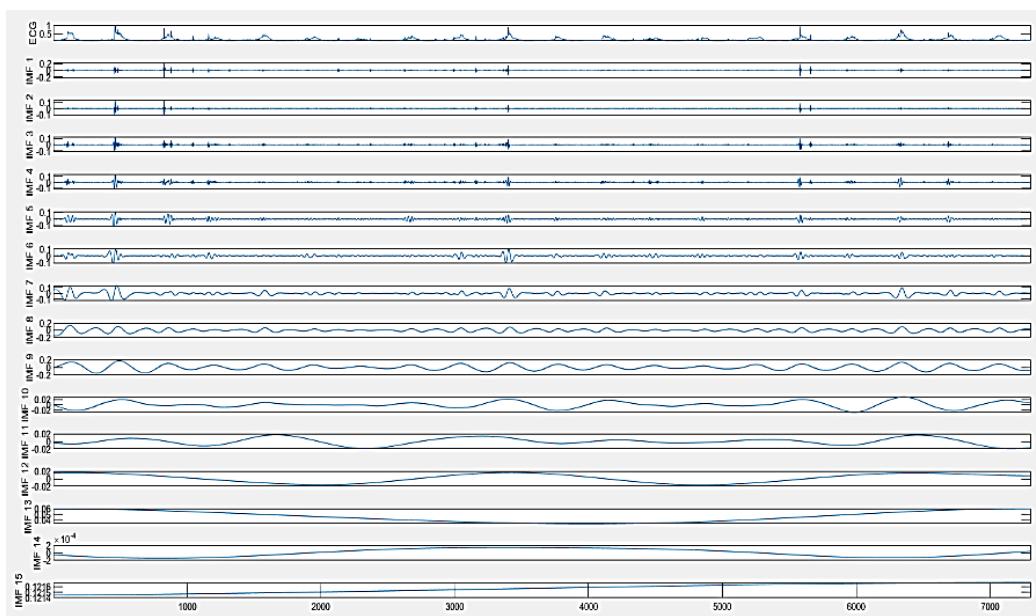
با توجه به نتایج به دست آمده از سه معیار ارزیابی مدل برای داده های آموزش و آزمون، مشاهده می شود که نتایج برای مدل Q(X) در هر دو رودخانه از مدل های دیگر بهتر است. بنابراین نتیجه می شود دبی در یک روز تا حد زیادی تابع دبی در روز قبل و دمای حداکثر و حداقل و تابش خورشیدی در همان روز و همچنین بارش مربوط به یک، دو و سه روز قبل است. همان طور که مشاهده می شود نتایج

پایه از سیگنال اصلی است. این پروسه تا وقتی ادامه می‌یابد که تقریباً سیگنال باقیمانده ثابت شود. درنهایت زیر سری‌های به‌دست‌آمده از هر دو روش، به عنوان ورودی به مدل LSTM داده شد. به عنوان مثال پیش‌پردازش سری‌های زمانی پارامتر دبی جریان ایستگاه تپیک در مقیاس روزانه توسط تبدیل موجک و همچنین تجزیه مدت تجربی در شکل‌های ۵ و ۶ نشان داده شده است.

سری‌های به‌دست‌آمده به عنوان ورودی به مدل LSTM داده شد. مدل‌سازی نیز در دو حالت اقلیم نیمه‌خشک و مرطوب انجام شد. اولین قدم برای تجزیه سیگنال با تبدیل موجک انتخاب موجک مادر است. در این تحقیق از موجک مادر db4 با ۳ سطح تجزیه استفاده شد. اساس روش CEEMD نیز تجزیه سیگنال به IMF‌های مختلف و یک سیگنال باقیمانده است که درنهایت مجموع این‌ها، همان سیگنال اصلی خواهد بود. روش تشکیل IMF‌ها بر اساس تفریق تابع



