

مدل سازی رسوبات معلق رودخانه با استفاده از محاسبات نرم (مطالعه موردی: رودخانه دره رود)

محمد رضا نیک پور^۱، هادی ثانی خانی^۲

تاریخ ارسال: ۱۳۹۶/۰۵/۰۳

تاریخ پذیرش: ۱۳۹۶/۰۸/۰۱

چکیده

جابه جایی و ته نشینی بار معلق رودخانه ها باعث بروز مشکلات زیادی از جمله رسوب گذاری در مخازن سدها، تغییر مسیر رودخانه ها به دلیل رسوب گذاری در بستر آن ها، کاهش ظرفیت آبریزی آبراهه ها و تأسیسات انتقال آب و همچنین تغییر کیفیت آب به لحاظ مصارف شرب و کشاورزی می شود. در این پژوهش از مدل های فازی-عصبی تطبیقی (ANFIS)، برنامه ریزی بیان ژن (GEP) و رگرسیون بردار پشتیبان (SVR) جهت مدل سازی و پیش بینی میزان رسوبات معلق حوضه آبریز دره رود در استان اردبیل استفاده شد. در این راستا از داده های رسوب و دبی جریان ایستگاه هیدرومتری مشیران بر روی رودخانه دره رود (واقع در بالادست سد عمارت) استفاده شد. پس از آزمون هشت سناریوی مختلف توسط مدل SVR، الگوی ترکیبی شامل مقادیر دبی جریان در همان روز، دبی جریان و رسوب معلق در گام زمانی قبل به عنوان بهترین الگو شناخته شد. الگوی مذکور برای مدل های ANFIS و GEP نیز به عنوان ورودی استفاده شد. نتایج بیانگر عملکرد قابل قبول مدل ها و برتری مدل SVR با بیشترین ضریب تعیین ($R^2=0/97$)، کمترین ریشه میانگین مربعات خطا ($RMSE=17343 \text{ ton/day}$) و همچنین شاخص های نش-ساتکلیف ($NS=0/97$) و ویلموت ($WI=0/98$) در مرحله صحت سنجی بود. علاوه بر آن، توزیع فراوانی قدر مطلق خطای پیش بینی و نمودار جعبه ای توزیع خطای پیش بینی مدل های هوشمند نیز تأیید کننده عملکرد بهتر مدل SVR بود. ضمناً، کارایی مدل ANFIS تا حدی بهتر از مدل GEP بود. ضرایب و توابع به کار رفته برای واسنجی مدل های هوشمند مورد استفاده در این پژوهش می تواند برای تخمین رسوبات معلق ایستگاه های مجاور فاقد آمار دارای شریط زمین ساختی و هیدرولوژیکی یکسان در سطح منطقه بسیار مفید واقع شود.

کلمات کلیدی: بار معلق، برنامه ریزی بیان ژن، دره رود، رگرسیون بردار پشتیبان، فازی-عصبی تطبیقی.

^۱ استادیار گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران. ۰۹۱۳۲۲۲۰۴۸۵
m_nikpour@uma.ac.ir (نویسنده مسئول)

^۲ استادیار گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه کردستان، سنندج، ایران. ۰۹۱۲۵۵۵۰۶۰۰
h.sanikhani@uok.ac.ir

مقدمه

ارزیابی حجم رسوبات معلق رودخانه‌ها در طراحی و بهره‌برداری پروژه‌های آبی، از اهمیت زیادی در مهندسی آب برخوردار است. تخمین بار معلق در طیف وسیعی از مسائل از قبیل طراحی مخازن سدها، انتقال رسوب و آلودگی در رودخانه‌ها، طراحی کانال-های پایدار، برآورد میزان فرسایش و رسوب‌گذاری اطراف پایه‌های پل و مدیریت حوضه‌های آبخیز به‌کار گرفته می‌شود (Melesse et al., 2011). در زمینه تخمین بار معلق رودخانه‌ها روابط متعددی توسط متخصصان ارائه شده اما در بسیاری از موارد به علت پیچیدگی سازوکار جابه‌جایی رسوبات، نتایج حاصل از روابط تجربی با مقادیر واقعی مطابقت نداشته و لذا هیچ‌کدام مورد مقبولیت جهانی قرار نگرفته است (Azamathulla et al., 2013). مدل‌های هوشمند ابزار مناسبی برای درک رفتار غیر خطی یک پدیده می‌باشد و لذا پژوهشگران برای پیش‌بینی و برآورد بار معلق و بار بستر رودخانه‌ها به این مدل‌ها روی آورده‌اند. (Cigizoglu and Alp (2005) برای تخمین بار معلق روزانه حوضه آبریز جانیاتا واقع در ایالات متحده از مدل رگرسیون تعمیم یافته شبکه عصبی^۱ (GRNN) استفاده کردند و عملکرد این مدل را نسبت به مدل رگرسیونی چند متغیره مقایسه نمودند. نتایج تحقیق آن‌ها نشان داد که مدل GRNN از دقت بالاتری در برآورد بار معلق برخوردار می‌باشد. Kisi et al. (2012) دقت مدل‌های برنامه‌ریزی ژنتیک^۲، شبکه‌های عصبی مصنوعی^۳، سامانه استنتاج فازی-عصبی تطبیقی^۴ و ماشین بردار پشتیبان^۵ را در تخمین بار معلق روزانه دو ایستگاه هیدرومتری واقع در ایالات متحده ارزیابی کردند. در نهایت مدل GP نسبت به سایر مدل‌ها برتری محسوسی داشت. Mustafa et al. (2012) از مدل پرسپترون چندلایه^۶ (MLP) با چهار الگوریتم مختلف آموزش برای پیش-

بینی بار معلق رودخانه پری واقع در کشور مالزی استفاده کردند. در نهایت بهترین الگوریتم آموزش از نظر کوتاه‌ترین زمان لازم برای همگرایی و بالاترین دقت، معرفی شد. (Azamathulla et al. (2013) عملکرد سه مدل رگرسیونی چند متغیره، ANFIS و برنامه‌ریزی بیان ژن^۷ را در مدل‌سازی سه رودخانه در مالزی مورد ارزیابی قرار دادند. نتایج مطالعه آن‌ها نشان داد از بین سه روش مذکور مدل ANFIS با دقت بیشتری بار معلق را شبیه‌سازی می‌کند. Lafdani et al. (2013) جهت مدل‌سازی میزان بار رسوبی رودخانه دیراج در غرب ایران از مدل‌های SVM و ANNs استفاده کردند. آن‌ها جهت تعیین ترکیبات متغیرهای ورودی از آزمون‌های گاما و الگوریتم ژنتیک بهره گرفتند. نتایج بدست آمده نشان داد که هر دو روش هوشمند از دقت بالایی در تخمین میزان رسوبات معلق برخوردار بوده هر چند نوع آزمون در نظر گرفته شده جهت انتخاب متغیرهای ورودی می‌تواند بر نتایج مدل‌ها موثر باشد. Wiprecht et al. (2013) برای برآورد بار بستر و بار معلق در بازه‌ای به طول ۵۰۰ کیلومتر و در ۴۵ ایستگاه واقع در رودخانه راین، مدل ANFIS را مورد استفاده قرار دادند. در مقایسه با مقادیر اندازه‌گیری شده، مدل مذکور از دقت قابل قبولی برخوردار بود. Kitsikoudis et al. (2014) با استفاده از روابط تجربی بگنولد، میر-پیتر-مولر و پارکر بار بستر رودخانه‌ای واقع در ایالات متحده را محاسبه نموده و دقت روابط مذکور را با مدل‌های ANNs، ANFIS و GP مقایسه کردند. خطای مدل‌های هوشمند به مراتب کمتر از روابط تجربی گزارش شد و از بین مدل‌های هوشمند، مدل ANFIS دقت بهتری را به همراه داشت. (Kermani et al. (2016) از مدل‌های رگرسیون بردار پشتیبان بر پایه توابع کرنل متفاوت و شبکه‌های عصبی مبتنی بر الگوریتم‌های آموزشی متفاوت جهت مدل‌سازی غلظت رسوبات معلق استفاده نمودند و نتایج را با روش‌های رگرسیون چند متغیره خطی و منحنی سنجه مقایسه کردند. با توجه به شاخص‌های ارزیابی خطا، مدل رگرسیون بردار

