

ارزیابی و عملکرد مدل ماشین بردار پشتیبان در تخمین رسوبات معلق رودخانه ها

بابک شاهی نژاد^۱، رضا دهقانی^۲

تاریخ دریافت: ۱۳۹۵/۱۲/۲۱

تاریخ پذیرش: ۱۳۹۶/۳/۸

چکیده

همواره پدیده انتقال رسوب، بسیاری از سازه های رودخانه ای و سازه های عمرانی را تحت تأثیر قرار داده و عدم اطلاع از میزان دقیق آن خسارات بسیاری را موجب می شود. از این جهت دستیابی به روشی با دقت مناسب برای تخمین میزان بار رسوبی معلق رودخانه ها بسیار حایز اهمیت است. در این پژوهش جهت تخمین رسوبات رودخانه کاکارضا واقع در استان لرستان، از مدل ماشین بردار پشتیبان استفاده گردید و نتایج آن با برنامه ریزی بیان ژن مقایسه شد. پارامترهای دبی جریان، میزان مواد جامد محلول در آب و بارش بعنوان ورودی و پارامتر دبی رسوب بعنوان خروجی مدل در مقیاس زمانی ماهانه، طی دوره آماری (۱۳۷۳-۱۳۹۳) انتخاب شد. معیارهای ضریب همبستگی، جذر میانگین مربعات خطا و میانگین قدر مطلق خطا برای ارزیابی و نیز مقایسه عملکرد مدل ها مورد استفاده قرار گرفت. نتایج حاصله نشان داد که الگوهای ترکیبی توانسته با استفاده از دو مدل هوشمند مورد بررسی، در تخمین میزان رسوب نتایج قابل قبولی ارائه نماید. لیکن از لحاظ دقت، مدل ماشین بردار پشتیبان با بیشترین ضریب همبستگی (۰/۸۶۷)، کمترین جذر میانگین مربعات خطا (۰/۰۲۴ ton/day) و نیز میانگین قدر مطلق خطا (۰/۰۱۷ ton/day) در مرحله صحت سنجی در اولویت قرار گرفت. در مجموع نتایج حاصله نشان داد که مدل ماشین بردار پشتیبان توانایی بالایی در تخمین مقادیر حداقل و حداکثر از خود نشان داده است.

واژه های کلیدی: برنامه ریزی بیان ژن، دبی رسوبی معلق، رودخانه کاکارضا، ماشین بردار پشتیبان

(مسئول مکاتبه)^۱ استادیار گروه مهندسی آب، دانشگاه لرستان، ایران، تلفن: ۰۹۱۶۳۶۷۶۰۹۰ پست الکترونیکی shahinejad.b@lu.ac.ir

^۲ دانشجوی دکتری سازه های آبی، دانشگاه لرستان، ایران، تلفن: ۰۹۳۷۸۲۳۱۶۴۲ پست الکترونیکی reza.dehghani67@yahoo.com

مقدمه

پدیده انتقال رسوب از جمله فرآیندهای هیدرودینامیکی مهمی است که بسیاری از سیستم‌های هیدرولیکی و تأسیسات آبی را تحت تأثیر قرار می‌دهد و به عنوان یکی از مشکلات اساسی در بهره‌برداری از منابع آب های سطحی در جهان مطرح می‌باشد. با توجه به نقش و اهمیت رسوب در عمر مفید سدهای کشور که نقش بزرگی را در توسعه اقتصادی کشور ایفا می‌کنند، عدم توجه به اندازه‌گیری و محاسبه دقیق آن، باعث اتلاف سرمایه‌های ملی می‌گردد. بدیهی است که دقت پیش‌بینی میزان رسوب وارده به مخازن سدها، بستگی به روش‌های محاسباتی و معادلات ارائه شده در این زمینه دارد. از طرفی دامنه کاربرد این روش‌ها به سبب پیچیدگی طبیعت رودخانه‌ها و گوناگونی عوامل مؤثر در پدیده انتقال رسوب محدود می‌باشد و نتایج بدست آمده اغلب دارای دامنه نوسان زیادی است (آوریده و همکاران، ۱۳۸۰). خاصیت غیرخطی بودن معادلات، عدم قطعیت ذاتی برآورد رسوب، پیچیده بودن و هزینه بر بودن مدل‌های فیزیکی از جمله دلایلی است که باعث شده امروزه محققان برای پیش‌بینی پدیده‌های غیرخطی، روش‌های هوشمند را بکار گیرند، که از جمله میتوان به روش ماشین بردار پشتیبان^۱ و برنامه ریزی بیان ژن^۲ اشاره کرد. مدل ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است (دهقانی و همکاران، ۱۳۹۴). برنامه ریزی بیان ژن یک تکنیک برنامه ریزی خودکار است که راه حل مساله را با استفاده از برنامه ریزی کامپیوتر ارائه کرده و عضوی از خانواده الگوریتم تکاملی می‌باشد (قربانی و صالحی، ۱۳۹۰). در سالهای اخیر استفاده از روش‌های هوشمند در مطالعات دبی رسوبی مورد توجه محققین مختلف قرار گرفته است، که از جمله می‌توان به موارد ذیل اشاره نمود:

داننده مهر و همکاران (۱۳۸۹) رسوبات معلق رودخانه ليقوان چای را با استفاده از برنامه ریزی ژنتیک پیش‌بینی کردند. نتایج نشان داد برنامه ریزی ژنتیک در مقایسه با روش شبکه عصبی مصنوعی در پیش‌بینی

