

پیش‌بینی توزیع مکانی-زمانی بارش در حوضه ارومیه با استفاده از مدل هیبریدی EEMD-SVM-LSTM

بهنوش فرخزاده،^{۱*} رسول ایمانی،^۲ سپیده چوبه^۳

تاریخ دریافت: ۱۴۰۴/۰۴/۰۱

تاریخ پذیرش: ۱۴۰۴/۰۸/۰۵

چکیده

پیش‌بینی دقیق بارش ماهانه برای مدیریت منابع آب و کاهش خطرات ناشی از نوسانات اقلیمی در مناطق نیمه‌خشک اهمیت ویژه‌ای دارد. هدف از این پژوهش، توسعه و ارزیابی یک مدل هیبریدی ترکیبی بر پایه تجزیه تجربی حالت تجمعی (EEMD)، ماشین بردار پشتیبان (SVM) و شبکه عصبی حافظه بلندمدت (LSTM) به منظور شبیه‌سازی و پیش‌بینی بارش ماهانه در حوضه آبریز دریاچه ارومیه است. در این راستا، داده‌های بارش ماهانه چهار ایستگاه خوی، سقز، تبریز و ارومیه طی دوره ۱۹۸۰ تا ۲۰۲۴ گردآوری و برای آموزش و اعتبارسنجی مدل استفاده شد؛ سپس بازه زمانی ۲۰۳۰ تا ۲۰۵۰ برای پیش‌بینی آینده بررسی گردید. نتایج نشان داد که مقدار RMSE در ایستگاه‌های مورد بررسی برای مدل SVM بین ۰/۰۷ تا ۰/۱۱ میلی‌متر و برای LSTM بین ۰/۱۰ تا ۰/۲۹ میلی‌متر متغیر بود. بالاترین میزان افزایش بارش سالانه در دوره آینده در ایستگاه خوی (۱۸/۸۲ درصد) مشاهده شد، درحالی‌که ایستگاه سقز با کاهش حدود ۱۴ درصدی بارش مواجه شد. به‌طور میانگین، بارش سالانه کل حوضه در سناریوی آینده نسبت به دوره پایه حدود ۴ درصد کاهش خواهد یافت. یافته‌ها نشان داد مدل هیبریدی EEMD-SVM-LSTM می‌تواند روندهای پیچیده بارش را با دقت بالا شبیه‌سازی و پیش‌بینی کند و برای بهبود مدیریت منابع آب و برنامه‌ریزی سازگار با تغییرات اقلیمی در مناطق مشابه، رویکردی کارآمد محسوب می‌شود.

کلیدواژه‌ها: بارش، تغییر اقلیم، حوضه آبریز دریاچه ارومیه، مدل هیبریدی، یادگیری عمیق، یادگیری ماشین.

۱. استادیار، گروه مهندسی طبیعت، دانشکده منابع طبیعی و محیط‌زیست، دانشگاه ملایر، ملایر، ایران، نویسنده مسئول b.farokhzadeh@malayeru.ac.ir

۲. دکترای آبخیزداری- آب، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، کاشان، ایران، rasool.imani@grad.kashanu.ac.ir

۳. دکترای آبخیزداری- آب، دانشکده منابع طبیعی دانشگاه ارومیه، ارومیه، ایران، s.choobeh@urmia.ac.ir

مقدمه

در دهه‌های اخیر، تغییرات اقلیمی و افزایش بی‌سابقه نوسانات آب‌وهوایی، مدیریت پایدار منابع آب و توسعه اقتصادی-اجتماعی مناطق خشک و نیمه‌خشک جهان را با بحران‌های جدی مواجه کرده است (هانتینگتون،^۱ ۲۰۰۶؛ اسلامیان و اسلامیان، ۲۰۱۷؛ IPCC، ۲۰۲۳). تغییرات گسترده در الگوهای بارش، کاهش منابع آب سطحی و زیرزمینی، افزایش تبخیر و تعرق و وقوع بیشتر رخدادهای حادی مانند خشکسالی و سیلاب‌ها، از مهم‌ترین پیامدهای این تغییرات به شمار می‌روند که نه تنها امنیت غذایی و کشاورزی را به خطر انداخته، بلکه بقای اکوسیستم‌ها و زیرساخت‌های حیاتی را نیز تهدید می‌کند (عباسپور و همکاران، ۲۰۰۹؛ منصوری دانشور و همکاران، ۲۰۱۹؛ فرج‌زاده و همکاران، ۲۰۲۲؛ وحدتی‌فر و همکاران، ۲۰۲۵). کشور ایران به دلیل اقلیم خشک و نیمه‌خشک، یکی از آسیب‌پذیرترین نواحی جهان نسبت به پیامدهای تغییر اقلیم و کاهش بارندگی محسوب می‌شود؛ به‌طوری‌که بیش از ۸۵ درصد مساحت کشور تحت‌تأثیر خشکی و ناپایداری منابع آبی قرار دارد (IPCC، ۲۰۲۳؛ عطارد و همکاران، ۲۰۲۳). در این میان، حوضه آبریز دریاچه ارومیه به‌عنوان یکی از کانون‌های بحرانی، نمونه‌ای از تأثیرات تغییرات اقلیم، برداشت‌های بی‌رویه و مدیریت نامطلوب منابع آب است (دلاور و همکاران، ۲۰۱۴؛ رزم‌آرا و همکاران، ۲۰۱۶؛ مه‌سافر و همکاران، ۲۰۱۷؛ عزیزی و همکاران، ۲۰۲۴). شرایط موجود در این حوضه حساس، لزوم بهره‌گیری از ابزارهای علمی و فناوری‌های نوین برای پیش‌بینی دقیق بارش و مدیریت علمی منابع آب را بیش از هر زمان دیگری برجسته ساخته است. مطالعات متعددی به بررسی و مدل‌سازی بارش در ایران و جهان پرداخته‌اند. مدل‌های آماری سستی مانند رگرسیون خطی و مدل‌های سری زمانی، به‌رغم کاربرد گسترده، در مواجهه با رفتارهای غیرخطی و غیرایستای داده‌های هیدرولوژیکی عملکرد محدودی داشته‌اند (فکته^۲ و همکاران، ۲۰۰۴؛ بیوندی^۳ و همکاران، ۲۰۱۰؛ حسین‌زاده طلایی و همکاران، ۲۰۱۷؛ کای^۴ و همکاران، ۲۰۱۹؛ هو^۵ و همکاران،


۲۰۲۴). این موضوع منجر به توجه بیشتر پژوهشگران به استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین، به‌ویژه در مناطق با اقلیم خشک و متغیر شده است (نورانی و همکاران، ۲۰۱۱؛ احمد، ۲۰۲۲؛ صالح و همکاران، ۲۰۲۴). پیشرفت‌های چشم‌گیر در حوزه هوش مصنوعی و یادگیری ماشین (ML) در سال‌های اخیر، افق جدیدی در مدل‌سازی داده‌های هیدرولوژیکی گشوده است. در این راستا، مدل‌های ترکیبی و چندرزلوشنی، با تلفیق تکنیک‌های تجزیه سیگنال مانند EEMD یا Wavelet Transform و مدل‌های یادگیری عمیق نظیر LSTM و SVM، قدرت بالایی در استخراج ویژگی‌های پیچیده و پیش‌بینی دقیق بارش در بازه‌های زمانی مختلف از خود نشان داده‌اند و دقت پیش‌بینی بارش را نسبت به روش‌های سنتی افزایش داده‌اند (احمد، ۲۰۲۲؛ نورانی و همکاران، ۲۰۱۱؛ دی‌یوپ^۶ و همکاران، ۲۰۲۰؛ وانگ^۷ و همکاران، ۲۰۲۱).

مطالعات متعددی نشان داده‌اند که استفاده از مدل‌های هیبریدی قادر است ویژگی‌های زمانی و مکانی پنهان بارش را شناسایی کرده و دقت پیش‌بینی را به‌طور معناداری بهبود دهد (یدیت‌ها^۸ و همکاران، ۲۰۲۳؛ وانگ و همکاران، ۲۰۲۱). نورانی و همکاران (۲۰۱۱) دو رویکرد هیبریدی مبتنی بر هوش مصنوعی برای مدل‌سازی فرایند بارش-رواناب ارائه کردند که به شناسایی الگوهای تناوبی فرایند بارش کمک کرد. نتایج بهینه‌سازی الگوریتمی نیز نشان می‌دهد که ترکیب فراابتکاری‌ها با مدل‌های یادگیری می‌تواند کارایی پیش‌بینی بارش را افزایش دهد؛ برای نمونه، دیوپ و همکاران (۲۰۲۰) با ادغام WOA و MLP، بهبود معناداری در دقت برآورد بارش سالانه گزارش کردند. همچنین، الگوهای چندمقیاسی مبتنی بر تجزیه سیگنال و یادگیری عمیق مانند Wavelet-DL و EEMD-LSTM در پیش‌بینی بارش ماهانه، عملکرد برتری نسبت به مدل‌های تک‌مقیاسی ارائه کرده‌اند (یدیت‌ها و همکاران، ۲۰۲۳؛ جیانگ^۹، جیانگ^۹، ۲۰۲۳؛ جیوست نا^{۱۰} و همکاران، ۲۰۲۵).

6. Diop
7. Wang
8. Yeditha
9. Jiang
10. Jyostna

1. Huntington
2. Fekete
3. Biondi
4. Cai
5. Hou

۲۰۲۲). بخش‌های عمده‌ای از این حوضه دارای اقلیم نیمه‌خشک تا خشک بوده و میانگین بارندگی سالانه معمولاً کمتر از ۴۰۰ میلی‌متر است (عزیزی، ۲۰۲۴). در سال‌های اخیر کاهش بارش، افزایش دما، توسعه کشاورزی و ساخت سازه‌های آبی موجب کاهش ورودی آب و افت تراز دریاچه شده است (مهدی‌زاده و همکاران، ۲۰۲۵؛ فرهنگ‌دار شوری، ۲۰۲۳). برآوردها نشان می‌دهد بیش از ۷۰ درصد از مساحت دریاچه طی دو دهه اخیر کاهش یافته است (نیک‌رفتار و همکاران، ۲۰۲۱؛ عزیزی، ۲۰۲۴).