¹ Generalized regression neural network

² Genetic Programming (GP)

³ Artificial Neural Networks (ANNs)

⁴ Adaptive Neuro-Fuzzy Interference System (ANFIS)

⁵ Support Vector Machine (SVM)

⁶ Multi-Layer Perceptron (MLP)

⁷ Gene Expression Programming (GEP)

SVM، ANNs و درخت تصمیم^۵ استفاده کردند که در نهایت مدل SVM تطابق بهتری با مقادیر اندازه-گیری شده از خود نشان داد. با بررسی منابع انجام شده می‌توان گفت استفاده از روش‌های مدل‌سازی غیرخطی جهت پیش‌بینی بار معلق رودخانه ضروری به نظر می‌رسد. لذا در این راستا مدل ANFIS به-دلیل سادگی و کارآمدی بالا، مدل GEP به جهت ارائه روابط صریح بین متغیرهای ورودی و خروجی و مدل SVR به جهت کارایی و سرعت بالا برای تخمین بار معلق ایستگاه هیدرومتری مشیران بر روی رودخانه دره‌رود (واقع در بالادست سد عمارت) مورد ارزیابی قرار گرفت. در بین مدل‌های ذکر شده دامنه مطالعات انجام شده با استفاده از مدل SVR به خصوص در مطالعات مدل‌سازی رسوبات رودخانه، نسبتاً کم و محدود می‌باشد. رودخانه دره‌رود به‌عنوان مهم‌ترین سرشاخه رود مرزی ارس در ایران، یکی از رودخانه‌های مهم استان اردبیل و یکی از منابع اصلی تأمین آب بخش‌های مختلف استان می‌باشد. از سوی دیگر بر روی رودخانه مذکور سد مخزنی عمارت در حال ساخت می‌باشد. بنابراین نظر به موقعیت استراتژیک رودخانه مذکور و اهمیت مدیریت صحیح بهره‌برداری از آن، مدل‌سازی و پیش‌بینی میزان رسوبات معلق در این حوضه می‌تواند در راستای مدیریت منابع آب مناطق پایین دست نقش به‌سزایی را ایفا کند.

مواد و روش‌ها

سامانه استنتاج فازی - عصبی تطبیقی

مدل ANFIS بر اساس قوانین سامانه فازی بنا نهاده شده و از قابلیت الگوریتم آموزشی مدل ANNs برای تطبیق و تعیین پارامترهای مبتنی بر قوانین^۶ استفاده می‌کند (Russel and Campbell, 1996). در حالت کلی، یک مدل ANFIS شبکه‌ای چندلایه و متشکل از گره‌ها و کمان‌های اتصال دهنده گره‌ها می‌باشد. گره‌های ابتدایی و انتهایی آن معرف متغیرهای ورودی و خروجی (هدف) بوده و گره‌های میانی (پنهان) آن را توابع عضویت و قواعد فازی تشکیل می-

پشتیبان بر پایه تابع کرنل شعاعی از عملکرد بهتری نسبت به سایر مدل‌ها برخوردار بود. Kisi and Ozkan (2017) از یک مدل رگرسیونی جدید به نام LWLR^۱ برای برآورد بار معلق روزانه دو ایستگاه هیدرومتری واقع در کالیفرنیا استفاده کردند. نتایج مدل مذکور را با مدل‌های SRC، ANNs و LS-SVM مقایسه کردند. با در نظر گرفتن شاخص RMSE، مدل LWLR نسبت به سایر مدل‌ها از خطای کمتری برخوردار بود. روش‌نگر و همکاران (۱۳۹۴) جهت پیش‌بینی بار معلق رودخانه قطورچای از روش‌های GP و الگوریتم ژنتیک^۲ استفاده کرده و نتایج را با روش‌های نیمه تجربی و منحنی سنجه مقایسه نمودند. نتایج بدست آمده نشان داد که مدل GP از کارایی بالایی در تخمین میزان رسوبات برخوردار می‌باشد. شیخعلی پور و همکاران (۱۳۹۴) از روش‌های هوشمند شامل ANNs، ANFIS و GEP جهت برآورد بار معلق رودخانه سیستان استفاده کردند. ارزیابی دقت مدل‌ها با توجه به شاخص‌های آماری خطا نشان داد که هر سه روش نتایج مناسبی در برآورد بار رسوبی ارائه می‌دهد و مقایسه عملکرد مدل‌ها حاکی از برتری نسبی روش برنامه‌ریزی بیان ژن نسبت به سایر مدل‌ها بود. خزائی‌پول و طالبی (۱۳۹۵) مدل ترکیبی منحنی سنجه رسوب^۳ (SRC) و ANNs به نام مدل HAS ۴ را برای برآورد بار بستر رودخانه قطورچای ارائه دادند. نتایج نشان داد مدل HAS خطای کمتری نسبت به مدل‌های ANNs و SRC دارد. ذرتی‌پور (۱۳۹۵) کارایی مدل‌های ANNs و ANFIS را نسبت به مدل‌های آماری در برآورد بار معلق روزانه رودخانه طالقان رود مقایسه کرد. نتایج نشان داد که برآوردهای مدل ANFIS نسبت به مدل ANNs و برآوردهای مدل ANNs در مقایسه با مدل‌های آماری از دقت بالاتری برخوردار می‌باشد. عشقی و همکاران (۱۳۹۵) برای پیش‌بینی رسوبات معلق حوزه آبخیز بابا امان بجنورد از مدل‌های SRC،

¹ Local Weighted Linear Regression (LWLR)

² Genetic Algorithm

³ Sediment Rating Curve (SRC)

⁴ Hybrid of ANNs and SRC

⁵ Decision Tree

⁶ Rule-based parameters

لایه ششم (جمع بندی): در این لایه با جمع مقادیر غیرفازی شده، خروجی مدل ANFIS تولید می شود.

$$Output_{VI,i} = \sum \bar{W}_i f_i \quad (6)$$

دهند. مطابق شکل ۱، شش لایه مختلف برای مدل ANFIS قابل شناسایی است (Kisi et al., 2015): لایه اول (ورودی): شامل متغیرهای ورودی X_1 و X_2 می باشد.

$$Output_{I,X1} = X_1 \quad Output_{I,X2} = X_2 \quad (1)$$

لایه دوم (فازی سازی): در این لایه بر اساس تابع عضویت انتخاب شده، برای هر یک از ورودی ها، درجه عضویت (μ) در نظر گرفته می شود.