رسوبات معلق منطقه مورد مطالعه عملکرد بهتری دارد. ثانی خان و همکاران (۱۳۹۴) در پژوهشی دبی رسوبی رودخانه ونیاز واقع در استان آذربایجان شرقی را با استفاده از مدل‌های برنامه ریزی بیان ژن، فازی-عصبی، شبکه های عصبی و منحنی سنجه برآورد نموده و پس از مقایسه نتایج، دریافتند که مدل برنامه ریزی بیان ژن از دقت بالاتری برخوردار است. ستاری و همکاران (۱۳۹۵) عملکرد مدل های درختی M5 و رگرسیون بردار پشتیبان را بمنظور مدلسازی رسوبات معلق رودخانه اهر چای مورد بررسی قرار دادند و نشان دادند مدل درختی M5 کارایی بهتری در تخمین رسوبات رودخانه دارد. امامقلی زاده و همکاران (۱۳۹۵) در تحلیل مقایسه عملکرد مدل برنامه ریزی بیان ژن با روش های منحنی سنجه و فائو جهت پیش‌بینی رسوبات معلق رودخانه کرخه نشان دادند مدل برنامه ریزی بیان ژن مدلی مناسب جهت برآورد بار رسوبی رودخانه‌ها است. Aytek and Kisi (۲۰۰۸) در مطالعه ای برنامه ریزی ژنتیک را به عنوان روشی جدید برای فرموله کردن رابطه جریان و بار رسوب معلق روزانه در رودخانه تنگو واقع در مونتانا به کار گرفته و با منحنی سنجه و رگرسیون چند متغیره خطی مقایسه کردند. نتایج نشان داد که برنامه ریزی ژنتیک در مقایسه با دو روش دیگر عملکرد بهتری دارد. نتایج حاصل از پژوهش Kisi and Guven (۲۰۱۰) که از مدل برنامه ریزی ژنتیک خطی جهت پیش‌بینی غلظت رسوبات معلق رودخانه برادا^۳ واقع در ایالات متحده استفاده کردند نشان داد مدل برنامه ریزی ژنتیک در پیش‌بینی رسوبات معلق رودخانه عملکرد مناسبی از خود نشان داده است. Kisi and Shiri (۲۰۱۲) در پژوهشی بار معلق رسوب رودخانه ال^۴ واقع در کالیفرنیا با استفاده از داده های بارش روزانه، جریان و غلظت رسوب و توسط روش های برنامه ریزی بیان ژن، شبکه عصبی و سیستم استنتاج فازی-عصبی تطبیقی پیش‌بینی گردید. نتایج نشان داد روش برنامه ریزی بیان ژن در پیش‌بینی بار رسوب معلق روزانه عملکرد بهتری نسبت به دو روش دیگر دارد. et al Kakaei Lafdani (۲۰۱۳) با استفاده از دو مدل شبکه

³ Quebrada Blanca Station

⁴ Eel

¹ Support Vector Machine

² Gene Expression Programming

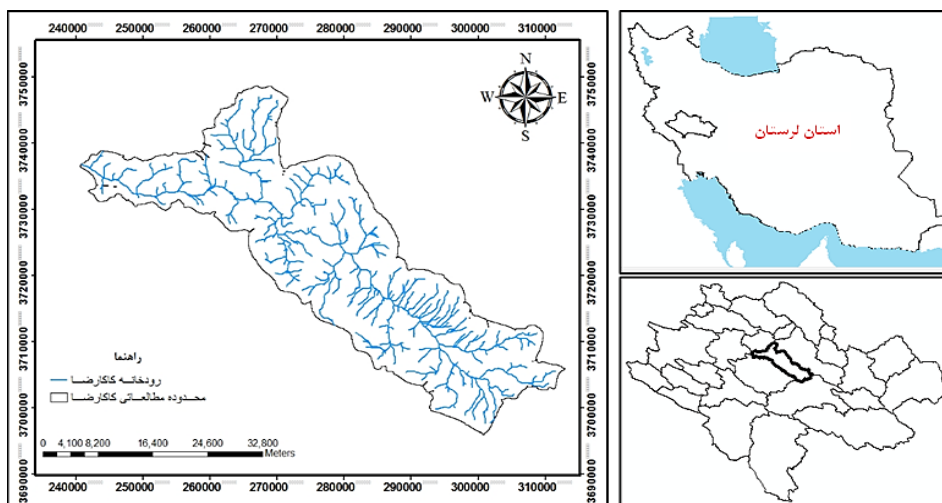
مواد و روش ها

منطقه مورد مطالعه

منطقه مورد مطالعه رودخانه کاکارضا واقع در استان لرستان می‌باشد. این رودخانه از رودخانه‌های دائمی استان لرستان بوده و از کوه‌های جنوب شرقی شهرستان الشتر و بخش چغلوندی (هرود) سرچشمه گرفته و در محدوده شهرستان الشتر بنام کاکارضا معروف است. این رودخانه بین " ۱۵ ° ۴۸ تا ۴۹ ° درجه طول شرقی و " ۲۲ ° ۳۲ الی " ۵۲ ° ۳۳ درجه عرض شمالی و در استان لرستان و شرق شهرستان خرم‌آباد واقع شده است و قسمتی از سرشاخه‌های رودخانه کرخه را در زاگرس تشکیل می‌دهد. رودخانه کاکارضا در ارتفاع ۱۵۵۰ متری از سطح آبهای آزاد قرار دارد. مساحت حوضه کاکارضا ۱۱۴۸ کیلومترمربع و دارای رودخانه‌ای بطول ۸۵ کیلومتر می‌باشد. رودخانه کاکارضا پس از پیوستن به رودخانه‌های کشکان، سیمره و کرخه، در نهایت به خلیج فارس می‌ریزد. که در شکل ۱ موقعیت جغرافیایی منطقه مورد مطالعه نشان داده شده است. در این پژوهش جهت برآورد بار رسوبی معلق رودخانه کاکارضا از داده‌های ماهانه دبی رسوب (تن در روز)، بارش (میلی متر)، دبی جریان (مترمکعب بر ثانیه) و میزان مواد جامد محلول در آب (میلی گرم در لیتر) مربوط به ایستگاه کاکارضا در طی سال آماری ۱۳۷۳-۱۳۹۳ که از شرکت آب منطقه ای استان لرستان اخذ شد، استفاده گردید. همچنین محدوده تغییرات و مشخصات آماری پارامترهای مذکور در جدول ۱ ارائه شده است.

