



مدیریت آب و آبیاری

دوره ۹ ■ شماره ۲ ■ پاییز و زمستان ۱۳۹۸

صفحه‌های ۲۸۹-۲۷۷

ارزیابی مدل تلفیقی تجزیه مد تجربی یکپارچه کامل - گاوسی در پیش‌بینی زمانی و مکانی دبی رودخانه

معصومه چمنی^۱، کیومرث روشنگر^{۲*}

۱. دانشجوی کارشناسی ارشد مهندسی و مدیریت منابع آب، دانشکده عمران، دانشگاه تبریز، تبریز، ایران.

۲. استاد، گروه مهندسی آب، دانشکده عمران، دانشگاه تبریز، تبریز، ایران.

تاریخ پذیرش مقاله: ۱۳۹۸/۱۰/۲۶

تاریخ دریافت مقاله: ۱۳۹۸/۰۷/۲۲

چکیده

پیش‌بینی صحیح دبی روزانه رودخانه، ابزاری مناسب جهت برنامه‌ریزی و مدیریت منابع آب سطحی می‌باشد. از این‌رو در این مقاله با بهره‌گیری از مدل‌های رگرسیون فرآیند گاوسی (GPR)، ماشین یادگیری قدرتمند (ELM) و روش ترکیبی تجزیه مد تجربی یکپارچه کامل، دبی بین ایستگاهی رودخانه آرکانزاس واقع در ایالت متحده آمریکا مورد بررسی قرار گرفت. به این منظور ابتدا دبی روزانه و ماهانه با استفاده از روش رگرسیون فرآیند گاوسی و ماشین یادگیری قدرتمند پیش‌بینی شد. سپس سری زمانی اصلی توسط روش تجزیه مد تجربی یکپارچه کامل به زیرسری‌های توابع مد ذاتی (IMFs) و باقیمانده (Residual) تجزیه گردید؛ در ادامه این زیرسری‌های تجزیه‌شده، ورودی مدل‌های گاوسی و ماشین یادگیری قدرتمند را تشکیل دادند تا مدل‌های ترکیبی طراحی گردند. برای ارزیابی کارایی مدل‌ها از معیارهای همبستگی خطی (DC)، ریشه میانگین مربعات خطا (RMSE)، ضریب همبستگی (R) و میانگین درصد خطای مطلق (MAPE) استفاده شد. نتایج نشان داد که استفاده از روش CEEMD باعث بهبود عملکرد مدل‌های مورد استفاده شده است. به طوری که مقادیر خطای مطلق (MAPE) مربوط به مدل GPR با پیش‌پردازش CEEMD در پیش‌بینی جریان ایستگاه‌های اول، دوم و سوم نسبت به مدل GPR بدون پیش‌پردازش به ترتیب ۳۴، ۲۷ و ۳۲ درصد کاهش داشته است. همچنین تأثیر هر یک از زیرسری‌های تجزیه مد تجربی یکپارچه کامل در پیش‌بینی دبی مورد ارزیابی قرار گرفت. مشاهده گردید که زیرسری باقیمانده ناکارآمدترین زیرسری است. مدل ترکیبی CEEMD-ELM در مدیریت حوضه‌های آبخیز و کنترل سیل کشور ایران می‌تواند استفاده شود.

کلیدواژه‌ها: توابع مد ذاتی، دبی بین ایستگاهی، سری زمانی، مدل ترکیبی.

Evaluation of CEEMD- GPR hybrid Model in Temporal and Spatial Daily Stream Flow Forecasting

Masoumeh Chamani¹, Kiyoumars Roushangar^{2*}

1. M.Sc. Student, Water Resources Engineering and Management, Department of Water Engineering, Faculty of Civil Engineering, Tabriz University, Tabriz, Iran.

2. Professor, Department of Water Engineering, Faculty of Civil Engineering, Tabriz University, Tabriz, Iran.

Received: October 14, 2019

Accepted: January 16, 2020

Abstract

Accurate prediction of river daily discharge is a suitable tool for water resources planning and management. In this paper, cross station discharge of the Arkansas River in U.S.A, were examined using Gaussian Process Regression (GPR), Extreme Learning Machine (ELM) and complete ensemble empirical mode decomposition combined models. For this Purpose, in the first step, the daily and monthly discharge was predicted via GPR and ELM models. Then, the discharge time series were broken up by CEEMD method into cages, and these subclasses were introduced into the Gaussian process regression and ELM modeling to simulate discharge. Furthermore, direct correlation (DC), Root Mean Square Error (RMSE), correlation coefficient (R) and Mean Absolute Percentage Error (MAPE) were used to evaluate the efficiency of the models. The results showed that the CEEMD approach improved the performance of the above mentioned models dramatically. For instance, the values of MAPE correspond to GPR hybrid model in forecasting discharge in the first, second and third station with CEEMD pre-processing were reduced by 34, 27 and 32 percent, respectively, as compared to those in the GPR model without pre-processing. Also, the effect of each of the sub-series of ensemble empirical mode decomposition model (Residual and IMFs) was studied to improve predictive outcomes. It was observed that the most inefficient subseries in the complete ensemble empirical mode decomposition model is the residual subseries. The CEEMD- ELM model can be used in watershed management and flood control in Iran.

Keywords: Combined Model, Cross Station Discharge, Intrinsic Mod Functions, Time Series.

مقدمه

پیش‌بینی دقیق جریان از اهمیت فراوانی در منابع آب به‌ویژه برای برنامه‌ریزی و مدیریت منابع آب، عملیات هیدرولوژیکی و محیط زیست و غیره برخوردار است (۱۱، ۴، ۱۵). از طرفی باید اشاره نمود که رواناب یک پدیده غیرخطی بوده و دارای تغییرات زمانی و مکانی گسترده‌ای می‌باشد؛ در نتیجه به سادگی قابل مدل‌سازی نیست (۱۸). به دلیل ماهیت غیرخطی اکثر پدیده‌های هیدرولوژیکی، روش‌های هوش مصنوعی به‌طور گسترده‌ای در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی در فرآیندهای هیدرولوژیکی مورد استفاده قرار گرفته است (۱۶، ۲۴). از جمله روش‌های هوش مصنوعی، ماشین یادگیری قدرتمند (ELM)^۱ و رگرسیون فرآیند گاوسی (GPR)^۲ می‌باشند که اولی، یک نوع شبکه عصبی مصنوعی جدید و دومی نوعی روش مبتنی بر کرنل است (۲۲، ۱۴، ۱۹). در سال‌های اخیر مطالعات متعددی در زمینه استفاده از این روش‌های کارآمد به‌منظور تخمین دبی جریان استفاده شده است که در ادامه به معرفی آن‌ها پرداخته خواهد شد.