شکل ۵- زیر سری تجزیه شده پارامتر دبی در ایستگاه تپیک توسط تبدیل موجک گستته



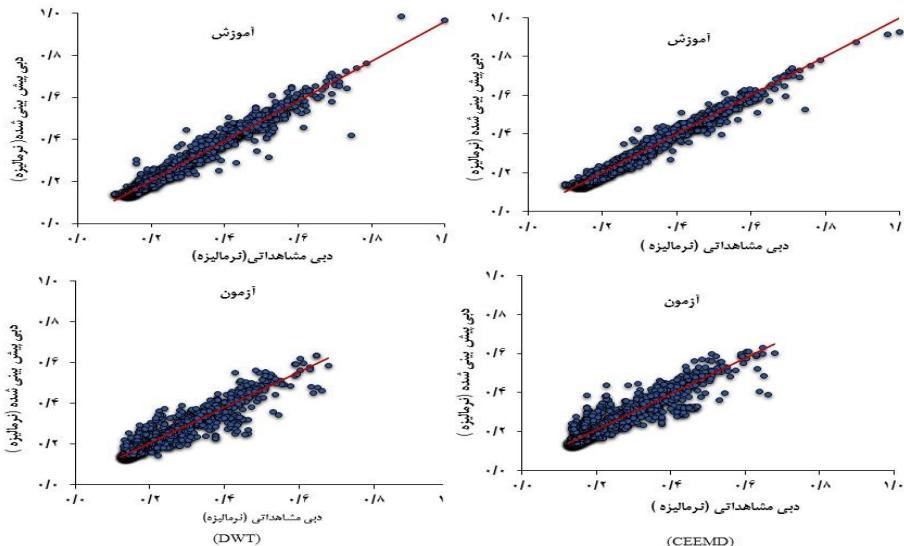
شکل ۶- زیر سری تجزیه شده پارامتر دبی در ایستگاه تپیک توسط تجزیه مدت تجربی یکپارچه کامل

جدول ۵- نتایج ارزیابی مدل‌سازی زمانی پس از تجزیه داده‌ها برای سه مدل برتر (DWT)

آزمون			آموزش			مدل	منطقه
RMSE	DC	R	RMSE	DC	R		
+/-0.18	+/-0.954	+/-0.977	+/-0.14	+/-0.974	+/-0.986	Q(X)	۱
-/-0.2	-/-0.946	-/-0.976	-/-0.15	-/-0.971	-/-0.989	Q(XI)	۲
+/-0.19	+/-0.95	+/-0.977	+/-0.14	+/-0.972	+/-0.987	Q(XII)	۳
+/-0.3	+/-0.906	+/-0.953	+/-0.16	+/-0.976	+/-0.989	Q(X)	۴
-/-0.3	-/-0.903	-/-0.95	-/-0.15	-/-0.979	-/-0.989	Q(XI)	۵
+/-0.3	+/-0.904	+/-0.951	+/-0.14	+/-0.98	+/-0.99	Q(XII)	۶

جدول ۶- نتایج ارزیابی مدل‌سازی زمانی پس از تجزیه داده‌ها برای سه مدل برتر (CEEMD)