عصبی مصنوعی و ماشین بردار پشتیبان به پیش بینی بار معلق رسوب روزانه رودخانه دویرج پرداختند و نشان دادند مدل ماشین بردار پشتیبان از دقت و عملکرد قابل قبولی در پیش بینی رسوبات معلق رودخانه برخوردار است. Nourani et al (۲۰۱۶) در پژوهشی دبی رسوبی رودخانه آجی چای را با استفاده از مدل‌های ماشین بردار پشتیبان و مدل‌های آماری برآورد نموده و پس از مقایسه نتایج، دریافتند که مدل ماشین بردار پشتیبان از دقت بالاتری برخوردار است. Buyukyildiz and Kumcu (۲۰۱۷) عملکردمدلهای ماشین بردار پشتیبان، شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی را جهت پیش بینی دبی رسوبی رودخانه کور^۱ واقع در شمال شرقی ترکیه مورد بررسی قرار دادند و نشان دادند مدل ماشین بردار پشتیبان در پیش بینی دبی رسوبی نسبت به سایر روش‌های هوشمند از دقت قابل توجهی برخوردار است. در مجموع با توجه به پژوهشهای انجام شده و ذکر این نکته که رودخانه کاکارضا یکی از مهمترین رودخانه‌های پرآب استان لرستان و مهم ترین منبع تأمین کننده آب بخش‌های مختلف نواحی مجاور خود می‌باشد، که در طی دهه‌های گذشته از میزان جریان خروجی این رودخانه در حوضه کاسته شده است و این امر می‌تواند بموجب افزایش رسوب گذاری در بستر رودخانه ایجاد شده است بنابراین اهمیت مدل سازی دبی رسوب آب این رودخانه و اقدامات مدیریتی جهت بهبود کیفیت آب آن بیش از پیش ضروری است. لذا هدف از این تحقیق تخمین دبی رسوبی رودخانه کاکارضا با استفاده از مدل ماشین بردار پشتیبان که بر مبنای استفاده از اصل استقرای کمینه‌سازی خطای ساختاری است و در شبیه‌سازی، با بکارگیری روش یادگیری با نظارت در توابع پایه شعاعی باعث می‌شود تخمین پارامتر از سرعت‌بالا و خطای کمتری نسبت به سایر توابع کرنل داشته باشد (Vapnik, ۱۹۹۵؛ Vapnik, ۱۹۹۸)، است.

^۱ Coruh



شکل ۱- منطقه مورد مطالعه

جدول ۱- خصوصیات آماری پارامترهای مورد استفاده جهت مدل سازی دبی رسوبی

چولگی	ضریب تغییرات	انحراف		پارامتر		
		معیار	ماکزیمم	میانگین	مینیمم	دبی (Q) بر حسب متر مکعب بر ثانیه
۰/۹۷۷	۱/۱۴۵	۵۶/۴۸۴	۳۷۰/۷۴۰	۱۴/۴۷۸	۰	بارش (P) بر حسب میلی متر
۰/۷۵۷	۰/۲۸۴	۶۳/۸۶۲	۴۸۴	۲۲۴/۱۷۰	۱۱۲	مواد جامد محلول در آب (TDS) بر حسب میلی گرم در لیتر
۲/۸۹۲	۱/۹۶۸	۱۴۶/۰۴۵	۸۳۶/۶۹۲	۷۴/۱۷۴	۰/۳۲۴	دبی رسوبی (Q _s) بر حسب تن در روز

ماشین بردار پشتیبان

چنانچه W^T ترانهاده بردار ضرایب و b ثابت مشخصه‌های تابع رگرسیونی و \emptyset نیز تابع کرنل باشد، آنگاه هدف پیدا کردن فرم تابعی برای $f(x)$ است. این مهم با آموزش مدل SVM توسط مجموعه‌ای از داده‌ها (مجموعه آموزش) محقق می‌شود (Misra et al, 2009). برای محاسبه W و b لازم است تابع خطا (معادله ۳) در مدل SVM- ϵ با در نظر گرفتن شرایط مندرج (قیود) در معادله (۴) و (۵) کمینه شود (Hamel, 2009).

$$\frac{1}{2} W^T . W + C \sum_{i=1}^N \epsilon_i + C \sum_{i=1}^N \epsilon_i^* \quad (3)$$

$$W^T . \emptyset (X_i) + b - y_i \leq \epsilon + \epsilon_i^* \quad (4)$$

$$y_i - W^T . \emptyset (X_i) - b \leq \epsilon + \epsilon_i, \quad \epsilon_i, \epsilon_i^* \geq 0, \quad i=1,2,\dots,N \quad (5)$$

در معادلات بالا C عددی صحیح و مثبت است، که عامل تعیین جریمه در هنگام رخ دادن خطای آموزش

ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد (Vapnik, 1995). در مدل رگرسیون SVM تابعی مرتبط با متغیر وابسته Y که خود تابعی از چند متغیر مستقل X است، برآورد می‌شود. مشابه سایر مسائل رگرسیونی فرض می‌شود رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $f(x)$ به علاوه مقداری اغتشاش (خطای مجاز ϵ) مشخص شود (Vapnik, 1998).

$$f(x) = W^T . \emptyset(x) + b \quad (1)$$

$$y = f(x) + \text{noise} \quad (2)$$

سال هشتم • شماره بیست و نهم • پاییز ۱۳۹۶

ثابت، مشابه با آنچه که در الگوریتم ژنتیک استفاده می شود و ساختارهای شاخه‌ای با اندازه‌ها و اشکال متفاوت، مشابه با درختان تجزیه در برنامه‌ریزی ژنتیک، ترکیب می‌شوند. در این روش پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و مجموعه‌ای از ترمینال‌ها، مدل‌سازی می‌شوند. مجموعه توابع، معمولاً شامل توابع اصلی حسابی {+, -, ×, /}، توابع مثلثاتی یا هر نوع تابع ریاضی دیگر {√, x2, exp, log, sin, cos, ...} و یا توابع تعریف شده توسط کاربر است که معتقد است، می‌توانند برای تفسیر مدل مناسب باشند. مجموعه ترمینال‌ها، از مقادیر ثابت و متغیرهای مستقل مسأله تشکیل شده‌اند. برای به‌کارگیری روش برنامه‌ریزی بیان ژن از نرم افزار GenXproTools 4.0 استفاده گردید.

معیارهای ارزیابی

در این تحقیق به منظور ارزیابی دقت و کارایی مدل ها، از نمایه های ضریب همبستگی (R)، جذر میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) طبق روابط زیر استفاده گردید. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و صفر می باشد.

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (9)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (10)$$

$$MAE = \frac{1}{n} \sum |x_i - y_i| \quad (11)$$

در روابط بالا، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد گام های زمانی، \bar{x} و \bar{y} نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی- محاسباتی نسبت به زمان نیز جهت تحلیل بیشتر نتایج استفاده شده است.