یاسین و همکاران (۲۴)، نرخ جریان ماهانه رودخانه دجله را با استفاده از روش ماشین یادگیری قدرتمند پیش‌بینی کردند و نتایج این روش جدید را با رگرسیون بردار پشتیبان (SVR)^۳ و شبکه عصبی مصنوعی عمومی (GRNN)^۴ مقایسه کردند به این نتیجه رسیدند که روش ELM از عملکرد بهتری نسبت به دو روش دیگر برخوردار است. لیما و همکاران (۱۷)، به پیش‌بینی جریان روزانه دو حوضه رودخانه در کانادا با استفاده از روش ماشین یادگیری قدرتمند پرداختند که نتایج آن‌ها نشان از توانایی این روش در پیش‌بینی جریان داشت. تائورمینا و همکاران (۲۲)، به

انتخاب متغیرهای ورودی جهت مدل‌سازی جریان روزانه با استفاده از الگوریتم ذرات بهینه پرداختند و با استفاده از روش ماشین یادگیری قدرتمند مدل‌سازی بارش - رواناب رودخانه کنتاکی را مورد بررسی قرار دادند. نتایج نشان‌دهنده زمان اجرای کم‌تر و دقت بالای مدل‌سازی بود. ژو و همکاران (۲۷) از مدل رگرسیون فرآیند گاوسی برای پیش‌بینی چند ماه بعد دبی رودخانه استفاده کردند. نتیجه گرفتند که روش رگرسیون فرآیند گاوسی با داشتن کم‌ترین میزان خطا و بیش‌ترین همبستگی از عملکرد مناسبی برخوردار است. گوی و چان (۸)، برای مدل‌سازی جریان از روش مبتنی بر کرنل رگرسیون بردار پشتیبان استفاده کردند.

با وجود توانایی بالای روش‌های هوشمند در تخمین پدیده‌های هیدرولوژیکی نظیر دبی جریان، برخی اوقات این روش‌ها منجر به نتیجه دلخواه و مناسب نمی‌شوند و نیاز به افزایش دقت این مدل‌ها می‌باشد (۵). وجود ویژگی‌هایی نظیر نویز، غیرخطی و غیرایستا بودن در بسیاری از پدیده‌های هیدرولوژیکی، به‌خصوص برآورد دبی، موجب پیچیدگی بیش‌تر این پدیده‌ها گشته و از طرف دیگر با توجه به داده‌گرا بودن این مدل‌ها، کیفیت و ویژگی خود این داده‌ها نیز از اهمیت بالایی برخوردار هستند (۳، ۹). از این‌رو پژوهش‌گران در سال‌های اخیر، از روش‌های پیش‌پردازش زمانی استفاده کردند (۱).

روش تجزیه مد تجربی (EMD)^۵ روشی کاملاً مؤثر استخراج سیگنال از داده‌ها می‌باشد و برای تجزیه سیگنال در حوزه زمان-فرکانس کاربرد دارد (۱۴). سانگ و همکاران (۲۱)، از روش EMD برای تحلیل داده‌های غیرخطی هیدرولوژی استفاده کردند. هوانگ و همکاران (۱۴)، برای پیش‌بینی جریان رودخانه سین در فرانسه از روش تجزیه مد تجربی استفاده کردند و سری زمانی دبی را به زیرسری‌های

1. Extreme Learning Machine
2. Gaussian Process Regression
3. Support Vector Regression
4. Generalized Regression Neural Network

مواد و روش‌ها

منطقه مورد مطالعه

منطقه مورد مطالعه در این تحقیق رودخانه آرکانزاس (واقع در ایالت متحده آمریکا)، یکی از شعب اصلی و پرآب رودخانه می‌سی‌سی‌پی می‌باشد که از کوه‌های راکی سرچشمه می‌گیرد. این رودخانه با داشتن طول ۲۳۲۲ کیلومتر و وسعت ۴۴۰۰۰۰ کیلومترمربع، ششمین رودخانه طویل ایالت متحده آمریکا و تأمین‌کننده اصلی آب آشامیدنی و کشاورزی مناطق وسیعی از ایالات ایالات کلرادو^۲، کانزاس^۳ و آرکانزاس می‌باشد. به‌طورکلی حوضه آبریز آرکانزاس به‌علت وجود پوشش‌های برفی دائمی در ارتفاعات مختلف آن دارای رژیم برفی بوده و ذوب برف در جریان دائمی آن مؤثر و قابل‌ملاحظه است. ریزش باران‌ها در فصل بهار شدید است و این اثر قابل‌توجهی در بالابردن مقدار دبی سالانه رودخانه دارد. از مسائل مهم در این حوضه، وقوع سیلاب‌های بزرگ می‌باشد که باعث مشکلات عدیده‌ای نظیر وارد آمدن خسارات به مزارع می‌شود.

شایان ذکر است که به‌منظور انجام این تحقیق از داده‌های روزانه و ماهانه دبی در بازه زمانی سال ۲۰۰۰ تا ۲۰۰۹ برای سه ایستگاه هیدرومتریک متوالی رودخانه آرکانزاس که از سایت زمین‌شناسی آمریکا^۴ استخراج شده است؛ به‌دلیل موقعیت ایستگاه‌ها و وجود داده کامل و هم‌چنین اهمیت آن در تأمین آب مناطق وسیعی از اطراف حوضه استفاده گردید. در جدول (۱) مشخصات ایستگاه‌ها آورده شده است. هم‌چنین در شکل (۱) موقعیت جغرافیایی رودخانه آرکانزاس آورده شده است. به‌منظور آموزش و صحت‌سنجی مدل، داده‌ها به دو قسمت به‌صورت سری زمانی تقسیم شده‌اند: ۷۵ درصد داده‌ها از اول به‌عنوان داده‌های آموزش و ۲۵ درصد باقیمانده به‌عنوان داده‌های آزمون انتخاب شده‌اند.

توابع مد ذاتی و باقیمانده تجزیه نمودند. در تحقیقی دیگر از ترکیب EMD با ANN در پیش‌بینی پدیده هیدرولوژیکی استفاده کردند (۲۵). روشنگر و چمنی (۲)، برای مدل‌سازی دبی - اشل از روش رگرسیون فرآیند گاوسی استفاده کردند و برای بهبود نتایج پیش‌بینی از روش تجزیه مد تجربی یکپارچه بهره بردند. آن‌ها نتیجه گرفتند که روش پیش‌پردازشی منجر به افزایش دقت مدل‌سازی می‌شود.

بررسی منابع نشان می‌دهد که پژوهش‌گران در مطالعات خود به بررسی عملکرد روش‌های هوش مصنوعی نظیر ماشین یادگیری قدرتمند و رگرسیون فرآیند گاوسی پرداخته‌اند و از مدل‌های ترکیبی نظیر الگوریتم بهینه ذرات و تجزیه مد تجربی برای بهبود دقت پیش‌بینی دبی استفاده کرده‌اند. اما تاکنون مطالعه مقایسه‌ای بین عملکرد روش‌های ELM و GPR در پیش‌بینی دبی انجام نشده است. هم‌چنین مطالعه‌ای در مورد مدل ترکیبی CEEMD-ELM برای پیش‌پردازش سری زمانی دبی و اثر زیرسری‌های حاصل از آن در نتایج پیش‌بینی صورت نگرفته است.