شکل (۱): موقعیت منطقه مورد مطالعه و پراکنش ایستگاه‌های سینوپتیک
Figure (1): Location of the study area and distribution of synoptic stations

داده‌ها

داده‌های مشاهداتی

داده‌های بارش ماهانه چهار ایستگاه سینوپتیک خوی، سقز، تبریز و ارومیه طی سال‌های ۱۹۸۰ تا ۲۰۲۴ از سازمان هواشناسی کشور گردآوری شد. این ایستگاه‌ها به دلیل داشتن آمار کامل و طولانی مدت، برای تحلیل انتخاب شدند. اطلاعات آماری و موقعیت مکانی ایستگاه‌ها در جدول (۱) ارائه شده است.

جدول (۱): اطلاعات آماری ایستگاه‌های مورد مطالعه

Table (1): Statistical information of the stations under study

ایستگاه	میانگین	میان	انحراف معیار	بیشترین مقدار	کمترین مقدار
ارومیه	۳۱۹/۷۹	۳۰۴/۵	۹۵/۴۸	۵۷۹/۵	۱۶۷/۲
خوی	۲۷۷/۹۹	۲۶۹/۴	۷۵/۷۹	۵۲۵/۷	۱۶۸
تبریز	۲۶۱/۵۹	۲۵۱/۶	۶۴/۳۱	۴۰۲/۸	۱۴۸
سقز	۴۷۰/۸	۴۶۰/۷۸	۱۲۰/۶۱	۷۹۰/۸۴	۲۷۲/۵۹

داده‌های اقلیمی و سناریوی آینده

برای پیش‌بینی شرایط آینده، از خروجی مدل گردش عمومی جو HadGEM3-GC31-LL تحت سناریوی SSP5-8.5 استفاده شد. این مدل یکی از مدل‌های پیشرفته و معتبر مجموعه

افزون بر آن، بهره‌گیری از ترکیب مدل‌های خطی و غیرخطی نیز توانسته است کیفیت پیش‌بینی در اقلیم‌های خشک و نیمه‌خشک را ارتقا دهد (پرویز و همکاران، ۲۰۲۳). با وجود این، مرور پژوهش‌های پیشین نشان می‌دهد که هنوز خلأ در به‌کارگیری کامل چارچوب‌های چندرزلوشنی همراه با یادگیری غیرخطی باقی است؛ به گونه‌ای که در بسیاری مطالعات یا تنها از یک مدل تکی استفاده شده یا یکپارچه‌سازی کامل decomposition+ML نادیده گرفته شده است.

لذا هدف اصلی پژوهش حاضر، کاربرد یک چارچوب هیبریدی مبتنی بر ادغام تجزیه تجربی حالت تجمعی (EEMD)، ماشین بردار پشتیبان (SVM) و شبکه حافظه بلندمدت (LSTM) برای پیش‌بینی بارش ماهانه در حوضه آبریز دریاچه ارومیه است. در این مدل، ابتدا داده‌های بارش با استفاده از EEMD به مؤلفه‌های فرکانسی مختلف تفکیک شده و سپس مؤلفه‌های با رفتار سریع‌تر با مدل SVM و روندهای کندتر با LSTM مدل‌سازی می‌شوند. بدین ترتیب، هم ویژگی‌های کوتاه‌مدت و هم بلندمدت داده‌ها به صورت هم‌زمان در ساختار مدل لحاظ می‌شود. نوآوری این پژوهش در ترکیب تکنیک‌های تجزیه سیگنال و یادگیری ماشین عمیق، تحلیل داده‌های چندایستگاهی، و شبیه‌سازی سناریوهای آینده بارش است که می‌تواند به عنوان الگویی موفق برای مدیریت علمی منابع آب، طراحی سیاست‌های سازگار با تغییر اقلیم و افزایش تاب‌آوری زیست‌بوم‌های منطقه‌ای مورد استفاده قرار گیرد.

مواد و روش

منطقه مطالعه

دریاچه ارومیه که در شمال غرب ایران واقع شده، بزرگ‌ترین دریاچه شور خاورمیانه و یکی از مهم‌ترین ذخایر زیست‌محیطی کشور به شمار می‌رود (نیک‌رفتار و همکاران، ۲۰۲۱). حوضه آبریز دریاچه ارومیه در مدار ۳۵ درجه و ۴۰ دقیقه تا ۳۸ درجه و ۲۹ دقیقه عرض شمالی و ۴۴ درجه و ۱۳ دقیقه تا ۴۷ درجه و ۵۳ دقیقه طول شرقی قرار گرفته است (شکل ۱). این دریاچه در مرکز حوضه‌ای به وسعت تقریبی ۵۲۰۰۰ کیلومتر مربع قرار دارد که از طریق رودخانه‌های دائمی و فصلی، عمدتاً توسط زرينه‌رود و سيمينه‌رود تغذیه می‌شود (مبدرسانی و همکاران،

جلوگیری شده و روند بهینه‌سازی در شبکه‌های عصبی و الگوریتم‌های مبتنی بر کرنل مانند SVM و LSTM تسهیل می‌شود (هسو^۴ و همکاران، ۲۰۰۳؛ سزن^۵، ۲۰۲۳).

مدل هیبریدی EEMD-SVM-LSTM

برای شبیه‌سازی و پیش‌بینی بارش ماهانه، از مدل هیبریدی EEMD-SVM-LSTM استفاده شد. در این چارچوب، ابتدا الگوریتم تجزیه تجربی حالت تجمعی (EEMD^۶) برای تفکیک سیگنال بارش مشاهده‌ای به چندین مؤلفه مد ذاتی (IMF) و یک مؤلفه باقی‌مانده (Residual) (وو و هوانگ^۷، ۲۰۰۹) به کار رفت. سپس، مؤلفه‌های با فرکانس بالا (IMFs) که بیانگر نوسانات سریع هستند، با ماشین بردار پشتیبان (SVM^۸) شبیه‌سازی شدند. این مدل به دلیل توانایی در بازنمایی روابط غیرخطی و پیچیده، برای داده‌های پرنوسان مناسب است (نجوا مهد ریزال^۹ و همکاران، ۲۰۲۲). در مقابل، مؤلفه باقی‌مانده که روندهای بلندمدت را نشان می‌دهد، با استفاده از شبکه حافظه بلندمدت (LSTM^{۱۰}) مدل‌سازی شد، زیرا این شبکه وابستگی‌های زمانی طولانی را به خوبی شناسایی می‌کند (هوچریت و اسچمید هوبر^{۱۱}، ۱۹۹۷).

تجزیه سیگنال بارش با استفاده از روش EEMD

این روش، یک روش پیشرفته در پردازش سیگنال است که برای تجزیه سری‌های زمانی غیرخطی و غیرایستا توسعه یافته و محدودیت‌های روش کلاسیک EMD را رفع می‌کند. در روش EMD، سیگنال به مجموعه‌ای از توابع مد ذاتی (IMF) با مقیاس‌های زمانی مختلف تجزیه می‌شود (هوانگ و همکاران، ۱۹۹۸)، اما یکی از ضعف‌های این روش، پدیده «آمیختگی مد» است؛ به این معنا که نوسانات با فرکانس‌های متفاوت ممکن است به طور اشتباه در یک IMF ادغام شوند (وانگ و همکاران، ۲۰۱۵). روش EEMD برای رفع این مشکل، با افزودن نویز سفید گوسی به سیگنال و انجام تجزیه‌های مکرر، سپس

CMIP6 است که توسط مرکز هواشناسی مت‌آفیس بریتانیا توسعه یافته و در شبیه‌سازی دقیق متغیرهای جوی و اقلیمی نظیر دما، رطوبت، فشار، تبخیر و بارش در مقیاس‌های زمانی و مکانی مختلف عملکرد مناسبی دارد (IPCC, 2023). خروجی‌های این مدل شامل متغیرهای دما (tas)، رطوبت نسبی (hurs)، فشار سطح دریا (psl)، تبخیر (evspsbl) و بارش کل (pr) است که به عنوان مهم‌ترین عوامل مؤثر بر بارش انتخاب شدند (یان^۱ و همکاران، ۲۰۲۲؛ وانگ و همکاران، ۲۰۲۳).

سناریوی SSP5-8.5 نمایانگر یک مسیر توسعه اقتصادی و اجتماعی با انتشار بالای گازهای گلخانه‌ای است که منجر به گرمایش قابل توجه جهانی می‌شود و یکی از سناریوهای بحرانی مورد استفاده در گزارش‌های IPCC به شمار می‌رود. در این تحقیق، داده‌های اقلیمی تاریخی و آینده به تفکیک زمانی ماهانه برای بازه‌های ۱۹۸۰-۲۰۲۴ (دوره تاریخی) و ۲۰۳۰-۲۰۵۰ (دوره آینده) مورد استفاده قرار گرفتند.

پیش‌پردازش داده‌ها

نرمال‌سازی داده‌ها

برای بهبود عملکرد مدل‌های به کار رفته، داده‌های بارش با استفاده از روش مقیاس‌بندی بیشینه-کمینه^۲ نرمال‌سازی شدند (فرمول یک). این روش داده‌ها را به بازه ۰ تا ۱ تبدیل می‌کند و از تأثیر منفی اختلاف مقیاس متغیرها بر روند آموزش مدل جلوگیری می‌نماید.

$$x_{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

در این فرمول، x_i مقدار اصلی بارش، x_{max} و x_{min} به ترتیب کمینه و بیشینه داده‌ها و x_{norm} مقدار نرمال‌شده است. این مقیاس‌بندی برای داده‌هایی که توزیع نرمال ندارند، مناسب است و باعث می‌شود همه ویژگی‌ها به یک اندازه در فرایند یادگیری مؤثر باشند (گرون^۳، ۲۰۲۲). این ویژگی برای داده‌های هیدرولوژیک مانند بارش، که اغلب رفتار غیرخطی و غیرایستا دارند، اهمیت ویژه‌ای دارد. همچنین، با کاربرد این روش، از غلبه متغیرهای با دامنه بزرگ‌تر بر خروجی مدل

4. Hsu

5. Sezen

6. Ensemble empirical mode decomposition

7. Wu & Huang

8. Support Vector Machine

9. Najwa Mohd Rizal

10. Long Short-Term Memory

11. Hochreiter & Schmidhuber

1. Yan

2. Max-Min Scalling

3. Géron

و واپنیک، ۱۹۹۵). این مدل با نگاشت داده‌ها به فضای ویژگی با ابعاد بالاتر، امکان مدل‌سازی روابط پیچیده را فراهم می‌کند و دقت مدل‌های هیبریدی را افزایش می‌دهد (احترام و همکاران، ۲۰۲۱).