نتایج پژوهش

یکی از مهمترین مراحل در مدلسازی، انتخاب ترکیب مناسبی از متغیر های ورودی است. در مدل های هوشمند انتخاب ورودی های اولیه مناسب و تاثیرگذار در پدیده بمنظور آموزش ماهیت سازوکار حاکم بر پدیده باعث

مدل است. \emptyset تابع کرنل، N تعداد نمونه‌ها و دو مشخصه ϵ_1^* و ϵ_i متغیرهای کمبود هستند. در نهایت تابع SVM رگرسیونی را می‌توان به فرم زیر بازنویسی کرد:

$$f(x) = \sum_{i=1}^N \bar{\alpha}_i \emptyset(x_i)^T \cdot \emptyset(x) + b \quad (6)$$

در معادله ϵ ، $\bar{\alpha}_i$ میانگین ضرایب لاگرانژ می‌باشد. محاسبه $\emptyset(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد (Yoon et al, 2011). برای حل این مشکل روند معمول در مدل SVM رگرسیون انتخاب یک تابع کرنل به صورت رابطه زیر است.

$$K(X_j, X) = \emptyset(X_j)^T \sqrt{b^2 - 4ac} \quad (7)$$

می‌توان از توابع مختلف کرنل برای ساخت انواع مختلف SVM- ϵ استفاده کرد. انواع توابع کرنل قابل استفاده در مدل SVM رگرسیونی عبارتند از: کرنل چندجمله‌ای^۱ و کرنل توابع پایه شعاعی^۲ (RBF) و کرنل خطی، به ترتیب طبق روابط زیر محاسبه می‌گردند. شکل ۲ ساختار مدل ماشین بردار پشتیبان را نشان می‌دهد. با توجه به اینکه از پرکاربردترین توابع کرنل، کرنل پایه شعاعی، خطی و چند جمله ای می باشد (Basak et al, 2007؛ Vapnik and Chervonenkis, 1991) در این پژوهش از این سه تابع کرنل استفاده شده است. قابل ذکر است فرآیند محاسبات ماشین بردار پشتیبان براساس کدنویسی در محیط متلب انجام، و پارامترهای توابع کرنل از طریق سعی و خطا بهینه گردیدند.

$$k(x, x_j) = (t + x_i \cdot x_j)^d \quad (8)$$

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (9)$$

$$k(x, x_j) = x_i \cdot x_j \quad (10)$$

برنامه ریزی بیان ژن

روش برنامه ریزی بیان ژن، در سال ۱۹۹۹ توسط فریرا ارائه شد (Ferreira, 2001). این روش ترکیبی از روش های برنامه‌ریزی ژنتیک (GP) و الگوریتم ژنتیک بوده (GA) که در آن، کروموزوم‌های خطی و ساده با طول

1. Polynomial
2. Radial Basis Functions (RBF)

نتایج ماشین بردار پشتیبان

به منظور پیش بینی دبی رسوبی رودخانه کاکارضا از مدل SVM استفاده شد. در این پژوهش ابتدا به منظور کاهش دامنه تغییرات داده های دبی رسوبی رودخانه کاکارضا به همسان سازی اطلاعات ورودی و خروجی، بر روی داده ها استاندارد سازی صورت گرفت. در مرحله بعد مقادیر بهینه مشخصه های مدل SVM شامل ϵ و C تعیین می گردد. همچنین در این پژوهش تابع کرنل های مختلفی، از جمله توابع پایه شعاعی، چند جمله ای و خطی انتخاب شد چرا که از دقت بهتری در برآورد دبی رسوبی رودخانه ها برخوردار است (Lin et al, 2006؛ Liong and Sivapragasam, 2002). در این تابع نیز مشخصه γ بایستی تعیین گردد. بنابراین در حالت کلی برای پیش بینی دبی رسوبی رودخانه کاکارضا بوسیله مدل SVM رگرسیونی، لازم است که مقادیر بهینه سه مشخصه مذکور محاسبه گردد که بدین منظور دو مشخصه ϵ و C توسط الگوریتم بهینه سازی جستجوی شبکه و متغیر γ نیز به صورت آزمون و خطا محاسبه شد. البته قابل ذکر است که الگوریتم بهینه سازی جستجوی شبکه بسیار کند عمل می کند و زمان محاسباتی زیادی را به خود اختصاص می دهد. برای حل این مشکل از برنامه اصلاح شده الگوریتم جستجوی شبکه در پژوهش Chen and Yu (2007) که به نام الگوریتم جستجوی شبکه دو مرحله ای معروف است به همراه اعتبار سنجی متقاطع استفاده شد. برای این منظور ابتدا با انتخاب شبکه های با ابعاد بزرگ، محدوده مشخصه های ϵ و C به ازای مقدار ثابت مشخصه γ تعیین شد. سپس با مشخص شدن محدوده مذکور و تقسیم آن به شبکه های با ابعاد ریزتر مقادیر دقیق دو مشخصه ϵ و C مشخص شدند. روند مذکور برای دیگر مقادیر γ نیز تکرار شد و بدین طریق مدل های متفاوتی با تغییر در مقدار γ حاصل شدند. حال می توان از بین مدل های توسعه داده شده، مدل با کمترین خطا را تعیین کرده و مشخصه های آن را به عنوان مقادیر بهینه ϵ ، C و γ انتخاب نمود. نتایج حاصل از مدل SVM در جدول ۴ ارائه شده است. با توجه به جدول مذکور ساختار ترکیبی شماره ۳ با تابع کرنل پایه شعاعی دارای بیشترین میزان ضریب همبستگی

بهبود عملکرد خواهد شد بنابراین در الگوسازی دبی رسوبی ماهانه رودخانه کاکارضا نیز سعی گردید تا موثرترین پارامترها جهت آموزش مدل ها انتخاب شود که در جدول ۲ نشان داده شده است (ستاری و همکاران، ۱۳۹۵؛ Nourani et al, 2016). در این پژوهش به منظور پیش بینی دبی رسوبی رودخانه کاکارضا از داده های ماهانه ایستگاه هیدرومتری این رودخانه در طول دوره آماری از سال ۱۳۷۳ تا ۱۳۹۳ استفاده شد. جهت مدلسازی، پارامترهای دبی جریان (Q)، میزان مواد جامد محلول در آب (TDS) و بارش (P) بعنوان ورودی و دبی رسوبی (Q_s) بعنوان پارامتر خروجی مدلهای بکار برده شد. همچنین در جدول ۳ همبستگی متقابل بین پارامترهای ورودی و خروجی نشان داده شده است با توجه به اینکه مقدار همبستگی متقابل بین داده های ورودی و خروجی که مطابق جدول ۳ بیشتر از ۰/۷۵۰ حاصل شد، ترکیب های مختلفی از پارامترهای ورودی به منظور دستیابی به مدل بهینه جهت تخمین بارش ماهانه دشت کاکارضا استفاده گردید که در جدول ۲ قابل مشاهده است. لازم به ذکر است جهت مدلسازی ۸۰ درصد داده ها برای آموزش و ۲۰ درصد باقی مانده جهت تست، بصورت تصادفی، که گستره وسیعی از انواع داده ها را پوشش دهد، انتخاب شد (Kisi and Karahan, 2006؛ Nagy et al, 2002). در ادامه نتایج مدل های مورد استفاده ارائه می گردد.