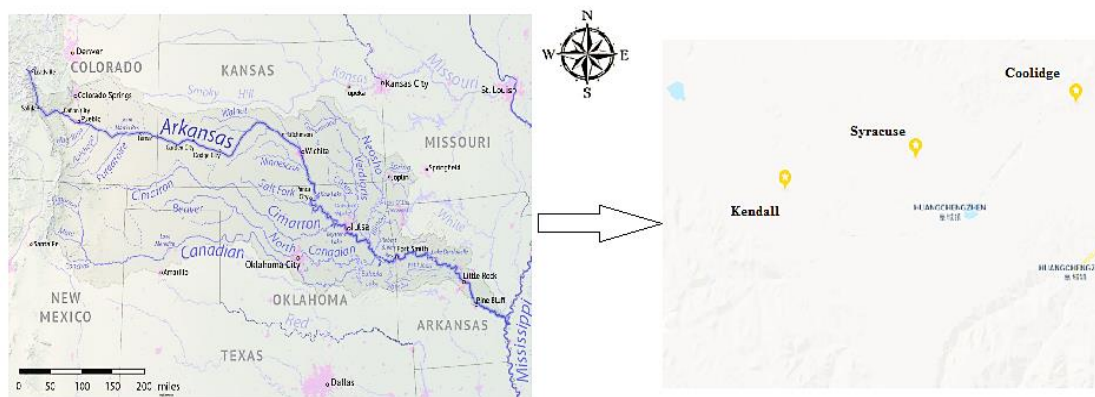
هدف از پژوهش حاضر تخمین دبی روزانه و ماهانه رودخانه آرکانزاس با استفاده از روش‌های ماشین یادگیری قدرتمند (ELM) و رگرسیون فرآیند گاوسی (GPR) می‌باشد. در ضمن تلاش شد که با اعمال روش پیش‌پردازشی نوظهور تجزیه مد تجربی یکپارچه کامل (CEEMD)^۱، دقت مدل‌های ELM و GPR افزایش یابد که نشان از نوآوری تحقیق دارد. هم‌چنین برای اولین بار در این تحقیق، اثر تمام فرکانس‌های حاصل از روش تجزیه مد تجربی یکپارچه کامل در مدل‌سازی‌های صورت‌گرفته در نظر گرفته شد و آنالیز چندمقیاسی انجام گرفت. در انتها نیز همه مدل‌ها (GPR, ELM, CEEMD-ELM و GPR) براساس معیارهای رایج نیکویی برازش با یکدیگر مقایسه شده‌اند.

2. Colorado
3. Kansas
4. United States Geological Survey

1. Complete Ensemble Empirical Mod Decomposition

جدول ۱. مشخصات ایستگاه‌های رودخانه آرکانزاس

ایستگاه هیدرومتریک	شماره ایستگاه	مقیاس زمانی	پیش‌ترین دبی (مترمکعب بر ثانیه)	کم‌ترین دبی (مترمکعب بر ثانیه)	انحراف استاندارد داده‌ها (مترمکعب بر ثانیه)
ایستگاه اول	۰۷۱۳۷۵۰۰	روزانه	۳۵/۳۹	۰/۰۰۷	۴/۵۳
		ماهانه	۶۹۴/۱۶	۶/۷۹	۱۴۱/۳۸
ایستگاه دوم	۰۷۱۳۸۰۰	روزانه	۲۷/۸۳	۰/۰۳۳	۳/۹۹
		ماهانه	۶۴۸	۱/۳۰	۱۲۸/۴۰
ایستگاه سوم	۰۷۱۳۸۰۲۰	روزانه	۲۷/۸۶	۰/۰۰۷	۳/۵۹
		ماهانه	۶۵۶/۶۰	۰/۴۲	۱۱۹/۱۸



شکل ۱. موقعیت جغرافیایی رودخانه آرکانزاس

سناریوهای تعریف‌شده

در مدل‌سازی‌های مطالعه حاضر، جریان روزانه و ماهانه به‌عنوان متغیر وابسته در نظر گرفته شد و بر این اساس دو سناریو برای تشکیل مدل‌های پیش‌بینی رواناب اتخاذ گردید. در سناریوی اول دبی جریان در تک‌تک ایستگاه‌ها به‌صورت مجزا بررسی شد. در سناریوی دوم به ارزیابی و امکان‌سنجی ارتباط دبی جریان بین سه ایستگاه هیدرومتریک متوالی پرداخته شد. به این ترتیب که برای پیش‌بینی دبی ایستگاه پایین‌دست از داده‌های دبی ایستگاه بالادست استفاده شد. به این منظور از داده‌های دبی جریان ایستگاه اول به‌عنوان ورودی جهت تخمین دبی جریان در ایستگاه دوم استفاده شد و برای پیش‌بینی

دبی ایستگاه سوم از داده‌های دبی ایستگاه دوم در روزهای قبل استفاده شد. ذکر این نکته نیز ضروری است که دبی جریان امروز به‌عنوان متغیر پیش‌بینی‌شونده و خروجی و دبی جریان یک روز تا چهار روز قبل نیز به‌عنوان ورودی‌های مدل‌سازی در نظر گرفته شدند. برای نمونه، جهت پیش‌بینی دبی ایستگاه دوم، $Q(t)_2 = [Q(t-1)_1, (Q(t-2)_1, \dots, Q(t-4)_1]$ ورودی‌های مدل را تشکیل دادند. اندیس‌های استفاده‌شده بیانگر شماره ایستگاه می‌باشند.

روش تجزیه مد تجزیه (EMD)

EMD روشی برای تجزیه سیگنال‌های گوناگون است که این عمل در فرآیندی تحت عنوان غربال‌کردن صورت

$$r_1(n) = x(n) - \text{imf}_1(n) \quad (3)$$

در این رابطه، $X(n)$ داده اصلی و IMF_1 تابع مد ذاتی اول می‌باشد.

مرحله پنجم: چنانچه باقیمانده دارای حداقل دو فرین باشد، مراحل اول تا پنجم تکرار می‌شود. در غیر این صورت الگوریتم متوقف می‌شود و آخرین باقیمانده در حکم باقیمانده سیگنال در نظر گرفته می‌شود.

رگرسیون فرایند گاوسی (GPR)

فرایند گاوسی مجموعه‌ای از متغیرهای تصادفی است که تعداد محدودی از آن‌ها با توزیع‌های گاوسی ادغام شده‌اند که تعمیمی از توزیع گاوسی می‌باشد. توزیع گاوسی در واقع توزیع بین متغیرهای تصادفی بوده درحالی‌که فرایند گاوسی بیانگر توزیع بین توابع می‌باشد. فرایند گاوسی $f(x)$ توسط توابع میانگین $m(x)$ و کواریانس به شکل زیر تعریف می‌شود:

$$m(x) = E(f(x)) \quad (4)$$

$$k(x, x') = E((f(x) - m(x))(f(x') - m(x')))) \quad (5)$$

در روابط ۴ و ۵، $k(x, x')$ تابع کواریانس (یا کرنل) بوده که در نقاط x و x' محاسبه می‌شود.

$$f(x) \sim GP(m(x), k(x, x')) \quad (6)$$

در این رابطه، $f(x)$ نشان‌دهنده فرایند گاوسی می‌باشد که معمولاً جهت ساده‌سازی، مقدار تابع میانگین برابر با صفر در نظر گرفته می‌شود. در فرایند گاوسی، رابطه بین بردار ورودی و هدف به فرم زیر می‌باشد:

$$y_i = f(x_i) + \varepsilon \quad (7)$$

در این روابط، ε مقدار نویز توزیع گاوسی با میانگین صفر و واریانس σ^2 می‌باشد، یعنی $\varepsilon \sim N(0, \sigma^2)$.

در این تحقیق از روش رگرسیون فرایند گاوسی با استفاده از نرم‌افزار متلب، جهت تخمین دبی درون ایستگاهی

می‌گیرد. طی این فرایند سیگنال اصلی به تعدادی مؤلفه با محتوای بسامدی متفاوت تجزیه می‌شود (۶، ۲۳).