$$Output_{II,i} = \mu_{Ai}(X_1), \quad i = 1, 2; \quad (2)$$

$$Output_{II,i} = \mu_{Bi}(X_2), \quad i = 1, 2$$

لایه سوم (قوانین): در گره های این لایه، مطابق با قوانین منطق فازی سوگنو، سیگنال های ورودی در هم ضرب شده و خروجی آن که بیانگر قوه اشتعال^۱ هر قانون فازی می باشد، به لایه بعد فرستاده می شود. در رابطه ۳، W_n قوه اشتعال قانون n ام می باشد.

$$Output_{III,i} = W_n = \mu_{Ai}(X_1)\mu_{Bi}(X_2), \quad i = 1, 2 \quad (3)$$

لایه چهارم (نرمال سازی): این لایه پس از دریافت هر یک از قوانین لایه سوم، مقادیر نرمال شده قوانین را توسط رابطه ۴ محاسبه می کند. طبق این رابطه، نسبت قوه اشتعال i امین قانون به مجموع قوه های اشتعال همه قوانین محاسبه می شود.


$$Output_{IV,i} = \bar{W}_i = \frac{W_i}{W_1 + W_2} \quad i = 1, 2 \quad (4)$$

لایه پنجم (غیرفازی سازی^۲): در این لایه میزان مشارکت (وزن) i امین قانون فازی، با حاصل ضرب قوه اشتعال نرمال شده (خروجی لایه چهارم) و تابع برآیند $(p_i + q_i + r_i)$ محاسبه می شود.

$$Output_{V,i} = \bar{W}_i f_i = \bar{W}_i (p_i + q_i + r_i) \quad (5)$$

¹ Firing strength

² Defuzzification



شکل (۱): ساختار مدل ANFIS (Kisi et al., 2015)

بالایی برخوردار است. پس از تحلیل حساسیت مدل GEP در تخمین بار معلق، پارامترها و عملگرهای ژنتیکی مورد استفاده به همراه مقادیر آنها در جدول ۱ ارائه شده است.

مدل برنامه ریزی بیان ژن

برنامه ریزی بیان ژن (GEP) یکی از الگوریتم‌های تکاملی است که بر اساس فرضیه تکاملی داروین^۱ بنا نهاده شده است. ویژگی مهمی که مدل GEP را از سایر روش‌های محاسباتی نرم^۲ متمایز می‌کند، ارائه معادله جبری برای تخمین متغیر هدف^۳ می‌باشد (Ferreira, 2001). در این پژوهش از نرم‌افزار GeneXpro Tools 4.0 برای به کارگیری مدل GEP استفاده شد. در محیط این نرم‌افزار برای شبیه‌سازی بار معلق، مراحل ذیل دنبال شد: گام اول، انتخاب تابع برازش^۴ بود. در این پژوهش، ریشه نسبی مربعات خطا^۵ (RRSE) به عنوان تابع برازش انتخاب شد. گام دوم، انتخاب متغیرهای ورودی و توابع برای تولید کروموزوم‌ها بود. در تحقیق حاضر، ترکیبی از دبی جریان و مقادیر رسوب معلق در گام‌های زمانی قبل به عنوان متغیرهای ورودی در نظر گرفته شد. در گام سوم، ساختار و معماری کروموزوم‌ها و در گام چهارم، توابع ارتباط دهنده آنها انتخاب شد. سرانجام در گام پنجم، عملگرهای ژنتیک انتخاب شد. لازم به ذکر است که برای استخراج رابطه ریاضی برآورد رسوبات معلق علاوه بر عملگرهای اصلی ریاضی مرسوم از توابع مثلثاتی و نمایی نیز استفاده شد. از جمله قابلیت‌های GEP نسبت به سایر الگوریتم‌های هوشمند، ارائه معادله ریاضی بین متغیرهای ورودی و خروجی می‌باشد که این موضوع جهت انجام پیش‌بینی از اهمیت

¹ Darwinian Evolution Theory

² Soft computing approaches

³ Target

⁴ Fitness function

⁵ Root relative square error (RRSE)

جدول (۱): مقادیر پارامترها و عملگرهای مورد استفاده در مدل GEP

عملگرهای ژنتیکی	تنظیمات کلی
نرخ جهش ۰/۰۴۴	تعداد کروموزومها ۳۰
نرخ وارون سازی ۰/۱	اندازه رأس ۷
نرخ ترانهش درج متوالی ۰/۱	تعداد ژن در هر کروموزوم ۳
نرخ ترانهش ریشه درج متوالی ۰/۱	تعداد جمعیت تولیدی ۱۰۰۰
نرخ ترکیب تک نقطه‌ای ۰/۳	تابع پیوند مجموع (+)

مدل ماشین بردار پشتیبان

مدل SVM ماشین مجهز به الگوریتم آموزشی انعطاف پذیر بوده که برای حل مسائل طبقه بندی و رگرسیونی مورد استفاده قرار می گیرد. در مدل رگرسیونی SVM که تحت عنوان SVR نامیده می شود، وابستگی متغیر وابسته (y) به مجموعه ای از متغیرهای مستقل (x) برآورد می شود. در این مدل فرض بر این است که مانند سایر مسائل رگرسیونی و طبق رابطه ۷، رابطه بین متغیرهای وابسته و مستقل توسط تابع f(x) به همراه مقداری نویز^۱ معین می شود (Vapnic, 1995).

$$y = f(x) + noise = [w \cdot \phi(x) + b] + \varepsilon \quad (7)$$

در رابطه ۷، w بردار ضرایب، $\phi(x)$ تابع ترسیمی غیرخطی (تابع کرنل^۲) و پارامترهای b و ε به ترتیب مقادیر بایاس و خطای مجاز تابع رگرسیون هستند. بنابراین موضوع اصلی، یافتن فرم مناسبی از تابع f(x) است که بتواند آموزش صحیح مدل SVR را با به کارگیری داده های آموزشی و با هدف کمینه کردن تابع خطا به همراه داشته باشد. در معادلات ۸ و ۹ تابع خطا به همراه محدودیت های مورد نیاز برای کمینه سازی آن ذکر شده است (Mehdizadeh et al., 2017).

$$\frac{1}{2} \|w\|^2 + C_C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (8)$$

$$\begin{aligned} y_i - b - [w \cdot \phi(X_i)] &\leq \varepsilon + \xi_i \\ [w \cdot \phi(X_i)] + b - y_i &\leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \quad (9)$$

در روابط فوق، Cc پارامتر کنترل گنجایش یا ظرفیت، yi مقدار برآورد شده توسط مدل، ξ_i و ξ_i^* ضرایب کمبود^۳ هستند. در مدل SVR برای حل مسائل غیرخطی از توابع کرنل استفاده می شود. بنابراین برای دستیابی به جواب بهینه، انتخاب تابع کرنل مناسب حائز اهمیت است. توابع کرنل مختلف در مدل SVR عبارتند از: خطی، چندجمله ای، سیگموئید و تابع پایه شعاعی گوسی^۴ (GRBF). در این پژوهش از تابع پایه شعاعی (معادله ۱۰) برای مدل سازی بار معلق استفاده شد. در رابطه ۱۰، K(Xi,Xj) نمایانگر تابع کرنل و σ انحراف معیار میزان اغتشاشات گوسی^۵ می باشد.

$$K(x_i, x_j) = \exp\left(-\|x_i - x_j\|^2 / 2\sigma^2\right), \quad \sigma > 0 \quad (10)$$

ارزیابی عملکرد مدل ها

جهت آزمون عملکرد مدل های مورد استفاده در این مطالعه از چهار شاخص آماری شامل ضریب تعیین (R2)، ریشه میانگین مربعات خطا (RMSE) و شاخص کارایی ناش-ساتکلایف (NS) و شاخص ویلموت (WI) استفاده گردید. ضریب تعیین در محدوده بین صفر تا یک تغییر می کند، که مقدار بالای این ضریب نشان دهنده عملکرد بهتر مدل است.