در SVM، داده‌های ورودی x با یک تابع نگاشت $\phi(x)$ به فضای ویژگی منتقل می‌شوند و مدل به صورت زیر تعریف می‌شود:

$$f(x) = \langle w, \phi(x) \rangle + b \quad (۴)$$

که در آن، w بردار وزن و b بایاس مدل است. هدف، کمینه‌سازی تابع هزینه زیر است تا خطای آموزش و پیچیدگی مدل هم‌زمان کنترل شود. هدف، کمینه‌سازی تابع هزینه زیر است تا خطای آموزش و پیچیدگی مدل هم‌زمان کنترل شود:

$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \epsilon_i \quad (۵)$$

با محدودیت‌های:

$$\begin{cases} y_i - \langle w, \phi(x_i) \rangle - b \leq \epsilon + \xi_i \\ \langle w, \phi(x_i) \rangle + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

در این روابط، C ضریب جریمه برای کنترل توازن بین پهنای حاشیه^۵ و خطای مدل، ϵ حاشیه حساسیت‌ناپذیر^۶، ξ_i و ξ_i^* متغیرهای لغزش هستند که مدل را نسبت به نویز داده‌ها مقاوم می‌سازند (دراکر^۷ و همکاران، ۱۹۹۶؛ والوت و مونستر^۸، ۲۰۱۸). انتخاب تابع کرنل تأثیر زیادی بر عملکرد مدل مدل دارد. چهار کرنل متداول عبارت‌اند از:

کرنل خطی^۹: این کرنل ساده‌ترین حالت بوده و داده‌ها را بدون هیچ‌گونه تبدیل، مستقیماً در فضای اولیه مدل‌سازی می‌کند. مناسب داده‌هایی است که رابطه میان متغیرها تقریباً خطی باشد.

کرنل چندجمله‌ای^{۱۰}: در این کرنل، داده‌ها با استفاده از چندجمله‌ای‌ها به فضای ابعاد بالاتر نگاشت می‌شوند. درجه چندجمله‌ای قابل تنظیم است و این نوع کرنل می‌تواند روابط غیرخطی را تا حدی مدل کند.

میانگین‌گیری نتایج، باعث تولید IMF های دقیق‌تر و کاهش اثر نویز و خطاهای تصادفی می‌شود (وو و هوانگ، ۲۰۰۹). در پیش‌بینی بارش، IMF های با فرکانس بالا مانند IMF1 و IMF2 بیانگر نوسانات کوتاه‌مدت، و IMF های با فرکانس پایین مانند IMF4 و بالاتر بیانگر روندهای اقلیمی بلندمدت هستند (یو^۱ و همکاران، ۲۰۱۸). این رویکرد امکان استخراج الگوهای معنادار بارش را در کنار حذف مؤثر نویز و اغتشاشات تصادفی فراهم می‌سازد (ژائو^۲ و همکاران، ۲۰۲۳).

مراحل تجزیه سیگنال بارش با استفاده از EEMD

۱. افزودن نویز سفید به سیگنال: به سیگنال اصلی بارش، نویز سفید گاوسی با دامنه کوچک افزوده می‌شود تا توزیع یکنواخت مؤلفه‌های فرکانسی در سراسر مقیاس‌های زمانی تضمین گردد.

$$x_i(t) = x(t) + w_i(t) \quad (۲)$$

۲. تجزیه سیگنال به مدهای ذاتی (IMFs) و مؤلفه باقی‌مانده (Residual)

$$x_i(t) = \sum_{k=1}^n c_{i,k}(t) + r_i(t) \quad (۳)$$

که در آن، $c_{i,k}(t)$ مد ذاتی k ام، $r_i(t)$ مؤلفه باقی‌مانده برای تکرار i ام است.

مراحل ۱ و ۲ برای تعداد مشخصی از تکرارها انجام می‌شود تا مجموعه‌ای از تجزیه‌های مختلف به دست آید در نهایت، برای کاهش اثر نویز و به دست آوردن IMF های نهایی و قابل اعتماد، میانگین‌گیری روی هر کدام از IMF های به دست آمده از تمام تکرارها صورت می‌گیرد. به این ترتیب، هر IMF نهایی برابر با میانگین IMF های متناظر در تمام مراحل آزمون خواهد بود و اثر نویز افزوده تا حد زیادی حذف می‌شود (ژائو و همکاران، ۲۰۲۳).

مدل SVM

ماشین بردار پشتیبان (SVM) یک مدل یادگیری نظارت‌شده برای طبقه‌بندی و رگرسیون است که در داده‌های غیرخطی عملکرد بالایی دارد (واپنیک و چرووننکیس، ۱۹۷۴؛ کورتز^۴ و

5. Flatness
6. Epsilon-Insensitive Margin
7. Drucker
8. Wallot & Mønster
9. Linear Kernel
10. Polynomial Kernel

1. Yu
2. Zhao
3. Vapnik & Chervonenkis
4. Cortes

ورودی جدید و حالت قبلی به روزرسانی می‌کند و به این ترتیب قادر است اطلاعات مفید را طی دنباله‌های زمانی طولانی نگه دارد و الگوهای پیچیده را در داده‌های سری زمانی، مانند بارش ماهانه، به درستی شناسایی کند.

$$\begin{aligned} f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \hat{c}_t &= \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ c_t &= f_t * c_{t-1} + i_t * \hat{c}_t \\ o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t &= o_t * \tanh(c_t) \end{aligned} \quad (۷)$$

در این مدل، x_t بردار ورودی در زمان t ، h_{t-1} وضعیت پنهان قبلی، و c_{t-1} وضعیت سلول قبلی را نشان می‌دهد. پارامترهای قابل یادگیری شامل وزن‌ها و بایاس‌ها برای هر دروازه هستند. توابع سیگموئید و تانژانت هیپربولیک نیز به عنوان توابع فعال‌سازی در ساختار LSTM به کار می‌روند (ژائو و همکاران، ۲۰۲۳). پس از مدل‌سازی مؤلفه‌های مختلف سیگنال بارش با استفاده از مدل‌های SVM و LSTM، خروجی‌های حاصل، برای بازسازی سری زمانی نهایی ترکیب شدند.

آموزش و پیش‌بینی مدل

مدل هیبریدی در دو مرحله اجرا شد:

آموزش و آزمون: مدل با داده‌های تاریخی (۱۹۸۰-۲۰۱۴) آموزش داده شد و سال‌های ۲۰۱۵ تا ۲۰۲۴ برای آزمون و اعتبارسنجی به کار رفتند. در این مرحله، مدل رابطه غیرخطی بین متغیرها و بارش مشاهده‌ای را فراگرفت.

پیش‌بینی آینده: پس از آموزش، خروجی‌های اقلیمی مدل HadGEM3 در بازه ۲۰۳۰-۲۰۵۰ به مدل آموزش دیده اعمال شد تا بارش ریزمقیاس شده و تصحیح شده برای ایستگاه‌های منتخب برآورد گردد.

در این فرایند، مدل هیبریدی به عنوان سامانه‌ای برای ریزمقیاس نمایی^۶ و اصلاح انحراف مدل^۷ عمل کرده و خروجی خام مدل اقلیمی را به مقادیر محلی منطبق با واقعیت‌های مشاهداتی تبدیل می‌کند. روند کلی تحقیق در شکل (۲) نمایش داده شده است. در این چارچوب، مدل

کرل سیگموئید^۱ این کرل که به کرل تانژانت هیپربولیک هیپربولیک هم معروف است، مشابه عملکرد یک شبکه عصبی تک‌لایه عمل می‌کند و بیشتر در کاربردهای خاص یا برای شبیه‌سازی شبکه‌های عصبی مورد استفاده قرار می‌گیرد.

کرل تابع پایه شعاعی^۲ پرکاربردترین کرل برای روابط پیچیده و غیرایستا، با عملکرد بالا در داده‌های هیدرولوژیکی و سری‌های زمانی غیرخطی (هسو^۳ و همکاران، ۲۰۰۳). در این تحقیق، از کرل RBF استفاده شد.

پس از حل مسئله بهینه‌سازی، ضرایب لاگرانژ α_i^* و α_i تعیین می‌شوند و خروجی مدل با تابع تصمیم زیر محاسبه می‌شود:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (۶)$$

که در آن، $K(x_i, x)$ تابع کرل است و میزان شباهت بین داده‌های پشتیبان و ورودی جدید را مشخص می‌کند. این تابع، مقدار پیش‌بینی شده متغیر هدف را برای داده‌های جدید ارائه می‌دهد.