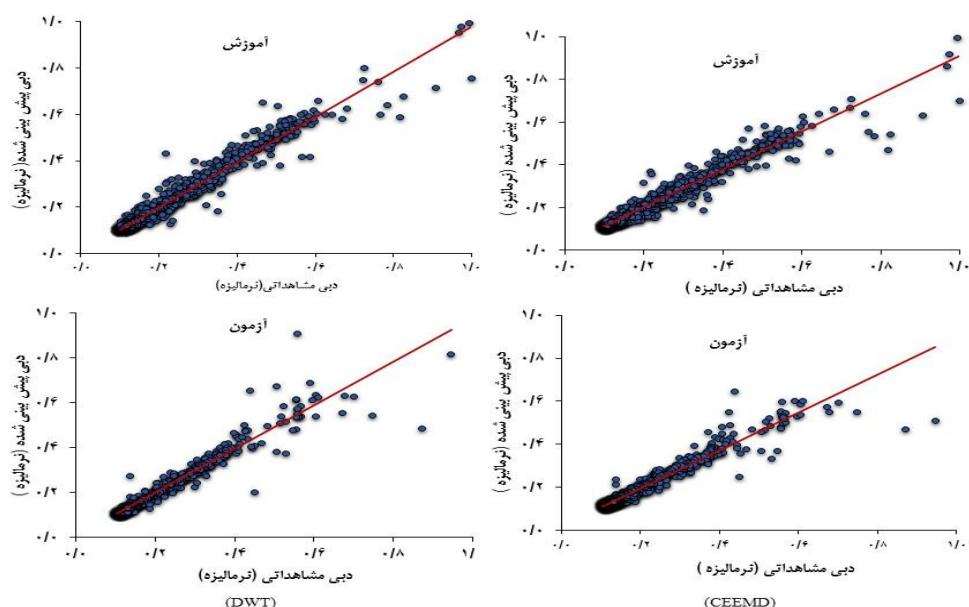
آزمون			آموزش			مدل	منطقه
RMSE	DC	R	RMSE	DC	R		
+/-0.21	+/-0.94	+/-0.972	+/-0.18	+/-0.955	+/-0.982	Q(X)	۱
-/-0.21	-/-0.938	-/-0.97	-/-0.13	-/-0.977	-/-0.988	Q(XI)	۲
+/-0.23	+/-0.93	+/-0.968	+/-0.16	+/-0.963	+/-0.982	Q(XII)	۳
+/-0.28	+/-0.88	+/-0.943	+/-0.13	+/-0.985	+/-0.992	Q(X)	۴
-/-0.36	-/-0.865	-/-0.94	-/-0.11	-/-0.989	-/-0.994	Q(XI)	۵
+/-0.34	+/-0.879	+/-0.94	+/-0.12	+/-0.986	+/-0.993	Q(XII)	۶



شکل ۷- نتایج مرحله آموزش و آزمودن مدل برتر (X) در رودخانه چالوس پس از تجزیه داده‌ها توسط تبدیل موجک و تجزیه مد تجربی

برتر در رودخانه نازلو چای در اقلیم نیمه‌خشک نتایج بهتری نسبت به رودخانه چالوس در اقلیم مرطوب دارد. بنابراین نتیجه می‌شود دبی جریان در یک روز تابع دبی در روز قبل، دمای حداکثر و حداقل و تابش خورشیدی در همان روز و بارش یک، دو و سه روز قبل خواهد بود. برای همین جهت مقایسه نتایج دو رودخانه پس از پردازش داده‌ها به دو روش ذکر شده در شکل ۷، ۸ آورده شده است.

نتایج حاصل از مدل‌سازی پس از پردازش داده‌ها توسط تبدیل موجک گستته و تجزیه مد تجربی در جدول ۵ و ۶ آورده شده است. همان‌طور که در نتایج نیز مشاهده می‌شود تجزیه سری‌های زمانی تا حدودی باعث بهبود نتایج شده‌اند و تأثیر تجزیه با استفاده تبدیل موجک گستته بیشتر از روش تجزیه مد تجربی کامل است. مطابق نتایج بهده مدل (X) (بهترین مدل است و طبق نتایج بدون پیش‌پردازش تعییر اقلیم تأثیر چندانی بر روی نتایج ندارد ولی مدل



شکل ۸- نتایج مرحله آموزش و آزمودن مدل برتر (Q(X)) در رودخانه نازلو چای پس از تجزیه داده‌ها توسط تبدیل موجک و تجزیه مد تجربی