جدول ۲- ترکیب های منتخب پارامترهای ورودی مدل های

ماشین بردار پشتیبان و برنامه ریزی بیان ژن

شماره	ساختار ورودی	خروجی
۱	$Q(t)$	$Q_s(t)$
۲	$Q(t), P(t)$	$Q_s(t)$
۳	$Q(t), TDS(t), P(t)$	$Q_s(t)$

جدول ۳- همبستگی متقابل بین پارامترهای ورودی و خروجی

	$Q(t)$	$P(t)$	$TDS(t)$
$Q_s(t)$	۰/۸۵۰	۰/۸۱۰	۰/۷۵۰


سال هشتم • شماره بیست و نهم • پاییز ۱۳۹۶

است، ملاحظه می گردد که این مدل در تخمین اکثر مقادیر دقت قابل قبولی داشته بگونه ای که این مقادیر را نزدیک به مقدار واقعیشان برآورد کرده است. نتایج بدست آمده با پژوهش های Buyukyildiz and Kumcu (۲۰۱۷) و Nourani et al (۲۰۱۵) همخوانی دارد. علت این امر را می توان اینگونه بیان نمود با توجه به اینکه ماشین بردار پشتیبان بر مبنای استفاده از اصل استقرای کمینه سازی خطای ساختاری است بنابراین در شبیه سازی، با بکارگیری روش یادگیری با نظارت در توابع پایه شعاعی باعث می شود تخمین پارامتر از سرعت بالا و خطای کمتری نسبت به سایر توابع کرنل داشته باشد و این یکی از ویژگی های ممتاز توابع پایه شعاعی محسوب می شود.

$R=0/867$ و کمترین جذر مربعات خطا $RMSE=0/24\text{ton/day}$ و کمترین میانگین قدر مطلق خطا $MAE=0/017\text{ton/day}$ در مرحله صحت سنجی جواب بهتری نسبت به سایر ساختارها از خود نشان داده است. همچنین با توجه به جدول ۴ مشاهده میگردد مدل ماشین بردار پشتیبان عملکرد بالایی در تخمین دبی رسوبی حوضه کاکارضا حتی در صورت استفاده از تنها یک پارامتر ورودی نیز از خود نشان داده است که این امر سبب می شود در مناطقی که نواقص آماری وجود دارد این شبکه با در اختیار داشتن پارامترهای ورودی حداقل نظیر دبی جریان عملکرد قابل قبولی در پیش بینی دبی رسوبی داشته باشد. در شکل ۲ نیز تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان نشان داده شده

جدول ۴- تحلیل نتایج مدل ماشین بردار پشتیبان برای ساختارهای مختلف ورودی دبی رسوبی

شماره	کرنل	آموزش			صحت سنجی		
		MAE (ton/day)	RMSE (ton/day)	R	MAE (ton/day)	RMSE (ton/day)	R
۱	توابع پایه شعاعی	۰/۷۸۳	۰/۱۰۲	۰/۸۰۲	۰/۰۲۷	۰/۰۳۶	۰/۸۰۲
	چند جمله ای	۰/۷۷۴	۰/۱۰۷	۰/۷۹۲	۰/۰۳۴	۰/۰۴۲	۰/۷۹۲
	خطی	۰/۷۵۸	۰/۱۱۵	۰/۷۸۶	۰/۰۴۷	۰/۵۳۰	۰/۷۸۶
۲	توابع پایه شعاعی	۰/۸۱۴	۰/۰۸۹	۰/۸۴۶	۰/۰۲۸	۰/۰۴۰	۰/۸۴۶
	چند جمله ای	۰/۷۹۱	۰/۱۰۸	۰/۸۲۳	۰/۰۳۳	۰/۰۵۴	۰/۸۲۳
	خطی	۰/۷۸۴	۰/۱۱۶	۰/۸۰۵	۰/۰۳۹	۰/۰۶۱	۰/۸۰۵
۳	توابع پایه شعاعی	۰/۸۱۹	۰/۰۸۸	۰/۸۶۷	۰/۰۱۷	۰/۰۲۴	۰/۸۶۷
	چند جمله ای	۰/۸۰۷	۰/۰۹۷	۰/۸۵۱	۰/۰۲۱	۰/۰۳۵	۰/۸۵۱
	خطی	۰/۷۹۸	۰/۱۰۴	۰/۸۴۵	۰/۰۲۷	۰/۰۴۳	۰/۸۴۵



شکل ۲- نمودار مقادیر مشاهداتی و محاسباتی حاصل از مدل ماشین بردار پشتیبان در مرحله آموزش و صحت سنجی

نتایج برنامه ریزی بیان ژن

استفاده از برنامه ریزی بیان ژن به دلیل قابلیت و توانایی مدل در انتخاب متغیرهای مؤثر و حذف متغیرهایی با تأثیر کمتر و همچنین توانایی ارائه رابطه صریح جهت مدلسازی دبی رسوبی رودخانه کارضا مد نظر قرار گرفت. بدین منظور هر سه ورودی برای تعیین متغیرهای معنی دار استفاده، و جهت بررسی بیشتر علاوه بر مجموعه چهار عملگر اصلی (F2)، حالتی بر اساس عملگرهای ریاضی پیش فرض برنامه (F1) لحاظ گردیده است.