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

در این رابطه، $r_n(x)$ همان مؤلفه باقیمانده، بعد از n تعداد IMFs و $c_i(x)$ است، که IMFs همان توابع مد ذاتی و $c_i(x)$ تابع موج شکل (هارمونیک) استخراج شده از سیگنال اصلی که شرایط تابع مد ذاتی را ندارد. یک داده ممکن است در یک زمان دارای چندین مد ذاتی باشد. این مدهای نوسانی، تابع‌های مد ذاتی (IMF) نام دارد و دارای شرایط زیر هستند:

۱. در کل داده، تعداد نقاط فرین (اکسترمم) و نقاط صفر با هم برابر و یا حداکثر دارای یک واحد اختلاف هستند.

۲. در هر نقطه میانگین پوش برازش داده شده بر نقاط بیشینه محلی و پوش برازش داده شده بر نقاط کمینه محلی باید صفر باشد.

مراحل تجزیه سری زمانی جهت استخراج اطلاعات فرکانسی و حذف روند برای غلبه بر ناپایداری (برای رهگیری خواص گذرا و نوسانات کوتاه‌مدت سری) مطابق مراحل ذیل می‌باشد.

مرحله اول: تعیین نقاط بیشینه و کمینه محلی سیگنال $x(n)$

مرحله دوم: محاسبه میانگین پوش بالا و پایین با نام $m_1(x)$ با روش اسپلاین درجه سه^۱.

مرحله سوم: محاسبه اختلاف میان داده و میانگین پوش بالا و پایین مطابق رابطه (۲).

$$h_1(n) = x(n) - m_1(x) \quad (2)$$

در این رابطه، $X(n)$ داده اصلی و $m_1(x)$ میانگین پوش بالا و پایین منحنی می‌باشد.

مرحله چهارم: محاسبه باقیمانده مطابق رابطه (۳).

1. Cubic spline

$$h(X_i)\beta = Y_i^T, i=1,2,\dots, N \quad (9)$$

که در این روابط $g(x)$ تابع فعال‌سازی پنهان لایه ELM، β وزن بین خروجی و لایه پنهان، W وزن بین لایه پنهان و لایه ورودی و b بایاس نرون پنهان هستند. برای اجرای روش ماشین یادگیری قدرتمند از نرم‌افزار متلب استفاده شد که ۷۵ درصد داده‌ها برای آموزش و ۲۵ درصد بقیه نیز برای دسته آزمون انتخاب گردید. پارامترهای تعداد لایه ورودی، میانی و خروجی نیز با آزمون و خطا تعیین گردید که برای بهترین ترکیب ورودی (مدل چهارم)، تعداد لایه ورودی برابر چهار، تعداد لایه میانی برابر ۱۵ و تعداد لایه خروجی نیز یک انتخاب شد.

مدل ترکیبی CEEMD با GPR و ELM

مدل ترکیبی تجزیه مد تجربی یکپارچه کامل، با استفاده از کدنویسی در نرم‌افزار متلب، برای پیش‌بینی دبی طراحی گردید. الگوریتم CEEMD تا زمانی که باقیمانده بیش‌تر از سه اکستریم داشته باشد تحلیل داده‌ها را انجام می‌دهد. در این مدل نخست سری‌های زمانی رواناب به زیرسری‌هایی با فرکانس‌های متفاوت تجزیه می‌شوند. به‌عنوان نمونه می‌توان سری زمانی را به یک جز فرکانس بالا (IMF1) و چند جز فرکانس پایین (IMF2, IMF3, ..., IMFn-1, Residual)، برای رهگیری خواص گذرا و نوسانات کوتاه‌مدت سری تجزیه نمود. لازم به توضیح است که روش تجزیه مد تجربی یکپارچه کامل با حذف روند موجود در سری‌های زمانی به غلبه بر نایستایی می‌پردازد و دقت پیش‌بینی را بهبود می‌دهد. در تحقیق حاضر، نوفه سفید با دامنه $0/2$ انحراف سری زمانی دبی مورد استفاده قرار گرفته است. ES^2 (اندازه گروه) برابر با ۵۰۰ برابر هر عضو، گروه CEEMD انتخاب شده است (انتخاب از طریق سعی و خطا و مقایسه با مقادیر پیشنهادی استفاده‌شده در منابع). سری‌های زمانی طی

و بین ایستگاهی با استفاده از داده‌های پیش‌پردازش نشده، استفاده گردید. بعد از این که داده‌ها از نظر کیفیت و کمیت کنترل شدند؛ وارد مدل گاوسی شدند. میزان کارایی این روش تا حد زیادی به انتخاب تابع کرنل مناسب و هم‌چنین تعیین بهینه پارامترهای مربوطه بستگی دارد. در میان پژوهش‌های انجام‌شده در مقوله پیش‌بینی جریان و سایر مطالعات مهندسی آب، کرنل تابع پایه شعاعی^۱ به‌مثابه بهترین انتخاب از بین دیگر توابع کرنل گزارش شده است (۸، ۲۶، ۲۷). بنابراین در تحقیق حاضر از تابع یادشده به‌عنوان تابع کرنل استفاده شد. انتخاب تابع کرنل، به نوع پارامتر پیش‌بینی‌شونده بستگی دارد. برای پدیده‌هایی که رفتار خطی دارند تابع کرنل خطی و چندجمله‌ای مناسب است و برای پدیده‌های هیدرولوژیکی که اکثراً رفتار غیرخطی دارند تابع کرنل پایه شعاعی محور مناسب می‌باشد.

ماشین یادگیری قدرتمند (ELM)

ELM نوعی الگوریتم با درصد زیاد و آسان به لحاظ پیاده‌سازی است که نخستین بار توسط هوانگ و همکارانش پیشنهاد شد (۱۳). این روش برای غلبه بر ضعف‌های روش‌های یادگیری سنتی مانند الگوریتم‌های آموزش محور مبتنی بر تبادل گرادینان به‌وجود آمده است که شامل سه لایه ورودی، پنهان و خروجی است. در واقع نوعی روش یادگیری برای آموزش شبکه ANN است که به‌طور تصادفی وزن‌های ورودی (W) و بایاس (b) را تولید می‌کند (۱۰).