مدل LSTM

مدل LSTM یکی از انواع شبکه‌های عصبی بازگشتی (RNN) هستند که به منظور غلبه بر مشکل محو شدن گرادیان در پردازش داده‌های دنباله‌دار توسعه یافته‌اند. توانایی LSTM در مدیریت داده‌های پیچیده، غیرخطی و غیرایستا، آن را به گزینه‌ای بسیار مؤثر برای پیش‌بینی بارش تبدیل می‌کند و این مدل نسبت به روش‌های سنتی مانند ARIMA عملکرد بهتری نشان داده است (هوچریتز و اسچمید هوبر، ۱۹۹۷^۴). ساختار LSTM شامل سه دروازه اصلی (ورودی، فراموشی و خروجی) است که جریان اطلاعات را در طول توالی داده‌ها کنترل می‌کند. این دروازه‌ها به شبکه اجازه می‌دهند تا ضمن حفظ وابستگی‌های بلندمدت، نوسانات کوتاه‌مدت را نیز به خوبی مدل‌سازی کند (ین^۵ و همکاران، ۲۰۲۱). در هر گام زمانی، هر واحد LSTM وضعیت داخلی خود را با توجه به داده‌های

1. Sigmoid Kernel
2. RBF- Radial Basis Function
3. Hsu
4. Hochreiter & Schmidhuber
5. Yin

6. downscaling
7. bias correction

مدل در شرایط معمولی ارائه می‌دهد (هیندمان و کوهرلر،^۳ ۲۰۰۶؛ بروکول و دیویس،^۴ ۲۰۱۶؛ ژائو و همکاران، ۲۰۲۳).

$$MAE = \frac{1}{n} \sum |x_i^p - x_i^p| \quad (9)$$

نمایش و تحلیل مکانی

در این پژوهش، از روش درون‌یابی وزن‌دهی معکوس فاصله^۵ (IDW) برای برآورد مقادیر متغیرهای مکانی در نقاط فاقد داده استفاده شد. روش IDW بر این فرض استوار است که تأثیر نقاط مجاور بر مقدار یک نقطه ناشناخته با افزایش فاصله کاهش می‌یابد. به عبارت دیگر، نقاط نزدیک‌تر وزن بیشتری در تخمین مقدار مجهول دارند.

فرمول کلی این روش به صورت زیر بیان می‌شود:

$$Z(x_0) = \frac{\sum_{i=1}^n \frac{Z(x_i)}{d(x_0, x_i)^p}}{\sum_{i=1}^n \frac{1}{d(x_0, x_i)^p}} \quad (10)$$

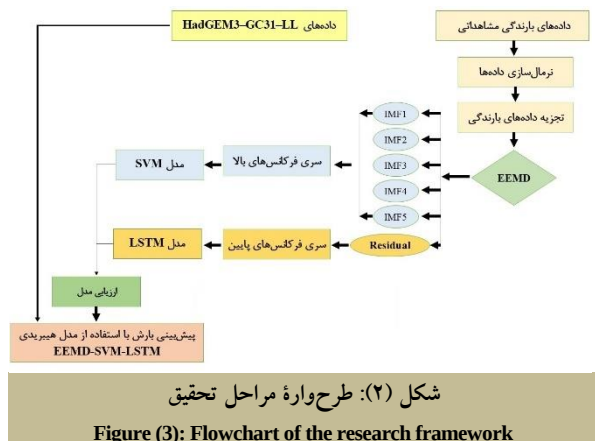
در این رابطه، Zx_0 مقدار برآوردشده در نقطه مجهول، Zx_i مقدار مشاهده‌شده در نقطه x_i ، $d(x_0, x_i)$ فاصله بین نقطه مجهول و نقطه x_i و p توان وزن‌دهی است که میزان تأثیر فاصله را کنترل می‌کند. در این تحقیق، مقدار پارامتر توان (Power) برابر ۰/۸ در نظر گرفته شد تا تأثیر نقاط مجاور با فاصله کم، به صورت ملایم‌تر نسبت به حالت توان‌های بزرگ‌تر کاهش یابد.

نتایج

نتایج تجزیه بارش مبتنی بر EEMD

در شکل (۳)، نتایج تجزیه سری زمانی بارش ماهانه به کمک الگوریتم EEMD برای ایستگاه‌های خوی (a)، سقز (b)، تبریز (c) و ارومیه (d) نشان داده شده است. همان‌طور که مشاهده می‌شود، سیگنال بارش هر ایستگاه به چندین تابع مد ذاتی (IMF) و یک مؤلفه باقی‌مانده (Residual) تفکیک شده است؛ این مؤلفه‌ها در مجموع امکان بازسازی تمام نوسانات و روندهای پنهان سیگنال اولیه را فراهم می‌کنند. در همه ایستگاه‌ها، مؤلفه IMF1 نمایانگر نوسانات با فرکانس بسیار بالا

اقلیمی HadGEM3-GC31-LL داده‌های خام اقلیمی آینده را تولید می‌کند و مدل EEMD-SVM-LSTM با یادگیری الگوی تاریخی بین پارامترهای اقلیمی و بارش، مقادیر آینده را در مقیاس محلی پیش‌بینی می‌کند. این روش ضمن حفظ ویژگی‌های فیزیکی اقلیم، دقت پیش‌بینی را به‌طور معناداری افزایش می‌دهد (یان^۱ و همکاران، ۲۰۲۲؛ وانگ و همکاران، ۲۰۲۳).



معیارهای ارزیابی مدل

به منظور سنجش دقت مدل، از دو شاخص آماری اصلی یعنی ریشه میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) استفاده شد. شاخص RMSE، جذر میانگین مربع تفاوت بین مقادیر پیش‌بینی شده و واقعی را اندازه‌گیری می‌کند و هرچه مقدار آن کمتر باشد، مدل دقت بالاتری دارد و نسبت به خطاهای بزرگ حساس‌تر است (ویلموث و ماتسورا،^۲ ۲۰۰۵).

$$RMSE = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_{io} - X_{ip})^2} \quad (8)$$

در این فرمول‌ها، X_{io} مقدار مشاهده‌شده، X_{ip} مقدار پیش‌بینی شده توسط مدل و n تعداد نمونه‌های مورد بررسی است. شاخص MAE نیز میانگین قدر مطلق اختلافات بین مقادیر پیش‌بینی شده و واقعی را محاسبه می‌کند. هرچه مقدار MAE کمتر باشد، مدل از دقت بالاتری برخوردار است. مزیت اصلی MAE نسبت به RMSE آن است که نسبت به داده‌های پرت حساسیت کمتری دارد و تصویری متعادل‌تر از عملکرد

3. Hyndman & Koehler

4. Brockwell & Davis


5. Inverse Distance Weighting

1. Yan

2. Willmott & Matsuura

وجود IMF5 و پایداری روند باقی مانده نشان دهنده فصل گرایی و ثبات نسبی بارش است. ایستگاه‌های تبریز و ارومیه نیز الگوی مشابهی دارند؛ اما مؤلفه باقی مانده در ارومیه حاکی از روند افزایشی ملایم بارش در دوره بلندمدت است که می‌تواند نشانه بهبود نسبی شرایط بارش در غرب حوضه باشد. برتری روش EEMD در مقایسه با روش‌های متعارف مثل فوریه یا موجک در این است که هم پدیده آمیختگی مدها را کاهش می‌دهد و هم جداسازی مؤثرتری از مؤلفه‌های با فرکانس مختلف در داده‌های غیرخطی و غیرایستا فراهم می‌آورد.

و تغییرات سریع است که عمدتاً نوین کوتاه مدت یا آشفتگی‌های تصادفی جوی را منعکس می‌کند. مؤلفه‌های IMF2 تا IMF4 در ایستگاه سقز تا IMF5، به تدریج از شدت نوسانات کاسته شده و چرخه‌های زیر فصلی تا بین سالی و روندهای میان مدت را نمایش می‌دهند. مؤلفه باقی مانده نیز روند بلندمدت یا تغییرات کم فرکانس را نشان می‌دهد. برای مثال، در ایستگاه خوی، IMF1 و IMF2 بیانگر پالس‌های سریع بارش و IMF3 و IMF4 نشان دهنده دوره‌های منظم تر و ملایم ترند؛ روند باقی مانده در این ایستگاه اندکی کاهشی است. در ایستگاه سقز،



شکل (۳): تجزیه سری زمانی بارش ماهانه با روش EEMD در چهار ایستگاه منتخب حوضه آبریز دریاچه ارومیه: (a) خوی، (b) سقز، (c) تبریز، و (d) ارومیه

Figure (3): EEMD-based decomposition of the monthly precipitation time series at four selected stations in the Urmia Lake basin: (a) Khoy, (b) Saqqez, (c) Tabriz, and (d) Urmia

مورد مطالعه طی دوره آزمون نشان می‌دهد. مؤلفه باقی‌مانده که نمایانگر نوسانات کم‌فرکانس و بلندمدت بارش است و توسط IMFها پوشش داده نمی‌شود، با استفاده از LSTM مدل‌سازی شده است؛ زیرا این شبکه‌ها توانایی بالایی در یادگیری وابستگی‌های زمانی طولانی دارند. همان‌طور که در نمودارهای (a) تا (d) مشاهده می‌شود، منحنی‌های شبیه‌سازی‌شده توسط LSTM تطابق خوبی با مقادیر واقعی باقی‌مانده دارند؛ به‌ویژه در ایستگاه‌های ارومیه و تبریز که مدل موفق شده است روند کلی و شکل سری باقی‌مانده را با کمترین انحراف بازسازی کند.

ارزیابی کمی عملکرد مدل (شکل ۶) نشان می‌دهد که مدل‌سازی باقی‌مانده با LSTM در ایستگاه‌های مختلف، RMSE را در محدوده ۰/۱ تا ۰/۲۹ و MAE را بین ۰/۰۸ تا ۰/۲۴ به دست آورده است. قابل ذکر است که ایستگاه ارومیه کمترین مقدار خطا را ثبت کرده است که بیانگر توانایی بالای LSTM در مدل‌سازی دینامیک باقی‌مانده در مناطق با نوسانات ملایم بارش است. اگرچه LSTM در مدل‌سازی ساختارهای زمانی بلندمدت عملکرد مطلوبی دارد، مقایسه با نتایج SVM (مطابق شکل ۴) نشان می‌دهد که SVM در اجزای با فرکانس بالا (IMF)، مقادیر خطای کمتری دارد. این یافته‌ها با مطالعات پیشین نیز هم‌خوانی دارد و نشان می‌دهد که SVM به‌دلیل توانایی تعمیم و بهینه‌سازی بالا برای مدل‌سازی نوسانات کوتاه‌مدت مناسب‌تر است، درحالی‌که LSTM در شناسایی وابستگی‌های بلندمدت برتری دارد (کورتز و واپنیک، ۱۹۹۵؛ هسو و همکاران، ۲۰۰۳؛ گرون، ۲۰۲۲). درمجموع، این نتایج بر ماهیت مکمل دو مدل تأکید دارد؛ SVM برای اجزای سریع و پرنوسان مناسب‌تر است و LSTM بازسازی دقیق مؤلفه‌های آرام و بلندمدت را ممکن می‌سازد. بنابراین، تلفیق این دو رویکرد در چارچوب هیبریدی EEMD-SVM-LSTM، روشی کارآمد و جامع برای پیش‌بینی بارش و بهره‌گیری از مزایای هر دو مدل را فراهم می‌کند.