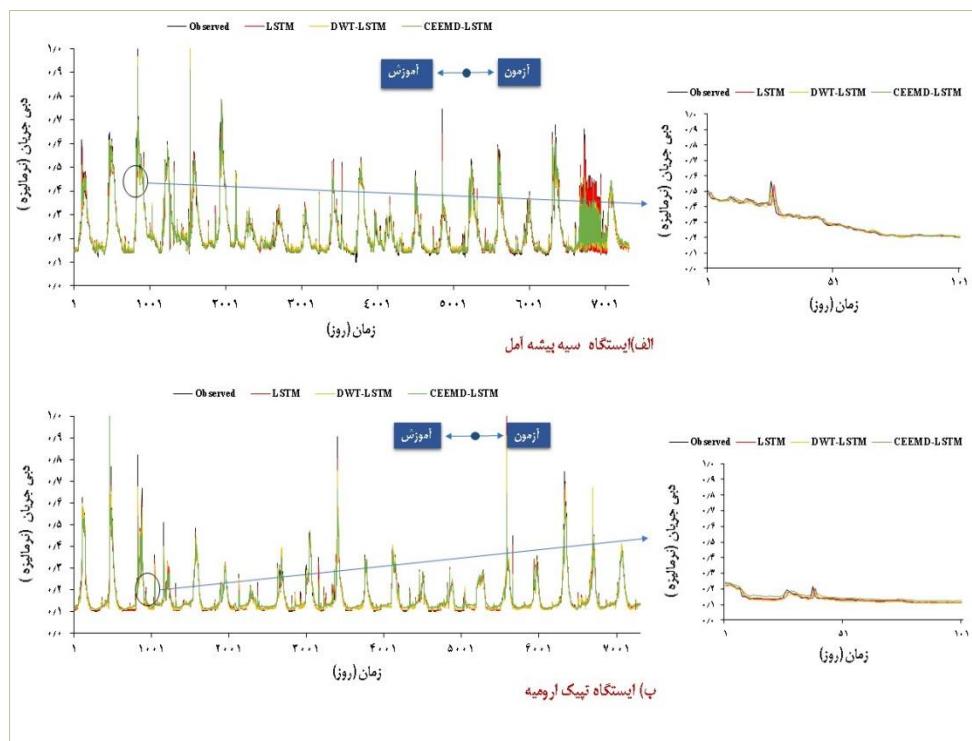
و افزایش مقدار DC شده است. که با پژوهشی صورت گرفته توسط Adamowski and Sun, (2010) و ثاقبیان، (۱۳۹۹) و همچنین میرزا نیا و همکاران، (۱۴۰۰) در خصوص پهلوود عملکرد تأثیر موجک بر افزایش دقت مدل‌های تخمینی در مدل‌سازی همخوانی دارد.

آنالیز حساسیت: جهت بررسی تأثیر پارامترهای به کار رفته در مدل برتر (مدل Q(X)) در حالت تجزیه با تبدیل موجک گستته در هر دو رودخانه آنالیز حساسیت انجام گرفت. برای این منظور با حذف تک تک پارامترهای مدل برتر و اجرای دوباره مدل و تعیین معیار ارزیابی RMSE میزان تأثیر پارامتر حذف شده در کاهش دقت مدل مورد بررسی قرار گرفت. نتایج حاصل از آنالیز حساسیت به صورت شکل ۱۰ ارائه گردیده است. همان‌طور که از شکل مشخص است با حذف پارامتر $(Q(t-1))$ دقت مدل تا حدود زیادی کاهش یافته است. بنابراین، می‌توان نتیجه گرفت که پارامتر $(Q(t-1))$ بیشترین تأثیر را در تخمین میزان دبی روزانه دارد.

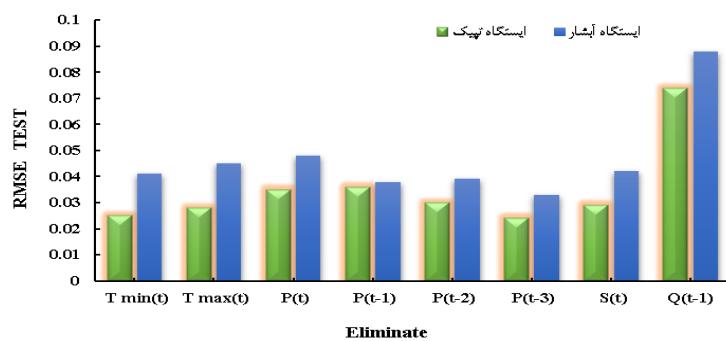
مقایسه نتایج: به منظور مقایسه نتایج به دست آمده از روش-های مختلف نتایج مربوط به مدل‌سازی سری زمانی دبی هر دو رودخانه در شکل ۹ آورده شده است. در این مطالعه با استفاده از روش‌های مبتنی بر هوش مصنوعی مانند روش حافظه طولانی-کوتاه‌مدت و مدل‌های ترکیبی موجک-حافظه طولانی-کوتاه‌مدت و تجزیه مد تجربی-حافظه طولانی-کوتاه‌مدت به پیش‌بینی دبی جریان در دو اقلیم مختلف پرداخته شد. نتایج معیارهای ارزیابی برای مرحله آزمون مدل‌های برتر با استفاده از روش‌های مذکور در جدول ۷ آورده شده است. مطابق نتایج مشاهده شده در هر دو اقلیم مدل Q(X) با داشتن بیشترین DC و کمترین RMSE به عنوان بهترین مدل ارزیابی شد. با توجه به نتایج در رودخانه نازلو چای معیار DC از ۰/۹۳۱ به ۰/۹۵۴ در تبدیل موجک و در رودخانه چالوس از ۰/۸۳۷ به ۰/۹۰۶ افزایش یافته و معیار RMSE در رودخانه نازلو چای از ۰/۰۲۳ به ۰/۰۱۸ و در رودخانه چالوس از ۰/۰۴۰ به ۰/۰۳۰ کاهش یافته است. اگرچه در هر دو نوع مدل‌سازی پردازش داده‌های باعث بهبود نتایج شده است اما مدل‌سازی با استفاده تبدیل موجک موجب کاهش