³ Slack variables

⁴ Gaussian radial basis function

⁵ Gaussian noise level

¹ Noise

² Kernel function

گردید. لازم به ذکر است که بر اساس گزارش‌های موجود، سد عمارت در سال ۱۳۹۷ بهره‌برداری خواهد شد. ایستگاه هیدرومتری مشیران در 31° - 47° طول جغرافیایی، 32° - 38° عرض جغرافیایی، در ارتفاع ۷۸۰ متری از سطح دریا واقع شده است. شکل ۲ محدوده و موقعیت کلی منطقه مورد مطالعه را نشان می‌دهد. داده‌های دبی و بار معلق از شرکت آب منطقه‌ای استان اردبیل اخذ شد. به لحاظ هیدرولوژیکی روش‌های مختلفی جهت برآورد بار معلق رودخانه‌ها وجود دارد. با استفاده از داده‌های هیدرومتری و رسوب‌سنجی و با توجه به اینکه دبی رسوب تابعی از دبی جریان می‌باشد، رابطه بین آن‌ها استخراج شده و با استفاده از ارقام درازمدت دبی جریان، با معلق رودخانه در قالب منحنی سنج برآورد می‌گردد. دسته‌بندی داده‌ها جهت افزایش دقت برآورد رسوب به روش منحنی سنج مرسوم می‌باشد و روش‌های مختلفی نظیر روش سالانه، فصلی، ماهانه و تشابه هیدرولوژیکی ماهانه وجود دارد. با توجه به هزینه‌بر بودن نمونه‌برداری رسوب معلق، معمولاً نمونه‌های محدودی در طول یک سال آبی برداشت می‌شود. در این تحقیق جهت تطبیق داده‌های دبی جریان و رسوب معلق از روش منحنی سنج استفاده شد. از آزمون مان-کندال برای بررسی ایستایی داده‌های مورد استفاده و همچنین تصادفی بودن و روند داده‌ها استفاده شد. همچنین برای بررسی تصادفی بودن داده‌ها از ران تست نیز استفاده شد. کفایت داده‌ها با استفاده از رابطه مارکوس و درستی داده‌ها با روش جرم مضاعف مورد بررسی و آزمون قرار گرفت. تعداد کل نمونه‌برداری‌ها در طول دوره آماری مورد بررسی برابر ۸۸۵ نمونه بود که از این تعداد، ۷۰ درصد (۶۱۲ داده) به‌عنوان داده‌های آموزش ۱ و ۳۰ درصد باقی‌مانده (۲۶۳ داده) به‌عنوان داده‌های آزمون ۲ و صحت‌سنجی ۲ در نظر گرفته شد. در جدول ۲ مشخصات آماری مربوط به داده‌های اندازه‌گیری شده دبی جریان و بار رسوبی معلق در طول دوره آماری مورد نظر ارائه شده است.

(1999) Legates and McCabe چنین عنوان نمودند که استفاده از این شاخص به تنهایی به عنوان معیاری جهت ارزیابی عملکرد مدل مورد استفاده کافی نبوده و لازم است علاوه بر آن، شاخص‌های دیگری نیز در کنار آن استفاده شوند. لذا علاوه بر R^2 از شاخص‌های WI ، NS ، $RMSE$ و WI مطابق با روابط زیر استفاده گردید.

$$R^2 = \left(\frac{\sum_{i=1}^N (S_0 - \bar{S}_0)(S_M - \bar{S}_M)}{\sqrt{\sum_{i=1}^N (S_0 - \bar{S}_0)^2 \sum_{i=1}^N (S_M - \bar{S}_M)^2}} \right) \quad (11)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_0 - S_M)^2} \quad (12)$$

$$WI = 1 - \left[\frac{\sum_{i=1}^N (S_0 - S_M)^2}{\sum_{i=1}^N (|S_M - S_0| + |S_0 - \bar{S}_0|)^2} \right] \quad (13)$$

$$NS = 1 - \left[\frac{\sum_{i=1}^N (S_0 - S_M)^2}{\sum_{i=1}^N (S_0 - \bar{S}_0)^2} \right] \quad (14)$$

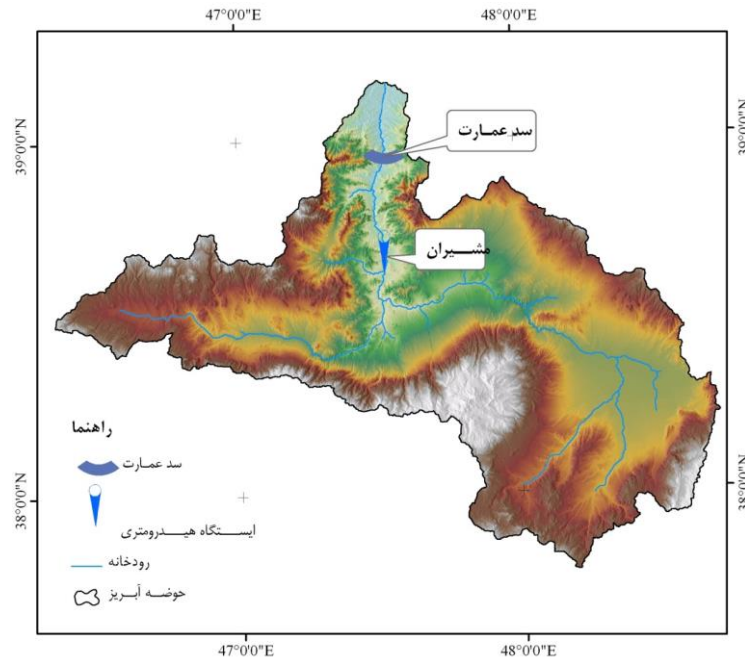
در روابط فوق، N تعداد داده‌ها، مقدار S_0 مقدار رسوب معلق اندازه‌گیری شده و S_M مقدار شبیه‌سازی شده برای رسوب معلق توسط مدل در گام زمانی t ام می‌باشد. همچنین \bar{S}_0 متوسط مقدار رسوب معلق اندازه‌گیری شده می‌باشد. بررسی عملکرد مدل‌ها در قالب ترکیبی از شاخص‌های ذکر شده جهت بررسی کارایی مدل‌ها مناسب است.