نتایج شبیه‌سازی مؤلفه‌های تجزیه‌شده بارش (IMF) توسط مدل SVM

پس از تجزیه سری زمانی بارش ماهانه در ایستگاه‌های مورد مطالعه، هریک از توابع مد ذاتی به‌طور مجزا با SVM مدل‌سازی شدند و مجموع این اجزا با سیگنال اولیه بازسازی‌شده توسط EEMD مقایسه گردید (شکل ۴). دقت شبیه‌سازی مدل در دوره آزمون با استفاده از شاخص‌های آماری، مورد ارزیابی قرار گرفت. نتایج حاصل نشان داد مدل SVM در تمامی ایستگاه‌ها عملکرد مطلوبی داشته، به‌طوری‌که RMSE در بازه ۰/۰۷ تا ۰/۱۱ و MAE در محدوده ۰/۰۵ تا ۰/۰۸ به دست آمد. این مقادیر در مقایسه با مدل LSTM، که به‌تنهایی RMSE بالاتر (۰/۱۰ تا ۰/۲۹) و MAE (۰/۰۸ تا ۰/۲۴) را ثبت کرد، نشان‌دهنده برتری SVM در شبیه‌سازی نوسانات کوتاه‌مدت و اجزای فرکانس بالاست که در IMFها دیده می‌شود. همان‌طور که در شکل (۴) نیز مشخص است، خروجی شبیه‌سازی SVM با مقادیر بازسازی‌شده EEMD به‌ویژه در ایستگاه‌های سقز و ارومیه تطابق بالایی دارد.


این کارایی مطلوب را می‌توان به توانایی تعمیم بالا SVM در فضای ویژگی‌های غیرخطی و با ابعاد بالا نسبت داد (کورتز و واپنیک، ۱۹۹۵؛ هسو و همکاران، ۲۰۰۳). استفاده از کرنل تابع پایه شعاعی (RBF) باعث شده تا مدل با حداقل بیش‌برازش، روابط پیچیده میان اجزای سیگنال را به‌خوبی شناسایی کند، که برای مدل‌سازی سیگنال‌های هیدرومتئورولوژیک با تغییرات تصادفی کوتاه‌مدت ایدئال است (نورانی و همکاران، ۲۰۱۴؛ گرون، ۲۰۲۲). تطابق این نتایج با پژوهش‌های پیشین نشان می‌دهد که جداسازی مدهای فرکانسی مختلف با EEMD و مدل‌سازی مجزای هر جزء توسط SVM، دقت شبیه‌سازی را به‌طور قابل توجهی افزایش می‌دهد (سزن، ۲۰۲۳).

نتایج مدل‌سازی مؤلفه باقی‌مانده توسط مدل LSTM


شکل (۵) مقایسه بین مقادیر باقی‌مانده استخراج‌شده از EEMD و مقادیر شبیه‌سازی‌شده توسط LSTM را در چهار ایستگاه



شکل (۴): مقایسه مؤلفه‌های تجزیه‌شده با EEMD و شبیه‌سازی‌شده توسط مدل SVM در ایستگاه‌های خوی (a)، سقز (b)، تبریز (c) و ارومیه (d)
 Figure (4): Comparison of the EEMD-decomposed components and those simulated by the SVM model at the Khoi (a), Saqqez (b), Tabriz (c), and Urmia (d) stations



شکل (۵): مقایسه مؤلفه باقی‌مانده تجزیه‌شده با EEMD و شبیه‌سازی‌شده توسط مدل LSTM در ایستگاه‌های خوی (a)، سقز (b)، تبریز (c) و ارومیه (d)
Figure (5): Comparison of the EEMD-decomposed residual component and that simulated by the LSTM model at the Khoy (a), Saqqez (b), Tabriz (c), and Urmia (d) stations



شکل (۶): ارزیابی عملکرد مدل‌های EEMD-LSTM و EEMD-SVM براساس شاخص‌های RMSE و MAE
Figure (6): Performance evaluation of the EEMD-LSTM and EEMD-SVM models based on the RMSE and MAE indices

(۱۹۸۰-۲۰۲۴) و آینده (۲۰۳۰-۲۰۵۰) تفاوت‌هایی آشکار دارد. در دوره پایه، بارش فصلی در اغلب ایستگاه‌ها دارای دو قله اصلی در بهار و پاییز است، درحالی‌که در دوره آینده شدت این قله‌ها کاهش یافته و توزیع بارش به سمت الگوی یکنواخت‌تر

نتایج شبیه‌سازی و پیش‌بینی بارش توسط مدل ترکیبی EEMD-SVM-LSTM در دوره پایه و آینده همان‌طور که در شکل (۷) مشاهده می‌شود، الگوی بارش ماهانه در چهار ایستگاه خوی، سقز، تبریز و ارومیه طی دو دوره پایه


مقایسه میانگین بارش سالانه در دوره آینده و پایه در ایستگاه‌های مورد مطالعه

براساس نتایج شبیه‌سازی ارائه‌شده، مقادیر میانگین سالانه بارش برای هریک از چهار ایستگاه در دوره پایه و دوره آینده در شکل (۸) آورده شده است. نتایج نشان می‌دهد که بیشترین افزایش بارش سالانه مربوط به ایستگاه خوی است؛ به‌طوری‌که مقدار میانگین سالانه از حدود ۲۷۲ میلی‌متر در دوره پایه به ۳۲۳ میلی‌متر در دوره آینده افزایش یافته است. در تبریز نیز افزایش جزئی بارش سالانه مشاهده می‌شود، درحالی‌که ایستگاه‌های ارومیه و سقز کاهش نسبی بارش را تجربه می‌کنند. این تغییرات بیانگر جابه‌جایی مکانی الگوی بارش در منطقه و افزایش ناهمگونی فضایی و زمانی بارش تحت‌تأثیر تغییرات اقلیمی در افق ۲۰۵۰ است.

در طول سال تمایل پیدا کرده است. در ایستگاه سقز، اگرچه بیشترین میانگین بارش همچنان در ماه‌های بهار و پاییز رخ می‌دهد، شدت آن در دوره آینده کاهش یافته و در تابستان تغییر محسوسی دیده نمی‌شود. در خوی، الگوی بارش از دو قله مشخص در دوره پایه به چندین اوج ملایم‌تر در ماه‌های بهار و پاییز تغییر کرده و مقادیر بارش به‌ویژه در فروردین و اردیبهشت افزایش یافته است.


در تبریز، بارش‌های ماهانه در دوره آینده افزایش نسبی داشته و نوسانات فصلی کاهش یافته است؛ درنتیجه، بارش به‌صورت یکنواخت‌تر در طول سال توزیع می‌شود. در ارومیه نیز کاهش نسبی در شدت قله‌های فصلی و افزایش همگنی مکانی بارش مشاهده می‌شود.

به‌طور کلی، مدل هیبریدی EEMD-SVM-LSTM نشان می‌دهد که در دوره آینده، شدت نوسانات فصلی بارش کاهش و توزیع زمانی آن یکنواخت‌تر خواهد شد.



شکل (۷): نمودار مقادیر میانگین بارش ماهیانه شبیه‌سازی‌شده توسط مدل EEMD-SVM-LSTM در دوره پایه و آینده


Figure (7): Mean monthly precipitation simulated by the EEMD-SVM-LSTM model for the baseline and future periods



شکل (۸): مقادیر میانگین بارش سالیانه شبیه‌سازی شده توسط مدل EEMD-SVM-LSTM در دوره پایه و آینده

Figure (8): Mean annual precipitation simulated by the EEMD-SVM-LSTM model for the baseline and future periods

مقیاس کل حوضه است. به‌طور کلی، نتایج مدل ترکیبی حاکی از جابه‌جایی مکانی کانون بارش به سمت نواحی مرکزی و شمالی حوضه و کاهش کلی میانگین بارش سالانه در آینده است که می‌تواند ناشی از تغییر الگوهای هم‌دید و کاهش نفوذ سامانه‌های بارشی غربی بر اثر تغییرات اقلیمی باشد.



شکل (۹): توزیع مکانی بارش سالانه: (a) دوره پایه (۱۹۸۰-۲۰۲۴); (b) دوره آینده (۲۰۳۰-۲۰۵۰)

Figure (9): Spatial distribution of annual precipitation: (a) baseline period (1980-2024); (b) future period (2030-2050)

توزیع مکانی تغییرات بارش سالیانه در دوره پایه و آینده

براساس نتایج به‌دست‌آمده از مدل ترکیبی EEMD-SVM-LSTM و نقشه‌های ارائه‌شده در شکل (۹)، توزیع مکانی بارش سالانه در حوضه آبریز دریاچه ارومیه طی دو دوره زمانی پایه (۱۹۸۰-۲۰۲۴) و آینده (۲۰۳۰-۲۰۵۰) بررسی شد. الگوی بارش در دوره پایه نشان می‌دهد که بیشترین میانگین بارش سالانه در جنوب و جنوب غرب حوضه، به‌ویژه در محدوده سقز و ارومیه، با مقادیری حدود ۴۷۱ میلی‌متر رخ داده است، درحالی‌که کمترین بارش سالانه در نواحی شمال شرقی حوضه (به‌ویژه تبریز) با حدود ۲۶۰ میلی‌متر مشاهده می‌شود. این الگو با شرایط توپوگرافی، فاصله از دریاچه و مسیر حرکت سامانه‌های بارشی منطقه انطباق دارد.