جدول ۷. مقایسه معیارهای ارزیابی برای سه روش به کار رفته برای مدل برتر در دو رودخانه

ایستگاه آبشار امل			ایستگاه تپک ارومیه			معیار
CEEMD LSTM	DWT LSTM	LSTM	CEEMD LSTM	DWT LSTM	LSTM	ارزیابی
۰/۸۸۰	۰/۹۰۶	۰/۸۳۷	۰/۹۴۰	۰/۹۵۴	۰/۹۳۱	DC
۰/۰۳۰	۰/۰۲۸	۰/۰۴۰	۰/۰۲۱	۰/۰۱۸	۰/۰۲۳	RMSE



شکل ۹- مقایسه نتایج مرحله آموزش و آزمودن مدل برتر (X_Q) بدون تجزیه و پس از تجزیه داده‌ها توسط تبدیل موجک و تجزیه مد تجربی



شکل ۱۰- تأثیر نسبی هر یک از پارامترهای ورودی مدل برتر در دو ایستگاه هیدرومتری تپیک و آبشار

مدل‌سازی هم بدون پیش‌پردازش داده‌ها و هم پس از تجزیه داده‌های سری زمانی با استفاده از تبدیل موجک و تجزیه مد تجربی انجام شد. با توجه به نتایج در هر دو رودخانه مدل X_Q که شامل پارامترهای ورودی دمای حداقل و حداکثر همان روز، تابش خورشیدی، دبی یک روز قبل و بارش سه روز قبل بود به عنوان مدل برتر شناخته شد. نتایج نشان داد که مدل منتخب قابلیت و کارایی بالایی در تخمین میزان دبی رودخانه را دارد. و روش‌های پیش‌پردازnde باعث بهبود نتایج شدند. در تبدیل موجک، معیار ارزیابی DC مدل برتر در ایستگاه تپیک رودخانه نازلو چای از ۰/۹۳۱ به ۰/۹۵۴ و در ایستگاه آبشار رودخانه چالوس از ۰/۸۳۷ به ۰/۹۰۶ افزایش یافت. و مقدار RMSE برای ایستگاه تپیک به مقدار ۰/۲۱۷۴ درصد و ایستگاه

نتیجه‌گیری

هدف از پژوهش حاضر پیش‌بینی دبی رودخانه با استفاده از روش ترکیبی حافظه طولانی- کوتاه‌مدت (LSTM)، تبدیل موجک و تجزیه مد تجربی در دو اقلیم نیمه‌خشک و مرطوب است. در این پژوهش به منظور دستیابی به این اهداف ابتدا داده‌های اقلیمی حداقل و حداقل دما، بارش و ساعات آفتابی طی دوره ۲۰۰۱-۲۰۲۰ از سازمان هواشناسی و داده‌های مربوط به ایستگاه‌های هیدرومتر یک از سازمان آب منطقه‌ای برای دو منطقه با اقلیم متفاوت اخذ گردید. رودخانه نازلو چای در اقلیم نیمه‌خشک در استان آذربایجان غربی و رودخانه چالوس در اقلیم مرطوب در استان مازندران هست. دو نوع

مدیریت آب و خاک، ۱، (۳): ۶۷-.