منطقه مورد مطالعه

حوضه آبریز دره‌رود با وسعتی برابر ۱۴۳۱۰ کیلومتر مربع بخش قابل توجهی از استان اردبیل را تحت پوشش قرار می‌دهد. ۶۸ درصد وسعت حوضه در استان اردبیل و ۳۲ درصد آن در استان آذربایجان شرقی است. دره‌رود که یکی از رودخانه‌های مهم حوضه آبریز مذکور می‌باشد، به‌عنوان مهم‌ترین سرشاخه رود مرزی ارس در ایران، از الحاق دو سرشاخه اصلی قره‌سو و اهرچای تشکیل می‌گردد. برای شبیه‌سازی بار معلق رودخانه دره‌رود از داده‌های آماری مربوط به ایستگاه هیدرومتری مشیران واقع در رودخانه مذکور و در بالادست سد عمارت طی دوره آماری ۳۵ ساله از سال ۱۳۶۰ تا سال ۱۳۹۴ استفاده

¹ Training

² Testing



شکل (۲): موقعیت جغرافیایی منطقه مورد مطالعه

جدول (۲): خصوصیات آماری مقادیر دبی و بار معلق رودخانه مورد استفاده در بازه زمانی ۱۳۹۴-۱۳۶۰

متغیر	واحد	میانگین	حداقل	حداکثر	انحراف معیار	ضریب تغییرات	چولگی
$Q_{(t)}$	(m^3/day)	۴۱/۳	۰/۰۳	۲۵۳/۷	۴۹/۵	۱/۲	۱/۷
$S_{(t)}$	($tone/day$)	۳۹۰/۱۵	۰/۲۱	۸۱۷۷۶۷	۹۷۲۲۷	۲/۵	۴/۲

توسعه مدل های مورد استفاده

در این تحقیق عملکرد سه الگوریتم هوشمند شامل مدل های SVR، GEP و ANFIS جهت پیش-بینی مقادیر رسوب معلق در ایستگاه مشیران مورد مقایسه قرار گرفت. جهت تخمین رسوب معلق از الگوهای ورودی مختلف شامل مقادیر پیشین رسوب و مقادیر دبی جریان در گام زمانی فعلی و قبل استفاده شد تا تأثیر هر یک از این متغیرها در مدل سازی رسوب معلق مشخص گردد. از بین مدل های مورد بررسی، ابتدا مدل SVR به دلیل کارایی و سرعت بالاتر در فرآیند مدل سازی انتخاب گردید. جهت به-کارگیری این مدل، از برنامه تدوین شده در محیط نرم افزار MATLAB استفاده شد. در گام نخست، هشت سناریوی مختلف به عنوان الگوهای ورودی در مدل SVR به شرح زیر استفاده گردید:

$$(SVR1) Q_t (1)$$

$$(SVR2) S_{t-1} (2)$$

$$(SVR3) Q_t, S_{t-1} (3)$$

$$(SVR4) Q_{t-1}, S_{t-1} (4)$$

$$(SVR5) S_{t-1}, S_{t-2} (5)$$

$$(SVR6) Q_t, Q_{t-1}, S_{t-1} (6)$$

$$(SVR7) Q_{t-1}, Q_{t-2}, S_{t-1}, S_{t-2} (7)$$

$$(SVR8) Q_t, Q_{t-1}, S_{t-1}, S_{t-2} (8)$$

نتایج و بحث

در جدول ۳ عملکرد مدل SVR به ازای هشت الگوی ورودی مختلف در قالب شاخص های آماری خطا و همچنین مقادیر بهینه پارامترهای مدل (C ، E و σ) به ازای هر الگو نشان داده شده است. با توجه به جدول ۳ و مقادیر شاخص های آماری خطا، می توان دید بهترین عملکرد مدل SVR به ازای الگوی شماره

گفت که مدل SVR به خوبی توانسته است رابطه غیرخطی و پیچیده موجود بین مقادیر ورودی و خروجی را نشان دهد. به طور کلی نتایج حاصله در این بخش نشان می‌دهد با حذف مقادیر دبی جریان در گام زمانی فعلی، عملکرد مدل به طور قابل توجهی کاهش می‌یابد.


پس از شناسایی بهترین الگوی ورودی توسط مدل SVR، از این الگو در مدل‌های GEP و ANFIS استفاده شد. همان‌گونه که قبلاً ذکر شد، اولین گام جهت به‌کارگیری مدل GEP، انتخاب تابع برازش مناسب می‌باشد. در این پژوهش، نتایج انتخاب تابع برازش در مدل GEP حاکی از آن بود که استفاده از تابع برازش ریشه نسبی مربعات خطا (RRSE) در مقایسه با سایر توابع جهت مدل‌سازی رسوب معلق، نتایج بهتری به همراه دارد. بنابراین تابع RRSE به عنوان تابع برازش در مدل انتخاب شد. گام بعد انتخاب عملگرهای اصلی برای ساخت درخت تجزیه است. توابع ریاضی به‌کار گرفته شده در این تحقیق و عملکرد مدل به ازای مجموعه‌ای معین از توابع در جدول ۴ نمایش داده شده است. با توجه به جدول ۴، کمترین مقدار شاخص RMSE به ازای تابع F5 حاصل شده است. پس از انتخاب بهترین ترکیب تابع ریاضی، گام بعد شامل پیدا کردن تابع پیوند مناسب است. از بین توابع پیوند شامل جمع، تفریق، ضرب و تقسیم، تابع پیوند جمع عملکرد بهتری در مقایسه با سایر توابع داشت که نتایج ارائه شده در جدول ۴ این موضوع را تأیید می‌کند.

۶ حاصل شده است که در آن از مقادیر دبی جریان در همان روز، دبی جریان و رسوب معلق در گام زمانی قبل به عنوان ورودی استفاده شده است. همچنین ضعیف‌ترین عملکرد مدل به ازای الگوی شماره ۲ بوده است که شامل مقدار بار معلق در گام زمانی قبل می‌باشد. دلیل این موضوع می‌تواند عدم وجود متغیر دبی جریان در الگوی شماره ۲ باشد و نشان می‌دهد که مقادیر رسوب معلق وابستگی زیادی به دبی جریان دارند. به ازای بهترین عملکرد مدل مقادیر شاخص‌های آماری $R2$ ، $RMSE$ ، NS و WI به ترتیب برابر $0/97$ ، $0/98$ ، $0/97$ و $0/98$ حاصل شده است. نتایج بدست آمده در این پژوهش با تحقیق Aytek and Kisi (2008) مطابقت دارد. مقایسه نتایج بدست آمده در این تحقیق با مطالعه Kisi et al. (2012) حاکی از آن است که در مطالعه آن‌ها نیز بهترین الگوی ورودی مدل‌های هوشمند شامل استفاده از مقادیر رسوب معلق در گام زمانی قبل، دبی جریان در گام زمانی فعلی و قبل بوده است که با نتایج تحقیق حاضر همخوانی دارد. همچنین با توجه به نتایج ارائه شده در جدول ۳، می‌توان گفت در حالتی که از دبی جریان همان روز (الگوی شماره ۱) استفاده شده است، نتایج شاخص‌های آماری خطا نسبتاً قابل قبول می‌باشد که این موضوع اثرات دوگانگی رفتار^۱ بین رسوب معلق و دبی جریان را نشان می‌دهد. می‌توان گفت که با در نظر گرفتن دبی جریان فعلی و رسوب در گام زمانی قبل به عنوان ورودی (الگوی شماره ۳) عملکرد مدل تا حدود زیادی بهبود یافته است. نتایج نشان می‌دهد که استفاده از دبی جریان و رسوب در گام زمانی قبل (الگوی شماره ۴) و همچنین استفاده از مقادیر رسوب با تأخیر در دو گام زمانی (الگوی شماره ۵) چندان رضایت‌بخش نمی‌باشد. با به‌کارگیری مقادیر دبی جریان و رسوب با تأخیر در دو گام زمانی (الگوی شماره ۷) نیز نتایج مناسبی حاصل نشده است. در شکل ۳ نمودار سری زمانی و پراکندگی داده‌های مشاهداتی و شبیه‌سازی شده رسوب معلق به ازای بهترین الگوی ورودی (الگوی شماره ۶) برای مدل SVR نشان داده شده است. با توجه به این شکل می‌توان