جدول ۵- مقادیر پارامترهای مورد استفاده با استفاده از روش برنامه ریزی بیان ژن

تنظیمات کلی	عملگرهای ژنتیکی
تعداد کروموزوم ها	۳۰ نرخ جهش ۰/۰۴۴
اندازه راس	۸ نرخ وارون سازی ۰/۱
تعداد ژن ها در هر کروموزوم	۳ نرخ ترانسپوز درج متوالی ۰/۱
تعداد جمعیت تولیدی	۱۰۰۰ نرخ ترانسپوز جذر درج متوالی ۰/۱
تابع پیوند	جمع نرخ ترکیب تک نقطه ایی (+) ۰/۳
تابع برازش معیار خطا	RMSE نرخ ترکیب دو نقطه ایی ۰/۳
	نرخ ترکیب ژن ۰/۱
	نرخ ترانسپوز ژن ۰/۱

همچنین در این پژوهش جهت ساخت درخت تجزیه و تولید یک جمعیت اولیه از راه حل هایی استفاده شد که این راه حل ها از ترکیب تصادفی مجموعه توابع (عملگرهای ریاضی مورد استفاده در فرمول ها) و ترمینال ها (متغیرهای مسئله و اعداد ثابت) ایجاد می شوند. نحوه و دلیل انتخاب این نوع عملگرها با توجه به مطالعات (Ghorbani et al, ۲۰۱۲؛ Khatibi et al, ۲۰۱۲) صورت گرفته است.

$$F1: \{+, -, *, /, \sqrt, \sqrt[3], \exp, \ln, 2^, 3^, \sin, \cos, \operatorname{atan}\} \quad (12)$$


$$F2: \{+, -, *, /, \} \quad (13)$$

با توجه به نتایج مطالعات قبلی، پارامترهای مورد استفاده و نرخ آنها در استخراج مدل های پیش بینی دبی رسوبی با استفاده از روش برنامه ریزی بیان ژن استخراج گردید، به طور خلاصه در جدول ۵ ارائه شده اند.

نتایج بدست آمده از اجرای مدل برنامه ریزی بیان ژن با هر دو عملگر و ساختارهای مختلف در جدول ۶ ارائه شده است. مشاهده می گردد که ساختار ترکیبی شماره ۳ و عملگر F2 در هر دو مرحله آموزش و صحت سنجی با بیشترین ضریب همبستگی $R=0.823$ و جذر میانگین مربعات خطا $RMSE=0.052 \text{ ton/day}$ و میانگین قدر مطلق خطا $MAE = 0.043 \text{ ton/day}$ نسبت به سایر ساختارها و عملگرها از دقت بیشتری برخوردار بوده است. بنابراین برنامه ریزی بیان ژن با عملگر F2 شامل چهار عملگر اصلی ریاضی، با وجود رابطه ساده ریاضی بیشترین دقت را در مدلسازی دبی رسوبی حوضه کارضا داشته است. نمودار مقادیر بهینه محاسباتی و مشاهداتی برنامه ریزی بیان ژن مربوط به مرحله آموزش و صحت سنجی در شکل ۳ نشان داده شده است. همانطور که از شکل مشخص است مدل برنامه ریزی ژن نتوانسته است در تخمین نقاط بیشینه دقت قابل قبولی ارائه دهد. که این نتایج با پژوهش های امامقلی زاده و همکاران (۱۳۹۵) و Kisi and Shiri (۲۰۱۲) همخوانی دارد و میتوان بیان نمود معادله حاصل از برنامه ریزی بیان ژن، از ترکیب تصادفی مجموع ترمینال ها و توابع بدست می آید بنابراین اگر رابطه بین ورودی ها و خروجی ها خطی باشد ولی عملگرهای \sin ، \cos و... در مجموعه توابع انتخاب شود برنامه ریزی بیان ژن در استخراج رابطه از آن عملگرهای انتخابی استفاده می کند که این امر باعث کاهش دقت مدل می شود که در این پژوهش جهت افزایش دقت مدل عملگرهای \sin ، \cos و... کاربرد ندارد و نیز با توجه به دقت و سادگی، مدل حاصل از چهار عمل اصلی ریاضی جهت تخمین میزان بار رسوبی پیشنهاد شد.

جدول ۶- تحلیل نتایج مدل برنامه ریزی بیان ژن برای ساختارهای مختلف ورودی دبی رسوبی

صحت سنجی			آموزش			عملگر	شماره
MAE (ton/day)	RMSE (ton/day)	R	MAE (ton/day)	RMSE (ton/day)	R		
۰/۰۵۵	۰/۰۶۳	۰/۷۹۵	۰/۰۷۵	۰/۱۰۲	۰/۷۸۳	F1	۱
۰/۰۴۲	۰/۰۵۶	۰/۸۰۴	۰/۰۶۳	۰/۰۹۴	۰/۷۹۱	F2	
۰/۰۳۱	۰/۰۵۳	۰/۸۱۵	۰/۰۵۸	۰/۰۹۵	۰/۸۰۳	F1	۲
۰/۰۲۸	۰/۰۴۱	۰/۸۲۹	۰/۰۴۹	۰/۰۸۹	۰/۸۱۳	F2	
۰/۰۴۳	۰/۰۵۲	۰/۸۲۳	۰/۰۷۳	۰/۰۹۷	۰/۸۱۸	F1	۳
۰/۰۲۷	۰/۰۳۴	۰/۸۴۷	۰/۰۵۲	۰/۰۸۵	۰/۸۳۰	F2	



شکل ۳- نمودار مقادیر مشاهداتی و محاسباتی حاصل از مدل برنامه ریزی بیان ژن در مرحله آموزش و صحت سنجی

مقایسه و ارزیابی عملکرد مدلها

در ادامه با انتخاب جواب بهینه هر کدام از مدل های هوشمند و مقایسه آنها با یکدیگر مشخص گردید، هر دو مدل با دقت خوبی توانسته اند دبی رسوبی رودخانه کاکارضا را شبیه سازی کنند. براساس جدول ۷ از بین مدل های به کار رفته، مدل ماشین بردار پشتیبان با بیشترین دقت $0/867$ و کمترین جذر میانگین مربعات خطا $0/024$ تن در روز و کمترین میانگین قدر مطلق خطا $0/017$ تن در روز در مرحله صحت سنجی انتخاب شد. مقایسه نتایج مدل های ماشین بردار پشتیبان با مدل برنامه ریزی بیان ژن حاکی از نزدیک بودن نتایج این دو مدل می باشد. در شکل ۴ نتایج مدل انتخاب شده دبی رسوبی در هر دو روش نسبت به مقادیر مشاهداتی نشان داده شده است، بگونه ای که هر دو مدل در تخمین اکثر مقادیر خوب عمل کرد است. با این حال مدل ماشین بردار پشتیبان این توانایی را داشته است که مقادیر کمینه، بیشینه و میانی را به خوبی پوشش دهد. همانطور که

در شکل ۴ مشخص است مدل ماشین بردار پشتیبان در تخمین نقاط مشاهداتی حداقل و حداکثر دبی رسوبی عملکرد قابل قبولی از خود نشان داده است در حالیکه مدل برنامه ریزی بیان ژن در تخمین نقاط مشاهداتی