- Adamowski, K., Prokoph, A. and Adamowski, J. 2009. Development of a new method of wavelet aided trend detection and estimation. *Hydrological Processes: An International Journal*. 23(18): 2686-2696.
- Amirat, Y., Benbouzid, M. E. H., Wang, T., Bacha, K. and Feld, G. J. A. A. 2018. EEMD-based notch filter for induction machine bearing faults detection. *Applied Acoustics*. 133: 202-209.
- Adarsh, S., VishnuPriya, M. S., Narayanan, S., Smruthi, M. S., George, P. and Benjie, N. M. 2016. Trend analysis of sediment flux time series from tropical river basins in India using non-parametric tests and multiscale decomposition. *Modeling Earth Systems and Environment*. 2(4): 1-16.
- Alizadeh, M. J., Kavianpour, M. R., Kisi, O. and Nourani, V. 2017. A new approach for simulating and forecasting the rainfall-runoff process within the next two months. *Journal of hydrology*. 548: 588-597.
- Adamowski, J. and Sun, K. 2010. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. *Journal of Hydrology*. 390(1-2): 85-91.
- Behzad, M., Asghari, K., Eazi, M. and Palhang, M. 2009. Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with applications*. 36(4): 7624-7629.
- Choy, K. Y. and Chan, C. W. 2003. Modelling of river discharges and rainfall using radial basis function networks based on support vector regression. *International Journal of Systems Science*, 34(14-15), 763-773.
- Chou, C. M. 2014. Complexity analysis of rainfall and runoff time series based on sample entropy in different temporal scales. *Stochastic Environmental Research and Risk Assessment*. 28(6): 1401-1408.
- Chung, J., Gulcehre, C., Cho, K. and Bengio, Y. 2014. Empirical evaluation of gated recurrent neural networks on sequence modeling. *ArXiv preprint arXiv: 1412.3555*.
- Danandeh Mehr, A. D., Nourani, V., Hrnjica, B. and Molajou, A. 2017. A binary genetic programing model for teleconnection identification between global sea surface temperature and local maximum monthly rainfall events. *Journal of Hydrology*. 555: 397-406.
- Danandeh Mehr, A. D., Kahya, E., & Olyaei, E. 2013.

آبشار به مقدار ۲۵ درصد بهبود حاصل شد. و بهترین حالت ارزیابی برای داده‌های آزمون با استفاده از تبدیل موجک برای ایستگاه تپیک در اقلیم نیمه‌خشک با معیارهای ارزیابی $R=0.977$ و $DC=0.954$ و $RMSE=0.018$ به دست آمد. همچنین با توجه به نتایج آنالیز حساسیت مشخص شد پارامتر دبی یک روز قبل، تأثیرگذارترین پارامتر در تخمین دبی روزانه است. پیشنهاد می‌گردد در تحقیقات بعدی همین روش را برای مدل‌سازی حداقل دما و یا حداقل دما به علت تأثیرپذیری آن بر اقلیم موردنرسی قرار گیرد. همچنین می‌توان جهت پیش‌بینی متوسط دبی ماهانه، فصلی و سالانه از ترکیب هوش مصنوعی (LSTM) و ریزمقیاس نمایی آماری SDSM و یا-*WG* استفاده نمود.