برای N نمونه یادگیری مختلف $(X_i, Y_j) \in R^n \times R^m$ و $(i = 1, 2, \dots, N)$ ، خروجی لایه مخفی می‌تواند به‌صورت رابطه (۸) و خروجی نرون در لایه خروجی می‌تواند به‌صورت رابطه ۹ بیان شود (۱۰).

$$h = g(WX + b) \quad (8)$$

میانگین مطلق (MAPE)°. هر چه مقدار R و DC برای یک مدل به یک نزدیک‌تر و مقدار RMSE و MAPE کوچک‌تر باشد به معنی مطلوب بودن آن مدل است. روابط این پارامترهای آماری به صورت زیر می‌باشد:

$$R = \frac{\sum_{i=1}^N (Q_o - \bar{Q}_o) \times (Q_p - \bar{Q}_p)}{\sqrt{\sum_{i=1}^N (Q_o - \bar{Q}_o)^2 \times (Q_p - \bar{Q}_p)^2}} \quad (10)$$

$$DC = 1 - \frac{\sum_{i=1}^N (Q_o - Q_p)^2}{\sum_{i=1}^N (Q_o - \bar{Q}_p)^2}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Q_o - Q_p)^2}{N}}$$

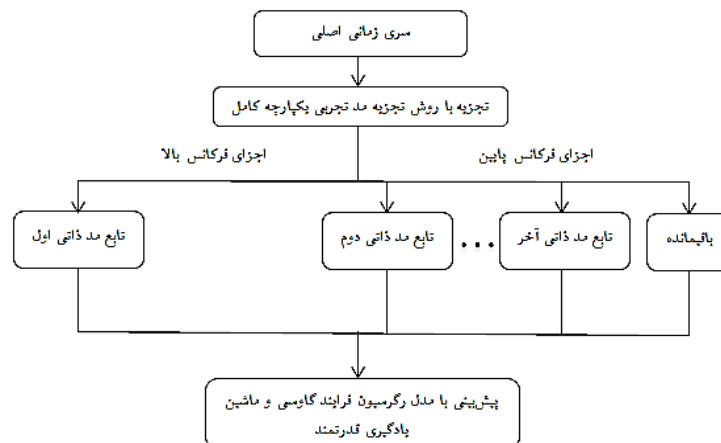
$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Q_o - Q_p}{Q_p} \right| \times 100$$

در این روابط، Q_o : دبی اندازه‌گیری شده، \bar{Q}_o : متوسط دبی اندازه‌گیری شده Q_p : دبی پیش‌بینی شده، \bar{Q}_p : متوسط دبی پیش‌بینی شده و N : تعداد داده‌هاست.

سال‌های ۲۰۰۹-۲۰۰۰ به ۱۲ زیرسری (IMF و Residual) تجزیه شدند. IMF1 تا IMF11 توابع مد ذاتی هستند و IMF12 زیرسری باقیمانده است که نشان‌دهنده روند می‌باشد. در این قسمت با استفاده از روش تجزیه مد تجربی یکپارچه کامل، ابتدا سری زمانی اصلی به زیرسری‌هایی تجزیه گردید. سپس مجموع زیرسری‌های به‌دست‌آمده به‌عنوان ورودی به مدل‌های GPR و ELM داده شد تا مدل‌های ترکیبی CEEMD-GPR و CEEMD-ELM طراحی گردند. شماتیک مدل ترکیبی به‌کاربرده‌شده در تحقیق حاضر در شکل (۲) ارائه شده است.

معیار ارزیابی

به‌منظور ارزیابی کارایی روش‌های استفاده‌شده در مدل‌سازی سری زمانی دبی جریان، از چهار پارامتر آماری استفاده گردید که عبارتند از: ضریب همبستگی بین مقادیر مشاهداتی و محاسباتی (R)^۲، همبستگی خطی (DC)^۳، ریشه میانگین مربعات خطا (RMSE)^۴ و درصد خطای



شکل ۲. شماتیک مدل‌سازی صورت گرفته در تحقیق

1. Intrinsic Mod Functions
2. Correlation Coefficient
3. Determination Coefficient
4. Root Mean Square Errors
5. Mean Absolute Percentage Error

نتایج و بحث

تعیین مدل‌های ورودی

با توجه به این که انتخاب مدل‌های ورودی در سیستم‌های هوشمند می‌تواند بر روی دقت جواب‌های حاصل از تحلیل تأثیرگذار، لذا سعی گردید در مدل‌سازی رگرسیون فرآیند گاوسی، ماشین یادگیری قدرتمند و مدل‌های تلفیقی، ورودی‌های مناسب و مؤثر در تخمین دبی هر یک از ایستگاه‌ها و دبی بین ایستگاهی انتخاب گردد. در این تحقیق مدل‌های متفاوتی با استفاده از داده‌های دبی با تأخیر زمانی، برای مقیاس زمانی روزانه و ماهانه به صورت جدول ۲ تعریف گردید. در این مدل‌ها، $Q(t)$: سری زمانی دبی امروز برای مقیاس زمانی روزانه، $Q(t-1)$: سری زمانی دبی یک روز قبل و به همین ترتیب دبی تا گام زمانی چهار روز قبل مشخص شده است. برای مقیاس زمانی ماهانه نیز به همین ترتیب می‌باشد.

جدول ۲. ترکیب مدل‌های ورودی

مدل	خروجی	ورودی مدل
I(I)	$Q(t)$	$Q(t-1)$
I(II)	$Q(t)$	$Q(t-1), Q(t-2)$
I(III)	$Q(t)$	$Q(t-1), Q(t-2), Q(t-3)$
I(IV)	$Q(t)$	$Q(t-1), Q(t-2), Q(t-3), Q(t-4)$

نتایج مدل‌سازی با روش‌های (ELM و GPR)

جهت پیش‌بینی دبی جریان، چهار مدل براساس سری زمانی دبی با تأخیر زمانی چهار گام زمانی قبل تعریف گردید و کارایی روش‌های مذکور مورد ارزیابی قرار گرفت. در اجرای مدل گاوسی و ماشین یادگیری قدرتمند ۷۵ درصد داده‌ها به عنوان داده‌های دسته آموزش و ۲۵ درصد باقیمانده به عنوان داده‌های دسته آزمون و صحت‌سنجی (هفت سال اول برای آموزش و سه سال آخر برای آزمون) در نظر گرفته شد. مدل‌های تعریف‌شده با هر دو روش GPR و ELM آنالیز گردید و نتایج بهینه حاصله برای سناریوی اول و دوم به ترتیب در جدول‌های (۳) و (۴) ارائه گردید. با توجه به

نتایج به دست آمده از چهار معیار ارزیابی مدل، برای هر سه ایستگاه مشاهده می‌شود که در حالت مدل‌سازی دبی درون‌ایستگاهی و بین ایستگاهی مدل I(IV) با پارامترهای ورودی $Q(t-1), Q(t-2), Q(t-3), Q(t-4)$ بیش‌ترین کارایی را دارا است. با مقایسه مدل‌ها به این نتیجه رسیدیم که افزایش تعداد پارامترهای ورودی دقت مدل‌ها را تا حدود زیادی افزایش می‌دهد. همچنین برای سناریوی اول، می‌توان مشاهده کرد که ضریب تبیین برای مرحله آزمون روش ELM، ۰/۹۴ و در روش GPR، ۰/۹۱ است. دیگر پارامترهای خطا یعنی RMSE و MAPE در روش ELM به ترتیب ۰/۰۳۶ و ۶/۸۰ و در روش GPR به ترتیب ۰/۰۳۸ و ۷/۶۰ هستند که این نتایج نشان‌دهنده برتری روش ELM در تخمین دبی روزانه می‌باشند. نکته دیگری که می‌توان به آن اشاره داشت تفاوت دقت مدل‌ها در دو مقیاس روزانه و ماهانه می‌باشد. واضح است که در مقیاس روزانه مدل‌های ساده استفاده شده (ELM, GPR) با تعداد نمونه ورودی به مراتب بیش‌تری نسبت به مقیاس ماهانه سروکار دارند. همین امر سبب می‌شود تا مدل‌ها آموزش بهتری در کالیبراسیون داشته باشند و دقت مدل‌ها در مقیاس روزانه نسبت به مقیاس ماهانه افزایش یابد. با دقت در نتایج جدول‌های (۳) و (۴) به این نتیجه می‌رسیم که سناریوی دوم با داشتن ضریب همبستگی و خطی بیش‌تر و خطای کم‌تر نسبت به سناریوی اول در تخمین رواناب روزانه و ماهانه موفق‌تر بوده است.