حداکثر توانی قابل قبولی نداشته است و این امر نشان از برتری مدل ماشین بردار پشتیبان نسبت به برنامه ریزی بیان ژن می باشد. همچنین با توجه به نتایج هر دو مدل مذکور، ساختار ترکیبی شماره ۳ بیشترین دقت را از بین سه ساختار مورد بررسی از خود نشان داده است بنابراین میتوان اظهار نمود که علاوه بر دبی و بارش، میزان مواد جامد محلول در آب در میزان رسوب پایین دست نقش بسزایی دارد بدین صورت که میزان مواد جامد محلول در آب با ذرات معلق رسوب در منطقه مورد مطالعه ارتباط داشته و موجب کاهش میزان رسوب در این منطقه شده است. نتایج حاصل از استفاده از ساختارهای ترکیبی شامل پارامترهای ورودی در این پژوهش نشان داد افزایش تعداد

این می‌باشد که علت آن افزایش تعداد پارامترهای موثر در ورودی و به دنبال آن گسترش حافظه مدل جهت تخمین مقادیر خروجی می باشد. همچنین باعث گردیده تعداد داده ها جهت آموزش شبکه بیشتر شده و شبکه بخوبی تعمیم داده شود.

پارامترهای موثر در مدل های مختلف جهت شبیه سازی دبی رسوبی موجب عملکرد بهتر در مدلسازی می شود. که این نتایج با پژوهش ستاری و همکاران (۱۳۹۵) و رجبی و همکاران (۱۳۹۴) همخوانی دارد. تجزیه و تحلیل نتایج پژوهش های مذکور بیان کننده

جدول ۷- تحلیل نتایج مدل‌های ماشین بردار پشتیبان و برنامه ریزی بیان ژن برای ساختارهای مختلف ورودی دبی رسوبی

صحت سنجی			آموزش			مدل
MAE (ton/day)	RMSE (ton/day)	R	MAE (ton/day)	RMSE (ton/day)	R	
۰/۰۱۷	۰/۰۲۴	۰/۸۶۷	۰/۰۴۴	۰/۰۸۸	۰/۸۱۹	ماشین بردار پشتیبان
۰/۰۲۷	۰/۰۳۴	۰/۸۴۷	۰/۰۵۲	۰/۰۸۵	۰/۸۳۰	برنامه ریزی بیان ژن



شکل ۴- نمودار مقادیر مشاهداتی و محاسباتی حاصل از مدل‌های ماشین بردار پشتیبان و برنامه ریزی بیان ژن در مرحله آموزش و صحت سنجی

سازای دبی رسوبی موجب عملکرد بهتر در مدلسازی می شود. علاوه برآن مشاهده گردید در مدل ماشین بردار پشتیبان با داشتن حداقل پارامترهای ورودی قادر به پیش بینی دبی رسوبی با دقت بالایی می باشد. که این موضوع بخصوص در ایستگاه هایی که با نواقص آماری مواجه می باشند می تواند کمک شایانی به برآورد پارامتر مورد نظر نماید. همچنین تحلیل نتایج حاصل از معیارهای ارزیابی نشان داد مدل ماشین بردار پشتیبان دقت بالاتر و خطای کمتری نسبت به برنامه ریزی بیان ژن دارد، که نشان می‌دهد مدل ماشین بردار پشتیبان می‌تواند به عنوان ابزاری کارآمد در زمینه پیش بینی دبی رسوبی رودخانه ها

نتیجه گیری

در این پژوهش سعی بر آن شد عملکرد مدل های هوشمند جهت شبیه سازی دبی رسوبی رودخانه کاکارضا واقع در استان لرستان مورد ارزیابی قرار گیرد. مدل های به کار گرفته شده شامل ماشین بردار پشتیبان و برنامه ریزی بیان ژن می باشد. مقادیر دبی رسوبی مشاهداتی با دبی رسوبی تخمین زده شده در مدل های مذکور (ماشین بردار پشتیبان و برنامه ریزی بیان ژن)، با استفاده از معیارهای ارزیابی مورد مقایسه قرار گرفت. نتایج حاصل از بررسی ساختارهای ورودی مدلها در این پژوهش نشان داد افزایش تعداد پارامترهای موثر در مدل های مختلف جهت شبیه

سال هشتم • شماره بیست ونهم • پاییز ۱۳۹۶

مدیریت آب های سطحی مفید بوده و استفاده از آنها گامی در اتخاذ تصمیمات مدیریتی در جهت بهبود کمیت جریان رودخانه ها است.

مورد استفاده قرار گیرد. علاوه بر آن نتایج بدست آمده از این پژوهش نشان داد که مدل های هوشمند در نوبه خود برای تسهیل توسعه و پیاده سازی استراتژی های