¹ Hysteresis

جدول (۳): مقادیر پارامترها و عملکرد مدل SVR به ازای الگوهای ورودی مختلف در دوره آزمون

مدل	شاخص‌های آماری عملکرد			پارامترهای مدل			
	WI	NS	RMSE (ton/day)	R2	σ	ϵ	Cc
SVR1	۰/۶۳	۰/۴۵	۳۰۰۲	۰/۷۵	۰/۵	۰/۰۰۱	۱۰۰
SVR2	۰/۴۰	۰/۱۸	۴۳۹۰	۰/۳۱	۰/۴	۰/۰۱	۱۰
SVR3	۰/۷۲	۰/۵۶	۲۶۳۰	۰/۸۰	۰/۹	۰/۰۰۰۱	۱
SVR4	۰/۵۷	۰/۳۳	۳۵۱۱	۰/۶۶	۰/۲	۰/۰۰۱	۱۰۰
SVR5	۰/۴۶	۰/۲۹	۴۱۷۶	۰/۳۴	۱/۳	۰/۰۰۰۱	۱۰۰۰
SVR6	۰/۹۸	۰/۹۷	۱۷۴۳	۰/۹۷	۰/۶	۰/۰۱	۱۰
SVR7	۰/۴۴	۰/۲۳	۴۲۲۱	۰/۳۲	۱/۵	۰/۰۰۱	۱۰۰
SVR8	۰/۸۹	۰/۷۸	۲۱۵۰	۰/۹۱	۰/۷	۰/۰۰۰۱	۱۰۰۰



شکل ۳- تغییرات سری زمانی و پراکندگی مقادیر مشاهداتی و شبیه‌سازی شده توسط مدل SVR در دوره آزمون

مدل GEP در دوره آزمون ارائه شده است. با توجه به این شکل می‌توان دید که اگر چه مقدار ضریب تعیین برای مدل GEP جهت پیش‌بینی مقادیر رسوب معلق قابل قبول و معنی‌دار می‌باشد، اما عمده ضعف مدل در پیش‌بینی مقادیر پیک رسوب معلق بوده است. مقدار خطای مدل‌های SVR، ANFIS و GEP در درجه پیش‌بینی مقادیر پیک رسوب معلق به ترتیب برابر ۷/۵، ۱۴، و ۱۶ درصد بود. مقایسه نتایج مدل GEP با مدل SVR نیز حاکی از برتری مدل SVR در پیش‌بینی مقادیر رسوب معلق به الگوی الگوی وردی شماره ۶ می‌باشد.

در رابطه ۱۵ معادله ریاضی جهت تخمین رسوب معلق بر مبنای الگوی ورودی شماره ۶ ارائه شده است.

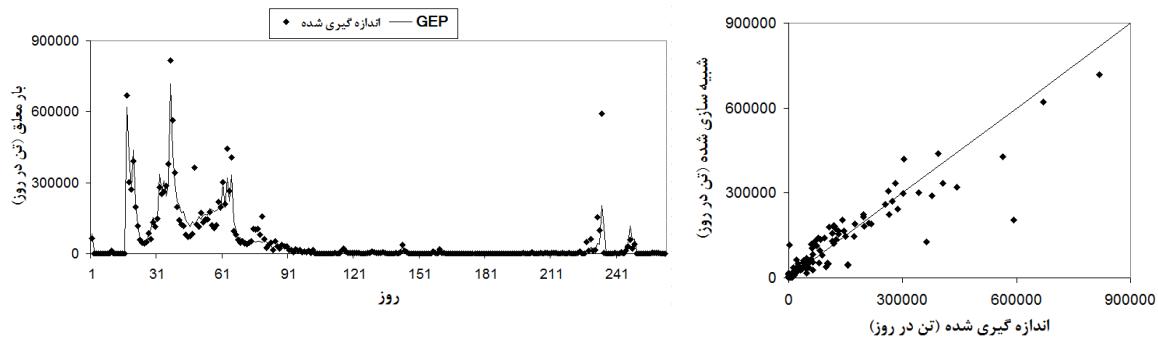
$$S_t = (9.96 + Q_t)(10.96Q_t - Q_{t-1}) - 9.87Q_{t-1} \ln(S_{t-1}) - \frac{Q_{t-1}^2 - Q_{t-1}}{\sqrt{S_{t-1} + ((Q_{t-1} - Q_t)^2(2.95S_{t-1}))}} \quad (15)$$

با توجه به رابطه (۱۵) می‌توان دید که متغیر دبی جریان بر میزان رسوب معلق اثر قابل توجهی دارد و این موضوع نتایج بدست آمده در بخش‌های قبل را تأیید می‌کند. در شکل ۴ نیز نمودار سری زمانی و پراکندگی داده‌های مشاهداتی و شبیه‌سازی شده با

جدول (۴): نتایج بکارگیری توابع ریاضی مختلف بر روی مقدار شاخص RMSE

تابع	مدل ریاضی	RMSE (ton/day)
F1	+ - * /	2003
F2	+ - * / ln x, e ^x	2001
F3	+ - * / $\sqrt[3]{x}$, \sqrt{x} , x ³ , x ²	1994
F4	+ - * / ln x, e ^x , $\sqrt[3]{x}$, \sqrt{x} , x ³ , x ²	1982
F5	+ - * / ln x, e ^x , $\sqrt[3]{x}$, \sqrt{x} , x ³ , x ² , sin x, cos x, Arctg x	1978

نوع تابع پیوند	سال
جمع	1978
تفریق	1993
ضرب	1984
تقسیم	1998



شکل ۴- تغییرات سری زمانی و پراکندگی مقادیر مشاهداتی و شبیه‌سازی شده توسط مدل GEP در دوره آزمون

گزارش شد. قابل ذکر است که تعداد توابع عضویت با استفاده از آزمون و خطا به ازای کمترین مقدار RMSE بدست آمده است. با توجه به جدول ۵، می‌توان گفت که بهترین تابع عضویت از نوع مثلثی بوده که تعداد آن برای متغیرهای دبی جریان در گام‌های زمانی فعلی و پیشین و رسوب در گام زمانی قبل به ترتیب برابر ۲، ۲ و ۴ می‌باشد. Russel and Campbell (1996) نیز عنوان نمودند که استفاده از توابع عضویت مثلثی به لحاظ کاربردی نتایج بهتری به همراه دارد. در شکل ۵ نیز نمودار تغییرات و پراکندگی مقادیر رسوب معلق مشاهداتی و شبیه‌سازی شده با مدل ANFIS نشان داده شده است. با توجه به

در ادامه به بررسی عملکرد مدل ANFIS جهت پیش بینی مقادیر رسوب معلق در ایستگاه مشیران پرداخته می‌شود. برای تقسیم‌بندی داده‌ها در مدل ANFIS، از روش‌های متفاوتی استفاده می‌شود که از جمله روش‌های مرسوم در این خصوص، روش افراز شبکه^۱ می‌باشد. این روش مبتنی بر انتخاب نوع تابع عضویت (مثلثی، ذونقه‌ای، گوسی، زنگوله‌ای و...) و تعداد تابع عضویت برای هر متغیر ورودی می‌باشد. در این تحقیق انواع توابع عضویت با به کارگیری الگوی بهینه ورودی (الگوی شماره ۶) مورد ارزیابی قرار گرفت و مقادیر شاخص RMSE متناظر با هر تابع در جدول ۵


^۱ Grid partitioning

مدل SVR بوده است، اگر چه مقادیر شاخص‌های آماری حاکی از برتری مدل SVR دارد.