منابع

- آذری، م، مرادی، ح، تقیان، ب، فرامرزی، م. ۱۳۹۲. ارزیابی اثرات هیدرولوژیکی تغییر اقلیم در حوضه آبخیز گرگان رود. *نشریه آب و خاک علوم و صنایع کشاورزی*، ۲۷(۳): ۵۴۷-۵۳۷.
- بهمنش، ج، آزاد طلا تپه، ن، رضایی، ح، خلیلی، ک. ۱۳۹۳. اثر تغییر اقلیم بر تبخیر تعرق مرجع، کمبود بارندگی و کمبود فشار بخار هوا در ارومیه. *نشریه دانش آب و خاک* ، ۲۵(۲): ۹۱-۷۹.
- بابایی مقدم، ا، خالدیان، م، شاه نظری، ع، و مرتضی پور، م. ۱۳۹۵. بررسی و پیش‌بینی دبی رودخانه‌های قزل‌اوزن و شاهroud. *اکو هیدرولوژی*، ۱۹۵-۲۰۴. ۱۹۵(۲): ۲۷-۵۳.
- ثاقبیان، س. م. ۱۳۹۹. پیش‌بینی زمانی و مکانی دبی جریان با استفاده از روش‌های تلفیقی هوش مصنوعی و پیش‌پردازش و پس پردازش سری زمانی. *نشریه آبیاری و زهکشی ایران*، ۱۴(۴): ۱۱۳۷-۱۱۵۱.
- سیاری، ن، علیزاده، ا، بنایان اول، م، فرید حسینی، ع، حسامی‌ترمانی، م. ر. ۱۳۹۰. مقایسه دو مدل گردش عمومی جو پیش‌بینی HadCM3,CGCM2 در پارامترهای اقلیمی و نیاز آبی گیاهان تحت تغییر اقلیم. *نشریه آب و خاک علوم و صنایع کشاورزی*، ۲۵(۴): ۹۲۵-۹۱۲.
- شنی‌زند، م، پیامنی، ک، احمدی، ش، و ویس کرمی، ا. ۱۳۹۳. پهنه‌بندی بوم اقلیم‌شناسی ایران. *مهندسی و مدیریت آبخیز*، ۱۷۵-۱۸۹. ۱۷۵(۲): ۶.
- میرزا نیا، ا، ملک احمدی، ح، شاه محمدی، ع، و ابراهیم‌زاده، ع. ۱۴۰۰. تأثیر موجک برافزایش دقت مدل‌های تخمینی در مدل‌سازی بارش-رواناب. *مطالعه موردی: حوضه صوفی چای. مدل‌سازی و*

- extreme learning machines. *Journal of hydrology.* 537: 431-443.
- Roushangar, K., Chamani, M., Ghasempour, R., Azamathulla, H. M. and Alizadeh, F. 2021. A comparative study of wavelet and empirical mode decomposition-based GPR models for river discharge relationship modeling at consecutive hydrometric stations. *Water Supply.* 21(6): 3080-3098.
- Roushangar, K. and Shahnazi, S. 2019. Evaluating the Performance of Data-Driven Methods for Prediction of Total Sediment Load in Gravel-Bed Rivers. *Iranian Journal of Soil and Water Research.* 50(6): 1467-1477.
- Roushangar, K. and Ghasempour, R. 2020. Monthly precipitation prediction improving using the integrated model based on kernel-wavelet and complementary ensemble empirical mode decomposition. *Amirkabir Journal of Civil Engineering.* 52(10): 2649-2660.
- Sak, H., Senior, A. W. and Beaufays, F. 2014. Long short-term memory recurrent neural network architectures for large scale acoustic modeling.
- Taormina, R. and Chau, K. W. 2015. Data-driven input variable selection for rainfall-runoff modeling using binary-coded particle swarm optimization and Extreme Learning Machines. *Journal of hydrology.* 529: 1617-1632.
- Wu, Z. and Huang, N. E. 2004. A study of the characteristics of white noise using the empirical mode decomposition method. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences.* 460(2046): 1597-1611.
- Yadav, B. and Eliza, K. 2017. A hybrid wavelet-support vector machine model for prediction of lake water level fluctuations using hydro-meteorological data. *Measurement.* 103: 294-301.
- Yaseen, Z. M., Jaafar, O., Deo, R. C., Kisi, O., Adamowski, J., Quilty, J. and El-Shafie, A. 2016. Stream-flow forecasting using extreme learning machines: a case study in a semi-arid region in Iraq. *Journal of Hydrology.* 542: 603-614.
- Zhu, S., Luo, X., Xu, Z. and Ye, L. 2019. Seasonal streamflow forecasts using mixture-kernel GPR and advanced methods of input variable selection. *Hydrology Research.* 50(1): 200-214.
- Streamflow prediction using linear genetic programming in comparison with a neuro-wavelet technique. *Journal of Hydrology.* 505: 240-249.
- Deng, L. and Yu, D. 2014. Deep learning: methods and applications. *Foundations and trends® in signal processing.* 7(3-4): 197-387.
- Felix, A. G., Jürgen, S. and Fred, C. 2000. Learning to forget: Continual prediction with LSTM. *Neural computation.* 12(10): 2451-2471.
- Graves, A., Liwicki, M., Fernández, S., Bertolami, R., Bunke, H. and Schmidhuber, J. 2008. A novel connectionist system for unconstrained handwriting recognition. *IEEE transactions on pattern analysis and machine intelligence.* 31(5): 855-868.
- Graves, A. and Schmidhuber, J. 2005. Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural networks.* 18(5-6): 602-610.
- Gers F, Schmidhuber J, Cummins F. Learning to Forget: Continual Prediction with LSTM. *Neural computation.* 2000; 12:2451-71.
- Huang, Y., Schmitt, F. G., Lu, Z. and Liu, Y. 2009. Analysis of daily river flow fluctuations using empirical mode decomposition and arbitrary order Hilbert spectral analysis. *Journal of Hydrology.* 373(1-2): 103-111.
- Hochreiter, S. and Schmidhuber, J. 1997. Long short-term memory. *Neural computation.* 9(8): 1735-1780.
- Kisi, Ö. and Çobaner, M. 2009. Modeling river stage-discharge relationships using different neural network computing techniques. *CLEAN–Soil, Air, Water.* 37(2): 160-169.
- Kisi, O. and Shiri, J. 2011. Precipitation forecasting using wavelet-genetic programming and wavelet-neuro-fuzzy conjunction models. *Water resources management.* 25(13): 3135-3152.
- Kisi, O. and Cimen, M. 2011. A wavelet-support vector machine conjunction model for monthly streamflow forecasting. *Journal of Hydrology.* 399(1-2): 132-140.
- Lau, K. M. and Weng, H. 1995. Climate signal detection using wavelet transform: How to make a time series sing. *Bulletin of the American meteorological society.* 76(12): 2391-2402.
- Lima, A. R., Cannon, A. J. and Hsieh, W. W. 2016. Forecasting daily streamflow using online sequential