نتایج مدل‌سازی با روش‌های تلفیقی (CEEMD-GPR و CEEMD-ELM)

با توجه به عملکرد نه‌چندان مطلوب مدل‌های GPR و ELM لزوم یک پیش‌پردازش مناسب (تجزیه مد تجزیه ی‌کپارچه کامل)، جهت بهبود عملکرد مدل‌های ساده ضروری دانسته شد. در واقع تجزیه مد تجزیه ی‌کپارچه کامل با تجزیه‌نمودن سری‌های زمانی اصلی به چندین

با هم تفاوت دارند. در مقیاس روزانه علاوه بر زیادبودن تعداد نمونه داده‌های ورودی، داده‌ها ممکن است دارای شوک باشند (یعنی مقادیر دبی در اثر عواملی نظیر بارش شدید به‌طور ناگهانی افزایش یابد). در مقیاس ماهانه علاوه بر تعداد کم نمونه‌ها به نسبت مقیاس روزانه، دارای ماهیت فصلی می‌باشند (مقدار دبی در یک ماه خاص بیش‌ترین ارتباط را با مقدار دبی همان ماه در سال قبل دارد). از این‌رو مدل CEEMD-GPR یا CEEMD-ELM به‌واسطه بهره‌مندی از تجزیه مد تجربی یکپارچه کامل و حذف روند موجود، هم بر شوک و هم بر فصلی‌بودن غلبه می‌نماید؛ از این‌رو در هر دو مقیاس عملکرد قابل قبولی دارد. نکته حائز اهمیت، افزایش تعداد داده‌های ورودی با اعمال روش پیش‌پردازشی است. علی‌رغم افزایش دقت مدل، حجم محاسبات به‌طور چشم‌گیری نیز افزایش یافته که به‌تبع آن زمان انجام محاسبات به‌طور فزاینده‌ای افزایش می‌یابد.

زیرسری (در این تحقیق تعداد زیرسری‌های تجزیه‌شده ۱۲ عدد است که شامل یک زیرسری باقیمانده و ۱۱ زیرسری تابع مد ذاتی می‌باشد) اقدام به حذف روند موجود در سری‌های زمانی برای غلبه بر نایستایی می‌پردازد. به‌عبارت خیلی ساده‌تر تجزیه مد تجربی یکپارچه کامل با بهره‌بردن از اصل جمع آثار قوا سری زمانی پیچیده را به چند زیرسری ساده تجزیه می‌نماید که برآیند همگی این زیرسری‌ها، سری زمانی اصلی می‌باشد (۲۹). متعاقباً با اعمال روش پیش‌پردازشی، افزایش دقت مدل و بهبود کارایی آن دور از انتظار نیست که با توجه به جدول‌های (۵) و (۶) شاهد آن هستیم (DC_{CEEMD}) $(DC_{GPR})_{Train or Test} > (GPR)_{Train or Test}$. از این‌رو مدل‌های هیبریدی تجزیه مد تجربی یکپارچه کامل - گاوسی و ماشین یادگیری قدرتمند به‌مراتب از مقبولیت بیشتری در مطالعه دبی برخوردار هستند. در بررسی دبی جریان در دو مقیاس روزانه و ماهانه، شایان ذکر است ماهیت داده‌ها

جدول ۳. معیارهای ارزیابی برای پیش‌بینی دبی روزانه و ماهانه مرحله آزمون با روش‌های GPR و ELM (سناریوی اول)

مقیاس زمانی	مدل	ایستگاه اول				ایستگاه دوم				ایستگاه سوم			
		MAPE	RMSE (m ³ /s)	DC	R	MAPE	RMSE (m ³ /s)	DC	R	MAPE	RMSE (m ³ /s)	DC	R
روزانه	GPR	۱۱/۰۳	۰/۰۵۰	۰/۶۹	۰/۸۸	۷/۶۰	۰/۰۳۸	۰/۹۱	۰/۹۳	۱۰/۹۴	۰/۰۴۹	۰/۸۷	۰/۹۱
	ELM	۱۰/۸۷	۰/۰۴۸	۰/۷۱	۰/۸۹	۶/۸۰	۰/۰۳۶	۰/۹۴	۰/۹۵	۱۰/۰۱	۰/۰۴۷	۰/۸۸	۰/۹۳
ماهانه	GPR	۱۳/۴۸	۰/۰۶۱	۰/۵۹	۰/۶۶	۹/۹۱	۰/۰۴۵	۰/۷۶	۰/۸۱	۱۲/۸۹	۰/۰۵۷	۰/۶۸	۰/۷۹
	ELM	۱۲/۸۷	۰/۰۵۹	۰/۶۱	۰/۶۷	۹/۲۱	۰/۰۴۲	۰/۷۷	۰/۸۳	۱۲/۰۵	۰/۰۵۵	۰/۷۰	۰/۸۰

جدول ۴. معیارهای ارزیابی برای پیش‌بینی دبی روزانه و ماهانه مرحله آزمون با روش‌های GPR و ELM (سناریوی دوم)

مقیاس زمانی	مدل	هدف: ایستگاه دوم				هدف: ایستگاه سوم			
		MAPE	RMSE (m ³ /s)	DC	R	MAPE	RMSE (m ³ /s)	DC	R
روزانه	GPR	۸/۱۹	۰/۰۴۵	۰/۹۳	۰/۹۴	۷/۸۱	۰/۰۴۳	۰/۹۴	۰/۹۶
	ELM	۸/۰۳	۰/۰۴۳	۰/۹۴	۰/۹۴	۶/۵۸	۰/۰۳۶	۰/۹۵	۰/۹۷
ماهانه	GPR	۱۱/۲۱	۰/۰۶۹	۰/۶۰	۰/۷۳	۱۰/۲۱	۰/۰۶۴	۰/۶۴	۰/۷۵
	ELM	۱۰/۶۷	۰/۰۶۸	۰/۶۲	۰/۷۵	۹/۹۱	۰/۰۶۱	۰/۶۷	۰/۷۶

جدول ۵. معیارهای ارزیابی برای پیش‌بینی دبی مرحله آزمون با روش‌های CEEMD-GPR و CEEMD-ELM (سناریوی اول)

ایستگاه سوم				ایستگاه دوم				ایستگاه اول				مدل	مقیاس زمانی
MAPE	RMSE (m ³ /s)	DC	R	MAPE	RMSE (m ³ /s)	DC	R	MAPE	RMSE (m ³ /s)	DC	R		
۶/۳۸	۰/۰۳۰	۰/۹۵	۰/۹۶	۵/۵۱	۰/۰۲۶	۰/۹۷	۰/۹۸	۷/۲۰	۰/۰۳۲	۰/۹۴	۰/۹۵	CEEMD- GPR	روزانه
۵/۹۶	۰/۰۲۸	۰/۹۷	۰/۹۷	۴/۹۲	۰/۰۲۴	۰/۹۸	۰/۹۸	۶/۹۷	۰/۰۳۰	۰/۹۴	۰/۹۶	CEEMD- ELM	
۷/۷۹	۰/۰۴۰	۰/۹۰	۰/۹۱	۶/۷۶	۰/۰۳۳	۰/۹۰	۰/۹۲	۸/۹۱	۰/۰۴۲	۰/۸۹	۰/۹۰	CEEMD- GPR	ماهانه
۷/۱۲	۰/۰۳۹	۰/۹۱	۰/۹۲	۶/۳۱	۰/۰۳۱	۰/۹۲	۰/۹۴	۸/۱۲	۰/۰۴۱	۰/۹۰	۰/۹۲	CEEMD- ELM	