این شکل می‌توان دید که عملکرد مدل ANFIS در پیش‌بینی مقادیر رسوب معلق تا حدی شبیه عملکرد

جدول (۵): عملکرد مدل ANFIS به‌ازای توابع عضویت متفاوت برای الگوی بهینه

RMSE (ton/day)	تعداد توابع عضویت	نوع تابع عضویت
۱۸۰۴	۴، ۲، ۲	مثلثی
۱۸۴۶	۴، ۳، ۲	گوسی
۱۸۲۲	۳، ۲، ۲	ذوزنقه‌ای
۱۸۵۱	۲، ۲، ۳	زنگوله‌ای



شکل (۵): تغییرات سری زمانی و پراکندگی مقادیر مشاهداتی و شبیه‌سازی شده توسط مدل ANFIS در دوره آزمون

کننده درصد فراوانی خطا می‌باشد. با توجه به این شکل کاملاً مشخص است که در محدوده خطای کمتر از ۵ درصد، حداکثر فراوانی خطا برای مدل SVR از سایر مدل‌ها بیشتر و برابر ۹۸ درصد می‌باشد در صورتی‌که این مقدار برای مدل‌های ANFIS و GEP به ترتیب برابر ۶۶ و ۶۹ درصد است که این موضوع حاکی از درصد خطای کمتر مدل SVR و برتری آن در پیش‌بینی رسوب معلق در این مطالعه است. نمودار جعبه‌ای خطای پیش‌بینی برای مدل‌های مختلف در شکل ۷ مورد مقایسه قرار گرفته است. نمودار جعبه‌ای بیان‌کننده مقادیر حداقل، حداکثر، متوسط، میانه و چندک‌های ۵ و ۹۵ درصد برای پیش‌بینی‌های انجام شده توسط هر مدل می‌باشد. با توجه به این شکل نیز می‌توان دید که دامنه خطای مدل SVR نسبت به مدل‌های ANFIS و GEP کمتر بوده و نتایج بدست آمده در این بخش در تطابق کامل با نمودار توزیع


در جدول ۶، نتایج شاخص‌های آماری برای مدل‌های SVR، GEP و ANFIS به‌ازای الگوی ورودی بهینه (الگوی شماره ۶) ارائه شده است. با توجه به نتایج حاصله می‌توان دید که عملکرد مدل SVR در مقایسه با سایر مدل‌ها بهتر بوده است. مدل‌های ANFIS و GEP در رتبه‌های دوم و سوم قرار می‌گیرند. با توجه به نتایج حاصله می‌توان گفت، مدل SVR به عنوان مدلی توانمند و با سرعت بالا می‌تواند جهت مدل‌سازی رسوب معلق در حوضه آبریز دره‌رود مورد استفاده قرار گیرد. در ادامه به مقایسه عملکرد مدل‌های هوشمند با استفاده از بررسی توزیع فراوانی قدر مطلق خطای پیش‌بینی و نمودار جعبه‌ای توزیع خطای پیش‌بینی مدل‌ها پرداخته می‌شود. در شکل ۶، نمودار فراوانی قدر مطلق خطای پیش‌بینی به‌ازای بهترین عملکرد مدل‌های SVR، GEP و ANFIS ارائه شده است. در این شکل هر یک از میله‌ها، بیان

برای میانه و مقادیر چندک برای مدل SVR حاصل شد. _____


فراوانی خطای مدل‌ها می‌باشد. با توجه به این شکل کاملاً مشهود است که پراکندگی خطا با مقادیر کمتر

جدول (۶): مقایسه عملکرد مدل‌های مورد استفاده جهت تخمین بار معلق به ازای بهترین الگوی ورودی

مدل	R^2	RMSE (ton/day)	NS	WI
SVR	۰/۹۷	۱۷۴۳	۰/۹۷	۰/۹۸
GEP	۰/۸۸	۱۹۷۸	۰/۸۸	۰/۹۲
ANFIS	۰/۹۶	۱۸۰۴	۰/۹۶	۰/۹۷



شکل (۶): نمودار فراوانی خطای مطلق پیش‌بینی به ازای مدل‌های GEP، ANFIS و SVR برای بهترین الگوی ورودی



شکل (۷): نمودار جعبه‌ای توزیع خطای پیش‌بینی مدل‌های GEP، ANFIS و SVR به ازای بهترین الگوی ورودی

ورودی مختلف شامل مقادیر دبی‌های جریان و رسوب معلق پیشین جهت مدل‌سازی رسوب معلق در گام زمانی فعلی استفاده شد. نتایج به دست آمده حاکی از عملکرد قابل قبول روش‌های مورد استفاده در پیش-بینی مقادیر رسوب معلق بود. بهترین الگوی ورودی در مدل‌ها شامل مقادیر دبی جریان در گام زمانی فعلی و قبل و بار معلق در گام زمانی قبل بود. مقادیر ضرایب R^2 ، RMSE، NS و WI برای مدل SVR در حالت بهینه به ترتیب برابر ۰/۹۷، ۱۷۴۳ و ۰/۹۸ به دست آمد. مقایسه عملکرد مدل‌های مختلف

نتیجه‌گیری

مدل‌سازی رسوب معلق رودخانه‌ها از اهمیت به-سزای برخوردار است که می‌تواند بر مدیریت و بهره-برداری از سازه‌های آبی و مورفولوژی رودخانه تاثیرگذار باشد. در این مطالعه به بررسی عملکرد روش‌های SVR، GEP و ANFIS در پیش‌بینی میزان رسوبات معلق رودخانه پرداخته شد. در این راستا از نمونه داده‌های دبی جریان و بار معلق ایستگاه مشیران واقع در حوضه آبریز رودخانه دره‌رود در استان اردبیل در یک دوره ۳۵ ساله استفاده شد. از الگوهای

کاهش یابد و این مسأله بر روی حافظه سیستم تأثیرگذار بوده و از این لحاظ ممکن است بر عملکرد مدل‌های ارائه شده نقش داشته باشد. بنابراین می‌توان چنین مطالعاتی را در دوره‌های معین چندین ساله، جهت به‌روز رسانی مدل با شرایط منطقه تکرار نمود. جهت انجام مطالعات آتی، می‌توان عملکرد مدل‌های ارائه شده در این پژوهش را جهت تخمین رسوب معلق رودخانه با استفاده از داده‌های ایستگاه‌های مجاور مورد بررسی قرار داد که این موضوع در حوضه‌های فاقد آمار از اهمیت بالایی برخوردار است.