منابع

- امامقلی زاده، ص. ر. کریمی دمنه. و خ. اژدری. ۱۳۹۵. مقایسه ی روشهای متداول برآورد بار رسوب معلق رودخانه ی کرخه با روش برنامه ریزی بیان ژن. نشریه جغرافیا و توسعه، سال ۱۴، شماره ۴۵، ص ۱۲۲-۱۴۰
- آوردیده، ف.م.، بنی حبیب . و ا. طاهرشمسی. ۱۳۸۰. کاربرد شبکه های عصبی مصنوعی جهت تخمین دبی رسوب رودخانه ها. سومین کنفرانس هیدرولیک ایران، دانشگاه تهران، تهران.
- ثانی خانی، ه.، م. نیک پور. ر. فرسادی زاده، د. و م. م. معیری. ۱۳۹۴. پیش بینی بار معلق رودخانه با استفاده از سامانه های هوشمند. نشریه پژوهش آب ایران، سال ۹، شماره ۲، ص ۱۶۵-۱۶۸
- داننده مهر، ع.ا.، علیایی، و م. ع. قربانی. ۱۳۸۹. پیش بینی بار معلق رودخانه ها بر مبنای دبی جریان با استفاده از برنامه ریزی ژنتیک. نشریه پژوهش های آبخیزداری، سال ۲۳، شماره ۳، ص ۴۴-۵۴
- دهقانی، ر.م.، قربانی، ع.، تشنه لب، م.، ریخته گر غیائی، ا. و ا. اسدی. ۱۳۹۴. مقایسه و ارزیابی مدل های شبکه عصبی بیزین، برنامه ریزی بیان ژن، ماشین بردار پشتیبان و رگرسیون خطی در تخمین بده جریان؛ مطالعه موردی حوضه صوفی چای. نشریه آبیاری و آب ایران، سال پنجم، شماره بیستم، ص ۶۶-۸۵
- رجبی، م.م. فیض اله پور، و ش. روستایی. ۱۳۹۴. استفاده از مدل تبرید تدریجی عصبی (NDE) در تخمین بار معلق رسوبی و مقایسه ی آن با مدل ANFIS و RBF مطالعه موردی: رودخانه گیوی چای. نشریه جغرافیا و توسعه، جلد ۳۹، شماره ۱۳، ص ۱-۱۶
- ستاری، م. ت.، رضازاده جودی، ع. صفدری، ف. و ف. قهرمانزاده. ۱۳۹۵. ارزیابی عملکرد روش های مدل درختی M5 و رگرسیون بردار پشتیبان در مدل سازی رسوب معلق رودخانه. نشریه حفاظت منابع آب و خاک، سال ۶، شماره ۱، ص ۱۱۰-۱۲۴
- قربانی، م. ع. و ا. صالحی. ۱۳۹۰. استفاده از برنامه ریزی بیان ژن در بررسی تغییرات داده های کیفی آب زیرزمینی با نوسانات سطح آب در دشت برخوردار اصفهان. ششمین کنگره ملی مهندسی عمران
- Aytek, A., and O. Kisi. 2008. A Genetic Programming Approach to Suspended Sediment Modelling. *Hydrology*, 351: 288-298.
- Basak, D., S. Pal, and D. C. Patranabis. 2007. Support vector regression. *Neural Inf. Process*, 11: 203-225.
- Buyukyildiz, M. and S. Y. Kumcu. Y. 2017. An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models. [Water Resources Management](#), 31(2):1-17
- Chen S.T., and P. S. Yu. 2007. Real-time probabilistic forecasting of flood stages. *Journal of Hydrology*, 340(2):63-77
- Ferreira, C. 2001. Gene expression programming: a new adaptive algorithm for solving problems. *Complex Systems*, 13(2): 87-129.
- Ghorbani, M.A., R. Khatibi, H. Asadi, and P. Yousefi. 2012. Inter- Comparison of an Evolutionary Programming Model of Suspended Sediment Time-series whit other Local Model. *INTECH*. doi. org/10.5772/47801,: 255-282.
- Hamel, L. 2009. *Knowledge Discovery with Support Vector Machines*, Hoboken, N.J. John Wiley.

- Kakaei Lafdani, E., A. Moghaddam Nia, and A. Ahmadi. 2013. Daily suspended sediment load prediction using artificial neural networks and support vector machines, *Hydrology*, 478: 50-
- Khatibi, R., L. Naghipour, M. A. Ghorbani, and M. T. Aalami. 2012. Predictability of relative humidity by two artificial intelligence techniques using noisy data from two Californian gauging stations. *Neural computing and application*, 23(7):.643-941.
- Kisi, O., and A. Guven. 2010. A machine code-based genetic programming for suspended sediment concentration estimation. *Advanced in Engineering Software*, 41(7):939-945.
- Kisi, O., and J. Shiri. 2012. River suspended sediment estimation by climatic variables implication: Comparative study among soft computing techniques. *Computers & Geosciences*, 43(4):73-82
- Kisi, O., M. Karahan, and Z. Sen. 2006. River suspended sediment modeling using fuzzy logic approach". *Hydrol Process*, 20: 4351-4362.
- Lin, J.Y., C. T. Cheng, and K. W. Chau. 2006. Using support vector machines for long-term discharge prediction. *Hydrolog Sci J*, 51(3):599-612
- Liong, S.Y., and C. Sivapragasam. 2002. Flood stage forecasting with support vector machines. *J Am Water Resour*, 38(4):173-186
- Misra, D., T. Oommen, A. Agarwa, S. K. Mishra, and A. M. Thompson. 2009. Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosyst Eng*, 103(3): 527-535
- Nagy, H., K. Watanabe, and M. Hirano. 2002. Prediction of sediment load concentration in rivers using artificial neural network model, *Journal of Hydraulics Engineering*, 128: 558-559.
- Nourani, V., F. Alizadeh, and K. Roushangar. 2016. Evaluation of a Two-Stage SVM and Spatial Statistics Methods for Modeling Monthly River Suspended Sediment Load. [Water Resources Management](#), 30(1):393-407
- Vapnik, V.N. 1995. *The Nature of Statistical Learning Theory*. Springer, New York
- Vapnik, V.N. 1998. *Statistical learning theory*. Wiley, New York
- Vapnik, V., and A. Chervonenkis. 1991. The necessary and sufficient conditions for consistency in the empirical risk minimization method. *Pattern Recognition and Image Analysis*, 1(3): 283-305.
- Yoon, H., S. C. Jun, Y. Hyun, G. O. Bae, and K. K. Lee. 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *J Hydrol*, 396(4):128-138

Evaluation and Performance of Support Vector Machine Model in Estimation of Suspended Sediment

Babak Shahi Nejad^{1*}, Reza Dehghani²

Abstract

Sediment transport has been constantly influenced the river and civil structures and the lack of information about its exact amount causes high damages. Achieving to proper procedure is important to estimate the sediment load in rivers. This study used the support vector machine model to estimate the sediments of the Kakareza river placing on Lorestan Province and their results were compared with results obtained by gene expression programming. Parameters including river discharge, rate of dissolved solids and precipitation for time period (1993-2013) were monthly selected. Criteria including correlation coefficient, root mean square error and mean absolute error were used to evaluate and also compare the performance of models. The achieved results showed that combinational patterns using two intelligence models could be investigated and acceptable results were presented for sediment rats. With regards to accuracy, the support vector machine model showed the highest correlation coefficient (0.867), minimum root mean square error (0.024 ton/day) and the mean absolute error (0.017 ton/day) which was initiated at verification stage. Finally, the results showed that the support vector machine has been shown great capability to estimate the minimum and maximum values for sediment discharge.

Keywords: Gene Expression Programming, Suspended Sediment, Kakareza River, Support Vector Machine

¹ Assistant Professor of Water Engineering, University of Lorestan, Khorramabad, Iran
(Corresponding author.; Email: shahinejad.b@lu.ac.ir)

² Ph.D. Student of Water Structure, Faculty of Agric., University of Lorestan, Khorramabad, Iran