جدول ۶. معیارهای ارزیابی برای پیش‌بینی دبی مرحله آزمون با روش‌های CEEMD-GPR و CEEMD-ELM (سناریوی دوم)

هدف: ایستگاه سوم				هدف: ایستگاه دوم				مدل	مقیاس زمانی
MAPE	RMSE (m ³ /s)	DC	R	MAPE	RMSE (m ³ /s)	DC	R		
۶/۰۱	۰/۰۲۸	۰/۹۶	۰/۹۸	۷/۰۵	۰/۰۲۹	۰/۹۶	۰/۹۶	CEEMD- GPR	روزانه
۵/۷۹	۰/۰۲۵	۰/۹۸	۰/۹۹	۶/۸۹	۰/۰۲۷	۰/۹۸	۰/۹۸	CEEMD- ELM	
۸/۰۴	۰/۰۴۰	۰/۷۶	۰/۸۳	۸/۹۲	۰/۰۴۲	۰/۷۴	۰/۸۲	CEEMD- GPR	ماهانه
۷/۲۰	۰/۰۳۹	۰/۷۹	۰/۸۶	۸/۰۵	۰/۰۴۰	۰/۷۷	۰/۸۴	CEEMD- ELM	

مشاهداتی مربوط به مقیاس روزانه و ماهانه جهت درک شهودی توضیحات بیان شده و نیز گراف‌های پراکندگی دبی مشاهداتی و محاسباتی در هر دو مقیاس مذکور در شکل (۳) ارائه گردیده است.


مقیاس روزانه و ماهانه

جهت بررسی تأثیر تمام فرکانس‌های حاصل از تجزیه مد تجربی یکپارچه کامل (IMFs و Residual) در نتایج مدل برتر سناریوی اول، آنالیز حساسیت انجام گرفت. برای این منظور با حذف تک‌تک زیرسری‌های مدل برتر و اجرای دوباره مدل و تعیین معیارهای ارزیابی RMSE و MAPE، میزان تأثیر پارامتر حذف‌شده در کاهش دقت مدل مورد بررسی قرار گرفت. نتایج حاصل از آنالیز حساسیت به‌صورت شکل (۴) ارائه گردیده است. همان‌طورکه از شکل مشخص است با حذف زیرسری باقیمانده دقت مدل تا حدودی کاهش یافته است. بنابراین، می‌توان نتیجه گرفت که زیرسری باقیمانده ناکارآمدترین زیرسری و زیرسری IMF₁ مؤثرترین زیرسری در مدل‌سازی دبی می‌باشند.


با دقت در جدول‌ها (سناریوی اول)، مشاهده می‌شود که تأثیر روش پیش‌پردازشی بر کاهش خطای مدل GPR در مقیاس روزانه برابر ۲۷ تا ۳۴ درصد و در مقیاس ماهانه برابر ۳۱/۷۸ تا ۳۹/۵۶ درصد بوده است. هم‌چنین تأثیر روش پیش‌پردازشی بر کاهش خطای مدل ELM در مقیاس روزانه برابر ۲۸ تا ۴۰/۴۵ درصد و در مقیاس ماهانه برابر ۳۱/۴۸ تا ۴۰/۹۱ درصد بوده است و برای سناریوی دوم، استفاده از روش ترکیبی نسبت به مدل‌های گاوسی و ماشین یادگیری قدرتمند در مقیاس زمانی روزانه، به‌ترتیب مقدار خطا را تقریباً ۷ تا ۱۴ و ۱۲ تا ۱۴/۱۹ درصد کاهش داده است. برای مقیاس ماهانه نیز به‌ترتیب مقدار خطا را تقریباً ۲۰/۴۲ تا ۲۱/۲۵ و ۲۶/۵۵ تا ۲۷/۸۵ درصد کاهش داده است. هم‌چنین تأثیر افزایش دقت توسط روش CEEMD برای سناریوی دوم کم‌تر از سناریوی اول است. به‌عبارتی هر چقدر دقت مدل‌های ساده در تخمین دبی کم‌تر باشد؛ روش پیش‌پردازشی مذکور تأثیر بیشتری در افزایش دقت مدل‌سازی را دارا می‌باشد.

در ادامه گراف مربوط به سری‌های زمانی محاسباتی از طریق مدل‌های CEEMD-ELM و ELM و سری زمانی

ارزیابی مدل تلفیقی تجزیه مد تجربی یکپارچه کامل - گاوسی در پیش‌بینی زمانی و مکانی دبی رودخانه



شکل ۳. سری زمانی دبی مشاهداتی و محاسباتی و گراف پراکندگی ایستگاه سوم (سناریوی دوم)، در



شکل ۴. تأثیر نسبی هریک از زیرسری‌های روش CEEMD برای مدل برتر ایستگاه اول (مقیاس روزانه)

نتیجه‌گیری

که نشان‌دهنده توانایی روش ترکیبی هوش مصنوعی با روش پیش‌پردازشی، نسبت به روش‌های ساده هوش مصنوعی می‌باشد؛ همسو با یافته‌های پژوهش‌گرانی از جمله بای و همکاران (۷) و روشنگر و علیزاده (۲۰) می‌باشد. همان‌طور که قبلاً ذکر گردید در سناریوی اول، تأثیر روش پیش‌پردازشی بر کاهش خطای مدل GPR در مقیاس روزانه برابر ۲۷ تا ۳۴ درصد و در مقیاس ماهانه برابر ۳۱/۷۸ تا

در تحقیق کنونی از مدل گاوسی و ماشین یادگیری قدرتمند برای پیش‌بینی دبی درون‌ایستگاهی و بین‌ایستگاهی رودخانه آرکانزاس در مقیاس زمانی روزانه و ماهانه استفاده شده است و در نهایت اثر تجزیه مد تجربی یکپارچه‌ی کامل به‌عنوان مدل‌های پیشنهادی ترکیبی مد تجربی - گاوسی و ماشین یادگیری قدرتمند مورد بررسی قرار گرفتند. نتایج این تحقیق

مدل هیبرید موجک و شبکه عصبی؛ مطالعه موردی ایستگاه هیدرومتری ونیاز در حوضه آبریز آجی چای. مهندسی آبیاری و آب ایران. ۲(۱۴): ۱۱۳-۱۲۸.

۴. مساعدی، ا.، نبی‌زاده، م.، و دهقانی، ا. (۱۳۹۱). تخمین هوشمند دبی روزانه با بهره‌گیری از سامانه استنباط فازی-عصبی تطبیقی. مدیریت آب و آبیاری. ۲(۱): ۸۰-۶۹.

۵. نورانی، و. (۱۳۹۴). مبانی هیدروانفورماتیک، انتشارات دانشگاه تبریز، تبریز، ۶۲۵ صفحه.