Prediction River Discharge Using the Combined Method of Long Short-Term Memory, Wavelet Transform and Empirical Mode Decomposition in Semi-Arid and Humid Climate

K. Roushangar^{1*}, S. Abdelzad²

Received: Jan.23, 2023

Accepted: May.27, 2023

Abstract

Iran is faced with a dry and semi-dry climate with destructive floods, droughts, and water shortages. Droughts and floods can affect the environment, economic, and social activities. Therefore, examining and predicting river discharge and planning management to control it, especially for future water consumption, is very valuable. In this study, changes in river discharge were modeled using statistical data from 2001 to 2020. Statistical data from synoptic and hydrometric stations in a semi-arid region in Urmia city of West Azerbaijan province and a humid region in Amol city of Mazandaran province were used. Out of twelve time-series models defined for the Long Short-Term Memory (LSTM) network, the best model was identified. Then, LSTM modeling was performed based on pre-processing methods of Discrete Wavelet Transform (DWT) and Complementary Ensemble Empirical Mode Decomposition (CEEMD). The results showed that the selected model has high ability and efficiency in estimating the amount of river discharge. On the other hand, pre-processing methods improved the results such that the DC evaluation criterion in the wavelet transform increased from 0.93 to 0.95 in the Nazloo River and from 0.83 to 0.90 in the Chalous River. The best evaluation results for test data using wavelet transform for the Nazloo River in the semi-arid climate with evaluation criteria of $R=0.977$, $DC=0.954$, and $RMSE=0.018$ were obtained. Furthermore, the results of the sensitivity analysis indicated that the discharge parameter of one day before is the most effective in daily discharge estimation.

Keywords: Artificial neural networks, Deep learning, Empirical mode decomposition, Maximum temperature, Wavelet transform

1 - Professor, Dept. of water Eng., Faculty of Civil Eng, University of Tabriz, Tabriz, Iran

2 - PhD Candidate ind Hydraulic Structures, Faculty of Civil Eng, University of Tabriz ,Tabriz, Iran

(*-Corresponding Author Email: kroshangar@yahoo.com)