بارش پیش‌بینی شده در دوره آینده نشان می‌دهد که کانون بیشینه بارش به سمت نواحی مرکزی و شمالی حوضه، به‌ویژه اطراف ارومیه و تبریز، جابه‌جا شده است. مقدار بیشینه بارش در این دوره حدود ۳۹۹ میلی‌متر و کمینه آن حدود ۲۷۶ میلی‌متر برآورد شده است و نواحی شمال غربی (خوی) و جنوب شرقی (سقز) کاهش نسبی بارش را نسبت به دوره پایه نشان می‌دهند.

براساس نمودار ارائه‌شده در شکل (۱۰)، میانگین بارش سالانه کل حوضه آبریز دریاچه ارومیه از حدود ۳۳۵ میلی‌متر در دوره پایه به حدود ۳۲۲ میلی‌متر در دوره آینده کاهش یافته است. این امر بیانگر کاهش حدود ۴ درصدی بارش سالانه در

و ارومیه) در دوره آینده با افزایش بارش و نواحی جنوب شرقی و شمال غربی (سقز و خوی) با کاهش بارش مواجه خواهند بود. این تغییرات می تواند ناشی از جابه جایی مسیر سامانه های بارشی مدیترانه ای و تغییر الگوهای همیدی بادهای غربی باشد (عطارد و همکاران، ۲۰۲۳؛ وحدتی فر و همکاران، ۲۰۲۵).

الگوی زمانی بارش نیز نشان دهنده کاهش شدت نوسانات فصلی و تمایل به یکنواختی بارش در طول سال است؛ به ویژه در تبریز و ارومیه. چنین تغییری می تواند اثر مستقیمی بر الگوی رواناب، زمان وقوع سیلاب ها و برنامه ریزی کشاورزی داشته باشد (احمدی و همکاران، ۲۰۲۳؛ آزاد و همکاران، ۲۰۲۱؛ دِ سوسا^۱ و همکاران، ۲۰۲۴).


افزایش سهم بارش زمستان و بهار، که در مدل پیش بینی شد، ممکن است نیاز به بازنگری در تقویم زراعی و مدیریت مخازن آبی را ایجاد کند.

به لحاظ روش شناسی، استفاده از مدل هیبریدی EEMD-SVM-LSTM موجب بهبود عملکرد پیش بینی شد. این مدل که با ترکیب تحلیل چندرزلوشنی و قابلیت یادگیری غیرخطی، الگوهای پیچیده و نوسانات چندمقیاسی بارش را به خوبی شناسایی کرد، مشابه با نتایج گزارش شده توسط یدیت و همکاران (۲۰۲۳) و دیوپ و همکاران (۲۰۲۲) است.

به طور کلی، یافته ها نشان می دهند که به رغم عدم تغییر چشمگیر در میانگین سالانه بارش، توزیع مکانی و فصلی آن در آینده دستخوش تغییراتی خواهد شد. این تغییرات می توانند سبب افزایش خطر وقوع سیلاب در شمال و خشکسالی در جنوب حوضه شوند و بر پایداری اکولوژیکی و امنیت آبی منطقه تأثیرگذار باشند.

۵. نتیجه گیری

نتایج این پژوهش نشان داد که تغییرات اقلیمی می تواند الگوهای زمانی و مکانی بارش در حوضه آبریز دریاچه ارومیه را تغییر دهد. مدل ترکیبی EEMD-SVM-LSTM با تلفیق تجزیه چندرزلوشنی، یادگیری ماشین و شبکه های عصبی عمیق، توانست رفتارهای غیرخطی و نوسانات چندمقیاسی



شکل (۱۰): بارش متوسط حوضه آبریز دریاچه ارومیه در دو دوره پایه و آینده

Figure (10): Average precipitation of the Urmia Lake basin in the baseline and future periods

بحث

در این پژوهش، تغییرات زمانی و مکانی بارش در حوضه آبریز دریاچه ارومیه طی دو دوره پایه (۱۹۸۰-۲۰۲۴) و آینده (۲۰۳۰-۲۰۵۰) با استفاده از مدل ترکیبی EEMD-SVM-LSTM مورد تحلیل قرار گرفت. نتایج نشان داد که تغییرات اقلیمی می تواند به طور معناداری الگوی بارش منطقه را تحت تأثیر قرار دهد.

میانگین بارش سالانه کل حوضه در دوره آینده با کاهش حدود ۴ درصد نسبت به دوره پایه (از ۳۳۴/۵ به ۳۲۰/۷ میلی متر) روبه روست. این کاهش در برخی ایستگاه ها، مانند ارومیه و سقز، محسوس تر بوده است، در حالی که در ایستگاه های خوی و تبریز افزایش نسبی مشاهده می شود. چنین الگوی ناهمگونی مکانی بیانگر جابه جایی کانون بارش به سمت شمال و مرکز حوضه و کاهش بارش در نواحی جنوبی و غربی است.

نتایج حاضر با یافته های پژوهش های پیشین درباره تأثیر تغییر اقلیم بر الگوهای بارش در شمال غرب ایران هم راستاست (حسن زاده و همکاران، ۲۰۱۲؛ عباسپور و همکاران، ۲۰۱۲؛ منصوری دانشور و همکاران، ۲۰۱۹). به طور مشابه، دلاور و همکاران، ۲۰۱۴؛ و مهسافر و همکاران، ۲۰۱۷) نیز کاهش تدریجی بارش و تشدید خشکسالی را از عوامل مؤثر بر افت سطح آب دریاچه ارومیه گزارش کرده اند. از منظر مکانی، نتایج مدل نشان داد که مناطق مرکزی و شمالی حوضه (به ویژه تبریز

با وجود دقت بالای مدل، چند محدودیت فنی باید مورد توجه قرار گیرد: نخست، مدل هیبریدی EEMD-SVM-LSTM به دلیل ماهیت چندمرحله‌ای، دارای پیچیدگی محاسباتی بالاست و اجرای آن نیازمند توان سخت‌افزاری و زمان پردازش قابل توجه است؛ دوم، مدل به‌شدت به کیفیت داده‌های ورودی وابسته است؛ داده‌های ناقص یا دارای نویز می‌توانند به افت چشمگیر در عملکرد مدل منجر شوند؛ سوم، تنظیم هم‌زمان پارامترهای سه بخش مدل فرایندی حساس، زمان‌بر و مستعد هم‌پوشانی است که ممکن است در صورت عدم بهینه‌سازی دقیق، باعث نوسانات غیرمنتظره در خروجی شود.

برای پژوهش‌های آتی، پیشنهاد می‌شود از الگوریتم‌های بهینه‌سازی تکاملی مانند PSO، GA یا HHO برای تنظیم خودکار پارامترهای مدل و کاهش هزینه محاسباتی استفاده شود. همچنین، توسعه مدل‌های ترکیبی جدید مانند تلفیق LSTM با XGBoost یا Random Forest می‌تواند دقت و پایداری پیش‌بینی را افزایش دهد. استفاده از روش‌های کاهش ابعاد مانند PCA یا Autoencoder نیز می‌تواند عملکرد مدل را در داده‌های بزرگ و چندمنبعی بهبود بخشد.

درنهایت، نتایج این پژوهش نشان داد که مدل‌های هیبریدی مبتنی بر یادگیری ماشین می‌توانند ابزارهای مؤثری برای پیش‌بینی بارش و ارزیابی اثرات تغییر اقلیم در مقیاس‌های منطقه‌ای باشند. این یافته‌ها ضمن تأکید بر اهمیت سیاست‌گذاری سازگار با اقلیم، ضرورت ارتقای سامانه‌های پایش، هشدار سیلاب و ذخیره‌سازی هوشمند آب را برای دستیابی به پایداری زیست‌محیطی در حوضه آبریز دریاچه ارومیه برجسته می‌کند.

بارش را با دقت بالا شبیه‌سازی کند. در این میان، مدل SVM در مدل‌سازی نوسانات سریع و مؤلفه‌های با فرکانس بالا عملکرد بهتری نسبت به LSTM داشت، درحالی‌که LSTM توانست روندهای بلندمدت را با دقت بیشتری بازسازی کند. تحلیل توابع مد ذاتی (IMFs) حاصل از روش EEMD نیز نشان داد که مدل هیبریدی توانایی استخراج مؤلفه‌های اصلی تغییرپذیری بارش را دارد و بازسازی نهایی سری زمانی از هم‌پوشانی خطاها جلوگیری می‌کند.

براساس مقایسه داده‌های دو دوره، میانگین بارش سالانه حوضه در آینده حدود ۴ درصد کاهش می‌یابد؛ هرچند این کاهش در مقیاس مکانی ناهمگون است. درحالی‌که ایستگاه‌های خوی و سقر کاهش بارش را تجربه می‌کنند، مناطق ارومیه و تبریز با افزایش نسبی مواجه‌اند. این جابه‌جایی مکانی کانون بارش به سمت شمال و مرکز حوضه، بازتابی از تغییر مسیر سامانه‌های بارشی و الگوهای همدیدی منطقه است.

از دیدگاه زمانی نیز نتایج نشان می‌دهد که بارش زمستان و بهار افزایش و بارش تابستان کاهش می‌یابد، که می‌تواند پیامدهای مستقیمی بر تقویم زراعی، مدیریت مخازن و الگوی رواناب سطحی داشته باشد. چنین تغییراتی به‌ویژه در مناطق خشک و نیمه‌خشک می‌تواند هم‌زمان منجر به افزایش احتمال سیلاب‌های فصلی و تشدید خشکسالی‌های تابستانه شود. از نظر تحلیل علمی، یافته‌های این پژوهش نشان می‌دهد که تغییرات اقلیمی در این حوضه صرفاً به تغییر در مجموع بارش محدود نمی‌شود، بلکه به بازتوزیع زمانی و مکانی بارش، افزایش نوسانات فصلی، و تغییر ساختار بارش‌های شدید نیز منجر می‌شود و بر لزوم بازنگری در راهبردهای سازگاری اقلیمی تأکید دارد.