6. Amirat, Y., Benbouzid, M.E.H., Wang, T., Bacha, K. & Feld, G. (2018). Ensemble Empirical Mod Decomposition-based notch filter for induction machine bearing faults detection. *Applied Acoustics*, 133, 202-209.
7. Bai, Y., Wang, P., Xie, J. J., Li, J. T. & Li, C. (2015). An additive model for monthly reservoir inflow forecast. *Hydrologic Engineering*, 20 (7), 1943-1955.
8. Choy, K. Y. & 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.
9. Danandeh Mehr, A., Nourani, V., Hrnjica, B. & Molajou, A. (2017). A binary genetic programming model for teleconnection identification between global sea surface temperature and local maximum monthly rainfall events. *Hydrology*, 555, 397-406.
10. Ding, S., Guo, L. & Hou, Y. (2017). Extreme learning machine with kernel model based on deep learning. *Neural Computing and Applications*, 28(8), 1975-84.
11. Guo, J., Zhou, J., Qin, H., Zou, Q. & Li, Q. (2011). Monthly stream flow forecasting based on improved support vector machine model. *Expert Systems with Applications*, 38 (10), 13073-13081.
12. Hosseini, S.M. & Mahjouri, N. (2016). Integrating Support Vector Regression and a Geomorphologic Artificial Neural Network for Daily Rainfall-Stream flow Modeling. *Hydrology*, 38, 329-345.
13. Huang, G-B. & Siew, C-K. (2005). Extreme learning machine with randomly assigned RBF kernels. *International Information Technology*, 11(1), 16-24.

۳۹/۵۶ درصد بوده است. هم‌چنین تأثیر روش پیش‌پردازشی بر کاهش خطای مدل ELM در مقیاس روزانه برابر ۲۸ تا ۴۰/۴۵ درصد و در مقیاس ماهانه برابر ۳۱/۴۸ تا ۴۰/۹۱ درصد بوده است. برای سناریوی دوم نیز استفاده از روش ترکیبی نسبت به مدل‌های گاوسی و ماشین یادگیری قدرتمند در مقیاس زمانی روزانه، به ترتیب، مقدار خطا را تقریباً ۷ تا ۱۴ و ۱۲ تا ۱۴/۱۹ درصد کاهش داده است و برای مقیاس ماهانه نیز به ترتیب مقدار خطا را تقریباً ۲۰/۴۲ تا ۲۱/۲۵ و ۲۶/۵۵ تا ۲۷/۸۵ درصد کاهش داده است. هم‌چنین با دقت در نتایج جدول‌ها مشاهده گردید که مدل‌سازی صورت‌گرفته در تخمین دبی جریان برای سناریوی دوم نسبت به سناریوی اول موفق‌تر می‌باشد. با بررسی تأثیر زیرسری‌های تجزیه مد تجربی کامل در نتایج مدل‌سازی، مشاهده گردید که زیرسری باقیمانده، ناکارآمدترین زیرسری است. با توجه به عملکرد مطلوب مدل‌های ترکیبی CEEMD-ELM در این تحقیق و اهمیت پیش‌بینی جریان در کشور ایران، استفاده از روش ترکیبی برای رودخانه‌های کشور پیشنهاد می‌شود.

منابع

۱. رجائی، ط.، و ابراهیمی، ه. (۱۳۹۳). مدل‌سازی نوسان‌های ماهانه آب زیرزمینی به وسیله تبدیل موجک و شبکه عصبی پویا. مدیریت آب و آبیاری. ۲(۱): ۸۷-۷۳.
۲. روشنگر، ک.، چمنی، م. (۱۳۹۸). پیش‌بینی و ارزیابی ارتباط دبی رودخانه در ایستگاه‌های هیدرومتریک متوالی با استفاده از روش‌های ترکیبی (GPR-EEMD) مطالعه موردی: رودخانه هوستونیک. تحقیقات آب و خاک ایران.
۳. شفائی، م.، فاخری‌فرد، ا.، دربندی، ص.، قربانی، م. (۱۳۹۲). پیش‌بینی جریان روزانه رودخانه با استفاده از

14. Huang, Y., Schmitt, F.G., Lu, Z. & Liu, Y. (2009). Analysis of daily river flow fluctuations using empirical mode decomposition and arbitrary order Hilbert spectral analysis. *Hydrology*, 373(1-2), 103-111.
15. Huang, S.Z., Huang, Q., Wang, Y.M. & Chen, Y.T. (2014). Stream flow series variation diagnosis based on heuristic segmentation and approximate entropy method. *Acta Scientiarum Naturalium Universitatis Sunyatseni*, 53 (4), 154-160.
16. Kwin, C.T., Talei, A., Alaghmand, S. & Chua, L.H.C. (2016). Rainfall-Stream flow Modeling using Dynamic Evolving Neural Fuzzy Inference System with Online Learning. *Procedia Engineering*, 154, 1103-1109.
17. Lima, A.R., Cannon, A.J. & Hsieh, W.W. (2016). Forecasting Daily Stream flow using Online Sequential Extreme Learning Machines. *Hydrology*, 537, 431-443.
18. Nayak, P.C., Sudheer, K.P., Rangan, D.M. & Ramasastri, K.S. (2004). A neuro-fuzzy computing technique for modeling hydrological time series. *Hydrology*, 291(1-2), 52-66.
19. Neal, R.M. (1997). Monte carlo implementation of Gaussian process models for Bayesian regression and classification, University of Toronto, Toronto: Department of Statistics and Department of Computer Science, *Technical Report*, no. 9702.
20. Roushangar, K. & Alizadeh, F. (2018). Entropy-based analysis and regionalization of annual precipitation variation in Iran during 1960–2010 using ensemble empirical mode decomposition. *Hydroinformatics*, 20 (2), 468-485.
21. Sang, Y.F., Wang, Z. & Liu, C. (2012). Period identification in hydrologic time series using empirical mode decomposition and maximum entropy spectral analysis. *Hydrology*, 424-425, 154-164.
22. Taormina, R. & Chau, K.W. (2015). Data-driven Input Variable Selection for Rainfall-Stream flow Modeling using Binary-Coded Particle Swarm Optimization and Extreme Learning Machines. *Hydrology*, 529, 1617-1632.
23. Wu, Z. & Huang, N.E. (2004). A study of the characteristics of white noise using the empirical mode decomposition method. *Proc RS Lond* 460A, 1597-1611.
24. Yaseen, Z.M., Jaafar, O., Deo, R.C., Kisi, O., Adamowski, J., Quilty, J. & El-shafie, A. (2016). Boost Stream-Flow Forecasting Model with Extreme Learning Machine Data-Driven: A Case Study in a Semi-Arid Region in Iraq. *Hydrology*, 542, 603-614.
25. Yaslan, Y. & Bican, B. (2017). Empirical mode decomposition based de noising method with support vector regression for time series prediction: a case study for electricity load forecasting. *Measurement*, 103, 52-61.
26. Yu, X., Liang, S.Y. & Babovic, V. (2004). EC-SVM approach for real-time hydrologic forecasting. *Hydroinformatics*, 6(3), 209-223.
27. Zhu, S., Luo, X., Xu, Z. & Ye, L. (2018). Seasonal stream flow forecasts using mixture-kernel GPR and advanced methods of input variable selection. *Hydrology Research*, 50(1), 200-214.