هوشمند در این پژوهش حاکی از برتری عملکرد مدل SVR نسبت به مدل‌های GEP و ANFIS بود. در این خصوص کارایی مدل ANFIS تا حدی بهتر از مدل GEP بود. جهت تعمیم نتایج به‌دست آمده در این مطالعه، نکات ذیل باید مورد توجه قرار گیرد. با توجه به اثرات تغییر اقلیم در کشور ایران که همراه با کاهش بارش و افزایش دما می‌باشد و لحاظ نمودن این موضوع که در حوضه آبریز مورد بررسی دبی جریان رودخانه تا حدی متأثر از ذوب برف می‌باشد، انتظار می‌رود در سال‌های آتی مقدار انباشت برف در منطقه

منابع

خزائی پول، الف. و ع. طالبی. ۱۳۹۵. ارائه مدل ترکیبی منحنی سنج رسوب و شبکه عصبی مصنوعی در برآورد بار رسوب بستر (مطالعه موردی: رودخانه قطورچای). مجله پژوهش آب ایران، سال دهم، شماره ۲، ص ۸-۱.

ذرتی پور، الف. ۱۳۹۵. افزایش دقت پیش‌بینی بار کل رسوبی با استفاده از الگوریتم‌های تکاملی (مطالعه موردی: بالادست حوضه طالقان). نشریه مرتع و آبخیزداری. سال هفتم، شماره ۱، ص ۷۸-۶۵.

روشنگر، ک. م. ت. اعلمی و ف. وجودی مهربانی. ۱۳۹۴. افزایش دقت پیش‌بینی بار کل رسوبی با استفاده از الگوریتم‌های تکاملی (مطالعه موردی: رودخانه قطورچای). نشریه آب و خاک. سال هفتم، شماره ۶، ص ۱۴۲۶-۱۴۱۶.

شیخعلی پور، ز. ف. حسن پور و و. عظیمی. ۱۳۹۴. مقایسه روش‌های هوش مصنوعی در برآورد بار معلق رسوب (مطالعه موردی: رودخانه سیستان). مجله پژوهش‌های حفاظت آب و خاک، سال هفتم، شماره ۲، ص ۴۱-۶۰.

عشقی، پ. ج. فرزاد مهر، م. ت. دستورانی و ز. طالبی. ۱۳۹۵. بررسی کارایی مدل‌های هوشمند در برآورد رسوبات معلق رودخانه‌ای (مطالعه موردی: حوزه آبخیز بابامان، خراسان شمالی). پژوهشنامه مدیریت حوزه آبخیز، سال هفتم، شماره ۱۴، ص ۹۵-۸۸.

- Aytek A. and O. Kisi. 2008. A genetic programming approach to suspended sediment modeling. *Journal of Hydrology*, 351: 288-298.
- Azamathulla H.M., Y.C. Caun, A. Aminudin and C.K. Chang. 2013. Suspended sediment load prediction of river systems: GEP approach. *Arabian Journal of Geoscience*, 6: 3469-3480.
- Cigizoglu H.K. and M. Alp. 2005. Generalized regression neural network in modeling river sediment yield. *Journal of Advances in Engineering Software*, 37: 63-68.
- Ferreira C. 2001. Algorithm for solving gene expression programming: a new adaptive problems. *Complex Systems*, 13(2): 87-129.
- Kermani Z.M., O. Kissi, J. Adamowski and A. Ramezani-Charmahineh. 2016. Evaluation of data driven models for river suspended sediment concentration modeling. *Journal of Hydrology*, 535: 457-472.
- Kissi O., A. Hosseinzadeh Dalir, M. Cimen and J. Shiri. 2012. Suspended sediment modeling using genetic programming and soft computing techniques. *Journal of Hydrology*, 450(1): 48-58.
- Kissi O., A. Sanikhani, H. Z.M. Kermani and F. Niazi. 2015. Long-term monthly evapotranspiration modeling by several data-driven methods without climatic data. *Computer and Electronics in Agriculture*, 115: 66-77.
- Kissi O. and C. Ozkan. 2017. A new approach foe modeling sediment-discharge relationship: Local Weighted Linear Regression. *Water Resources Management*, 31: 1-23.

Kitsikoudis V., E. Sidiropoulos and V. Hrissanthou. 2014. Machine learning utilization for bed load transport in gravel-bed rivers. *Water Resources Management*, 28: 3727-3743.

Lafdani E.K., A.M. Nia and A. Ahmadi. 2013. Daily suspended sediment load prediction using artificial neural networks and support vector machines. *Journal of Hydrology*, 478: 50-62.

Legates D.R. and G.J. McCabe. 1999. Evaluating the use of goodness-of-fit measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1): 233-241.

Mehdizadeh S., J. Behmanesh and K. Khalili. 2017. Using MARS, SVM, GEP and empirical equations for estimation of monthly mean reference evapotranspiration. *Computer and Electronics in Agriculture*, 139: 103-114.

Melesse A.M., S. Ahmad, M.E. McClain, X. Wang and Y.H. Lim. 2011. Suspended sediment load prediction of river systems: an artificial neural network approach. *Agriculture Water Management*, 98: 855-866.

Mustafa M.R., R.B. Rezaur, S. Saiedi and M.H. Isa. 2012. River suspended sediment prediction using various multilayer perceptron neural network training algorithms- A case study in Malaysia. *Water Resources Management*, 26: 1879-1897.

Russel S.O. and P.F. Campbell. 1996. Reservoir operating rules with fuzzy programming. *Journal of Water Resources Planning and Management*, 122 (3): 165-170.

Vapnic V.N. 1998. *The Nature of Statistical Learning Theory*. Wiley, New York: USA

Wieprecht S., G. Habtamu and C. Ted Yang. 2013. A neuro-fuzzy-based modelling approach for sediment transport computation. *Hydrological Sciences Journal*, 58(3): 587-599.

Suspended Load Modeling of River using Soft Computing Techniques (Case Study: Dareh-rood River)

Mohammad Reza Nikpour*¹, Hadi SaniKhani²

Abstract

The movement and deposition of the suspended load of rivers cause different problems; such as sedimentation in reservoirs, changing of river morphology based on sedimentation in the river bed, reducing the capacity of channels and water conveyance structures and changing of water quality for drinking and agricultural usage. In this study, adaptive neuro-fuzzy inference systems (ANFIS), gene expression programming (GEP) and support vector regression (SVR) was utilized for modeling and forecasting of suspended load for Dareh-rood catchment in Ardabil province. For this purpose, water discharge and sediment load of Moshiran hydrometric station located on Dareh-rood River (upstream of Emarat dam) was used. After evaluation of different input combinations (i.e. 8 scenarios) using the SVR, finally the model whose inputs consist of current discharge and one pervious discharge and suspended load was selected as the best scenario. The mentioned input combination was applied for ANFIS and GEP models. The results indicated that the SVR model with the highest $R^2=0.97$, the lowest $RMSE=1734$, $NS=0.97$ and $WI=0.98$ was superior to the other models during the validation phase. Furthermore, the frequency distribution and boxplots of forecasting errors of applied the data-driven models confirm the efficiency of the SVR model among others. Meanwhile, the performance of the ANFIS model was somewhat better than the GEP model. The coefficients and functions used to calibrate the intelligent models that utilized in this study can be very helpful in estimating the suspended sediments of ungagged nearby stations with the similar tectonic and hydrological conditions over the study region.

Keywords: Suspended load, Gene expression programming, Dreh-rood, Support vector regression, Adaptive neuro-fuzzy interference system.

¹ Assistant Professor, Department of Water Engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran. m_nikpour@uma.ac.ir

² Assistant Professor, Department of Water Sciences and Engineering, Faculty of Agriculture, University of Kurdistan, Sanandaj, Iran.