منابع

1. Abbaspour, K. C., Faramarzi, M., Ghasemi, S. S., & Yang, H. (2009). Assessing the impact of climate change on water resources in Iran. *Water resources research*, 45(10), 1-16. <https://doi.org/10.1029/2008WR007615>
2. Abbaspour, M., Javid, A. H., Mirbagheri, S. A., Ahmadi Givi, F., & Moghimi, P. (2012). Investigation of lake drying attributed to climate change. *International Journal of Environmental Science and Technology*, 9, 257-266. <https://doi.org/10.1007/s13762-012-0031-0>
3. Ahmadi, H., Aminnejad, B., & Sabatsany, H. (2023). Application of machine learning ensemble models for rainfall prediction. *Acta Geophys*, 71, 1775-1786. <https://doi.org/10.1007/s11600-022-00952-y>
4. Ahmed, A. A. M. (2022). Development of deep learning hybrid models for hydrological predictions. <https://doi.org/10.26192/q7q5z>

5. Attarod, P., Dezhban, A., Pypker, T. G., Sigaroodi, S. K., Bayramzadeh, V., Tang, Q., ... & Mariv, H. S. (2023). Iran's Changing Climate over the Past 30 Years. *Russian Meteorology and Hydrology*, 48(1), 53-62.
6. Azad, M.A.K., Islam, A.R.M.T., Rahman, M.S. et al. (2021). Development of novel hybrid machine learning models for monthly thunderstorm frequency prediction over Bangladesh. *Nat Hazards*, 108, 1109-1135. <https://doi.org/10.1007/s11069-021-04722-9>
7. Azizi, S. (2024). Drought and Environmental Transformations of Lake Urmia: An Integrated Analysis Using Machine Learning and GIS. *European Journal of Applied Sciences*, 12(5), 290-315.
8. Biondi, D., Versace, P., & Sirangelo, B. (2010). Uncertainty assessment through a precipitation dependent hydrologic uncertainty processor: An application to a small catchment in southern Italy. *Journal of Hydrology*, 386(1-4), 38-54.
9. Brockwell, P. J., & Davis, R. A. (1991). *Time series: theory and methods*. Springer science & business media.
10. Cai, C., Wang, J., & Li, Z. (2019). Assessment and modelling of uncertainty in precipitation forecasts from TIGGE using fuzzy probability and Bayesian theory. *Journal of Hydrology*, 577, 123995. <https://doi.org/10.1016/j.jhydrol.2019.123995>
11. Cortes, C., Vapnik, V. (1995). Support-vector networks. *Mach Learn*, 20, 273-297 <https://doi.org/10.1007/BF00994018>
12. de Sousa, M.F., Uliana, E.M., Aires, R.V.U. et al. (2024). Streamflow prediction based on machine learning models and rainfall estimated by remote sensing in the Brazilian Savanna and Amazon biomes transition. *Model Earth Syst Environ*, 10, 1191-1202. <https://doi.org/10.1007/s40808-023-01837-9>
13. Delavar, M., Babaei, O., & Fattahi, I. (2014). Evaluation of climate change impacts on Urmia Lake water level fluctuations. *Journal of Climate Research*, 1393(19), 53-65.
14. Drucker, H., Burges, C. J., Kaufman, L., Smola, A., Vapnik, V. (1996). *Support vector regression machines*. Advances in neural information processing systems,
15. Diop, L., Samadianfard, S., Bodian, A., Yaseen, Z. M., Ghorbani, M. A., & Salimi, H. (2020). Annual rainfall forecasting using hybrid artificial intelligence model: integration of multilayer perceptron with whale optimization algorithm. *Water Resources Management*, 34, 733-746. <https://doi.org/10.1007/s11269-019-02473-8>
16. Ehteram, M., Sammen, S. S., Panahi, F., & Sidek, L. M. (2021). A hybrid novel SVM model for predicting CO2 emissions using Multiobjective Seagull Optimization. *Environmental Science and Pollution Research*, 28, 66171-66192. <https://doi.org/10.1007/s11356-021-15223-4>
17. Eslamian, S., & Eslamian, F. A. (Eds.), (2017). *Handbook of Drought and Water Scarcity: Environmental Impacts and Analysis of Drought and Water*. CRC Press [Imprint].
18. Farajzadeh, Z., Ghorbanian, E., & Tarazkar, M. H. (2022). The shocks of climate change on economic growth in developing economies: evidence from Iran. *Journal of Cleaner Production*, 372, 133687. <https://doi.org/10.1016/j.jclepro.2022.133687>
19. Farhangdarehshouri, S. (2023). *Quantification of the water balance and experimental evaporation studies*, Lake Urmia, Iran. <https://doi.org/10.26083/tuprints-00024466>
20. Fekete, B. M., Vörösmarty, C. J., Roads, J. O., & Willmott, C. J. (2004). Uncertainties in precipitation and their impacts on runoff estimates. *Journal of Climate*, 17(2), 294-304. [https://doi.org/10.1175/1520-0442\(2004\)017%3C0294:UIPATI%3E2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017%3C0294:UIPATI%3E2.0.CO;2)
21. Fekete, B. M., Vörösmarty, C. J., Roads, J. O., & Willmott, C. J. (2004). Uncertainties in precipitation and their impacts on runoff estimates. *Journal of Climate*, 17(2), 294-304.
22. Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. "O'Reilly Media, Inc."
23. Hassanzadeh, E., Zarghami, M., & Hassanzadeh, Y. (2012). Determining the main factors in declining the Urmia Lake level by using system dynamics modeling. *Water resources management*, 26, 129-145. <https://doi.org/10.1007/s11269-011-9909-8>
24. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
25. Hosseinzadehtalaei, P., Tabari, H., & Willems, P. (2017). Uncertainty assessment for climate change impact on intense precipitation: how many model runs do we need?. *International Journal of Climatology*, 37, 1105-1117.
26. Hou, S., Geng, Q., Huang, Y., Bian, Z., 2024. Rainfall prediction model based on CEEMDAN-VMD-BiLSTM network. *Water, Air, & Soil Pollution*, 235(8), 482. <https://doi.org/10.1007/s11270-024-07299-8>
27. Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). A practical guide to support vector classification. <https://www2.cs.sfu.ca/~oschulte/teaching/726/spring11/svmguide.pdf>
28. Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... Liu, H. H. (1998). *The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis*. Proceedings of the Royal Society of London.
29. Huntington, T. G. (2006). Evidence for intensification of the global water cycle: Review and synthesis. *Journal of Hydrology*, 319(1-4), 83-95. <https://doi.org/10.1016/j.jhydrol.2005.07.003>

30. Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4), 679-688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
31. IPCC. (2023). *Climate Change 2023: Synthesis Report, Summary for Policymakers*. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]. IPCC, Geneva, Switzerland. <https://cir.nii.ac.jp/crid/1360019997669261824>
32. Jiang, X. (2023). A combined monthly precipitation prediction method based on CEEMD and improved LSTM. *PloS one*, 18(7), e0288211. <https://doi.org/10.1371/journal.pone.0288211>
33. Jyostna, B., Meena, A., Rathod, S. et al., (2025). Multiscale rainfall forecasting using a hybrid ensemble empirical mode decomposition and LSTM model. *Model. Earth Syst. Environ*, 11, 119. <https://doi.org/10.1007/s40808-024-02220-y>
34. Mahdizadeh, M., Eslamian, S., & Sabzevari, Y. (2025). Analysis of surface flows of Urmia Lake Basin: a review. *Hydrosystem Restoration Handbook*, 217-241. <https://doi.org/10.1016/B978-0-443-29802-8.00016-9>
35. Mahsifar, H., Maknoon, R., & Saghafian, B. (2017). The impact of climate change on water level of Urmia Lake. *Research in Marine Sciences*, 2(2), 83-94. <https://resmarsci.com/wp-content/uploads/2017/06/page-Marine-Sciences-3-3.pdf>
36. Mansouri Daneshvar, M. R., Ebrahimi, M., & Nejadsoleymani, H. (2019). An overview of climate change in Iran: facts and statistics. *Environmental Systems Research*, 8(1), 1-10. <https://doi.org/10.1186/s40068-019-0135-3>
37. Mobadersani, A., Hosseinzadeh Dalir, A., Yasi, M., Arvanaghi, H., & Kennard, M. J. (2022). New integrated hydrologic approach for the assessment of rivers environmental flows into the Urmia Lake. *Scientific Reports*, 12(1), 8110. <https://doi.org/10.1038/s41598-022-10262-4>
38. Najwa Mohd Rizal, N., Hayder, G., Mnzool, M., Elnaïm, B. M., Mohammed, A. O. Y., & Khayyat, M. M. (2022). Comparison between regression models, support vector machine (SVM), and artificial neural network (ANN) in river water quality prediction. *Processes*, 10(8), 1652. <https://doi.org/10.3390/pr10081652>
39. Nazari, A., Jamshidi, M., Roozbahani, A., & Golparvar, B. (2025). Groundwater level forecasting using empirical mode decomposition and wavelet-based long short-term memory (LSTM) neural networks. *Groundwater for Sustainable Development*, 28, 101397. <https://doi.org/10.1016/j.gsd.2024.101397>
40. Nikraftar, Z., Parizi, E., Hosseini, S. M., & Ataie-Ashtiani, B. (2021). Lake Urmia restoration success story: A natural trend or a planned remedy?. *Journal of Great Lakes Research*, 47(4), 955-969. <https://doi.org/10.1016/j.jglr.2021.03.012>
41. Nourani, V., Baghanam, A. H., Adamowski, J., & Kisi, O. (2014). Applications of hybrid wavelet-artificial intelligence models in hydrology: a review. *Journal of Hydrology*, 514, 358-377. <https://doi.org/10.1016/j.jhydrol.2014.03.057>
42. Nourani, V., Kisi, Ö., & Komasi, M. (2011). Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*, 402(1-2), 41-59. <https://doi.org/10.1016/j.jhydrol.2011.03.002>
43. Parviz, L., Rasouli, K., & Torabi Haghighi, A., (2023). Improving hybrid models for precipitation forecasting by combining nonlinear machine learning methods. *Water Resources Management*, 37(10), 3833-3855. <https://doi.org/10.1007/s11269-023-03528-7>
44. Razmara, P., Motiee, H., Massah Bavani, A., Saghafian, B., & Torabi, S. (2016). Risk assessment of climate change impacts on runoff in Urmia Lake basin, Iran. *Journal of Hydrologic Engineering*, 21(8), 04016023. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001379](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001379)
45. Saleh, M. A., Rasel, H. M., & Ray, B. (2024). A comprehensive review towards resilient rainfall forecasting models using artificial intelligence techniques. *Green Technologies and Sustainability* 100104. <https://doi.org/10.1016/j.grets.2024.100104>
46. Sezen, C. (2023). Pan evaporation forecasting using empirical and ensemble empirical mode decomposition (EEMD) based data-driven models in the Euphrates sub-basin, Turkey. *Earth Science Informatics*, 16(4), 3077-3095. <https://doi.org/10.1007/s12145-023-01078-5>
47. Vahdatifar, M., Mousavi, S. F., Farzin, S., & Hadiani, M. O. (2025). Comprehensive Study of Climate Change Impacts on Temperature and Precipitation in East and West of Mazandaran Province in North of Iran. *Water*, 17(8), 1181. <https://doi.org/10.3390/w17081181>
48. Vapnik, V. (1999). The nature of statistical learning theory. Springer science & business media.
49. Vapnik, V., & Chervonenkis, A. (1974). *Theory of pattern recognition*. Nauka, Moscow
50. Wang, W. C., Chau, K. W., Xu, D. M., & Chen, X. Y. (2015). Improving forecasting accuracy of annual runoff time series using ARIMA based on EEMD decomposition. *Water resources management*, 29, 2655-2675. <https://doi.org/10.1007/s11269-015-0962-6>
51. Wang, W., Du, Y., Chau, K., Chen, H., Liu, C., & Ma, Q., (2021). A comparison of BPNN, GMDH, and ARIMA for monthly rainfall forecasting based on wavelet packet decomposition. *Water*, 13(20), 2871. <https://doi.org/10.3390/w13202871>
52. Wang, D., Liu, J., Luan, Q., Shao, W., Fu, X., Wang, H., & Gu, Y. (2023). Projection of future precipitation change using CMIP6 multimodel

- ensemble based on fusion of multiple machine learning algorithms: A case in Hanjiang River Basin, China. *Meteorological Applications*, 30(5), e2144.
53. Willmott, C. J., & Matsuura, K., 2005. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate research*, 30(1), 79-82. doi:10.3354/cr030079
54. Wu, Z., & Huang, N. E. (2009). Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Advances in adaptive data analysis*, 1(01), 1-41. <https://doi.org/10.1142/S1793536909000047>
55. Yan, Y., Wang, H., Li, G., Xia, J., Ge, F., Zeng, Q., ... & Tan, L. (2022). Projection of future extreme precipitation in China based on the CMIP6 from a machine learning perspective. *Remote Sensing*, 14(16), 4033.
56. Yeditha, P. K., Anusha, G. S., Nandikanti, S. S. S., & Rathinasamy, M. (2023). Development of a monthly scale precipitation-forecasting model for Indian subcontinent using wavelet-based deep learning approach. *Water*, 15(18), 3244. <https://doi.org/10.3390/w15183244>
57. Yin, H., Zhang, X., Wang, F., Zhang, Y., Xia, R., & Jin, J. (2021). Rainfall-runoff modeling using LSTM-based multi-state-vector sequence-to-sequence model. *Journal of Hydrology*, 598, 126378. <https://doi.org/10.1016/j.jhydrol.2021.126378>
58. Yu, Y., Zhang, & H., Singh, V. P. (2018). Forward prediction of runoff data in data-scarce basins with an improved ensemble empirical mode decomposition (EEMD) model. *Water*, 10(4), 388. <https://doi.org/10.3390/w10040388>
59. Zhao, J., Nie, G., & Wen, Y. (2023). Monthly precipitation prediction in Luoyang city based on EEMD-LSTM-ARIMA model. *Water Science & Technology*, 87(1), 318-335. <https://doi.org/10.2166/wst.2022.425>
60. Zhao, X., Zhang, Y., & Wang, J. (2023). Application of EEMD in hydrological time series analysis. *Journal of Hydrology*, 620, 129456. <https://doi.org/10.1016/j.jhydrol.2023.129456>

Spatiotemporal Prediction of Precipitation Distribution in the Urmia Basin Using an EEMD-SVM-LSTM Hybrid Model

Behnoush Farokhzadeh,^{1*} Rasool Imani,² Sepideh Choobeh³

Received: 22/06/2025

Accepted: 11/11/2025

Extended Abstract

Introduction: Accurate prediction of monthly rainfall is crucial for water resource management and risk mitigation in semi-arid regions, particularly under climate change. The Lake Urmia Basin in northwestern Iran has faced significant environmental degradation in recent decades, driven by climatic variability, unsustainable agriculture, and inadequate water management. Forecasting future rainfall patterns is therefore essential for developing adaptive strategies to restore ecological balance and ensure sustainable development. However, traditional statistical models often fail to capture the nonlinear and non-stationary characteristics of hydrological data. This limitation has prompted the exploration of advanced machine learning and deep learning techniques. Hybrid models that integrate signal decomposition with intelligent algorithms have shown superior performance in time series forecasting by improving feature extraction and reducing noise. This study introduces a novel hybrid framework that combines Ensemble Empirical Mode Decomposition (EEMD), Support Vector Machine (SVM), and Long Short-Term Memory (LSTM) networks to simulate and predict monthly rainfall in the Lake Urmia Basin. The proposed EEMD-SVM-LSTM model leverages the complementary strengths of each component to capture both short-term fluctuations and long-term trends, thereby significantly enhancing predictive accuracy.

Materials and Methods: Monthly rainfall data from four synoptic stations—Urmia, Khoy, Tabriz, and Saez—were collected for the period 1980–2020 for model development and validation. Future projections were then generated for the 2030–2050 period under a business-as-usual scenario. The proposed methodology involved decomposing the original rainfall time series into several Intrinsic Mode Functions (IMFs) and a residual component using the Ensemble Empirical Mode Decomposition (EEMD) method. This decomposition facilitated a multi-resolution analysis by isolating distinct frequency components, thereby simplifying the modeling of complex, non-stationary rainfall dynamics.

The high-frequency IMFs, which represent short-term noise and rapid fluctuations, were modeled using a Support Vector Machine (SVM) algorithm, selected for its effectiveness with nonlinear relationships and limited data. Conversely, the low-frequency residual component, encapsulating the long-term trend, was predicted using a Long Short-Term Memory (LSTM) network, chosen for its ability to learn and retain long-term dependencies in sequential data. The final integrated prediction was obtained by summing the forecasted results from all SVM and LSTM components.

Model performance was quantitatively evaluated using Root Mean Square Error (RMSE) and Mean Absolute Error (MAE). To demonstrate the superiority of the hybrid approach, its predictive accuracy was benchmarked against standalone SVM and LSTM models.

Results: The EEMD process successfully decomposed the rainfall signals into distinct intrinsic mode functions, enabling a more targeted modeling approach. The hybrid EEMD-SVM-LSTM model demonstrated superior predictive performance compared to the standalone SVM and LSTM models. This was evidenced by consistently lower error metrics across all stations during both training and validation phases. The RMSE values for the hybrid model ranged from 0.07 to 0.11 mm, outperforming the standalone SVM (0.10–0.29 mm) and LSTM models. Projections for the 2030–2050 period revealed spatially variable changes in rainfall across the basin. Khoy station exhibited the highest annual rainfall increase (+18.8%), whereas Saez experienced the most significant decrease (–14.9%). At the basin level, the mean annual rainfall is projected to decline by approximately 4%, from 334.5 mm to 320.7 mm. Spatially, the analysis indicated a northward shift in precipitation concentration, with increases projected over Tabriz and Urmia, and decreases in the southern and western parts of the basin. Temporally, a shift toward a more

1. Assistant Professor, Natural Engineering Department, Faculty of Natural Resources and Environment, Malayer University, Malayer, Iran. (Corresponding Author); Email: b.farokhzadeh@malayeru.ac.ir

2. PhD Graduated in Watershed Management, Faculty of Natural Resources and Geoscience, Kashan University, Kashan, Iran. Email: rasool.imani@grad.kashanu.ac.ir

3. PhD Graduated in Watershed Management, Faculty of Natural Resources, Urmia University, Urmia, Iran. Email: s.choobeh@urmia.ac.ir

uniform seasonal distribution was observed, characterized by a relative increase in winter and spring precipitation and a more pronounced decline in late-summer rainfall.

Discussion and Conclusion: This study demonstrates that the hybrid EEMD-SVM-LSTM framework effectively captures the multi-scale dynamics of rainfall by integrating signal decomposition with machine learning. The model's superior predictive accuracy over standalone ML and DL models underscores the value of a hybrid approach for processing complex, non-stationary hydrological data, a finding consistent with previous research (e.g., Diop et al., 2020; Yeditha et al., 2023; Jyostna et al., 2025).

The projections indicate a concerning 4% decline in the basin's mean annual rainfall, coupled with a significant spatial redistribution toward northern and central sub-basins. This pattern implies a substantial shift in the regional water balance, potentially increasing flood risks in receiving areas while exacerbating drought and water stress in the southern and western zones. These spatially heterogeneous changes highlight the urgent need for adaptive water resource management. Key strategies should include optimizing irrigation efficiency, updating reservoir operation rules, and revising agricultural cropping calendars to align with the new hydrological regime.

Despite its robust performance, this study is subject to the inherent uncertainties of climate projections and data-driven modeling. Future research should enhance model robustness by incorporating additional climatic predictors—such as temperature, and large-scale circulation indices like ENSO and NAO—as well as high-resolution satellite-based rainfall products to improve spatial representativeness.

In conclusion, the EEMD-SVM-LSTM model provides a powerful and generalizable framework for high-fidelity rainfall forecasting in semi-arid regions. It serves as a critical tool for informing climate-resilient planning and promoting sustainable water resource management in the Lake Urmia Basin and other similarly vulnerable ecosystems worldwide.

Keywords: Rainfall, Climate Change, Lake Urmia Basin, Hybrid Model, Deep Learning, Machine Learning, Time Series Forecasting, Water Resource Management.