



پیش‌بینی بار رسوبی معلق بر مبنای پارامترهای فیزیکی گرافی حوضه

مهدی حیات‌زاده^۱، سحر امینی^۲، علی فتح‌زاده^۳، مریم اسدی^۴

۱- مهدی حیات‌زاده، استادیار آبخیزداری، دانشگاه اردکان، اردکان، ایران

۲- سحر امینی، دانشجوی کارشناسی ارشد آبخیزداری، دانشگاه اردکان، اردکان، ایران

۳- علی فتح‌زاده، دانشیار آبخیزداری، دانشگاه اردکان، اردکان، ایران

۴- مریم اسدی، دانش‌آموخته‌ی دکتری آبخیزداری، دانشگاه تهران، تهران، ایران

تأیید نهایی مقاله: ۱۴۰۰/۰۱/۳۱

وصول مقاله: ۱۳۹۷/۰۹/۱۶

چکیده

بار رسوبی معلق یکی از مهم‌ترین عناصر رودخانه‌ای است که علاوه بر تأثیر بر کیفیت آب، نقش مؤثری در مدیریت منابع آبی و سازه‌های احداثی بر روی این منابع دارد. از طرفی تعیین پارامترهای دقیق و مناسب که تأثیر زیادی در رسوب‌زایی حوضه‌ی آبریز داشته باشند می‌تواند نقش به‌سزایی در افزایش دقت مدل‌های داده‌کاوی در راستای برآورد بار رسوب معلق جریان داشته باشد. از آنجا که پارامترهای فیزیوگرافی که بیانگر ویژگی‌های فیزیکی حوضه‌ی آبریز هستند می‌تواند به عنوان یک فاکتور تعیین‌کننده در میزان رسوب‌زایی حوضه‌ی آبریز مطرح گردد. لذا در این پژوهش با تلفیق مدل‌های داده‌کاوی و پارامترهای فیزیوگرافی، بار رسوب ۳۰ حوضه‌ی آبریز در استان لرستان با دوره‌ی آماری ۳۳ ساله برآورد گردید. به منظور بررسی اثر شاخص‌های مختلف فیزیوگرافی بر میزان برآورد رسوب در گام نخست دبی جریان به عنوان تنها ورودی مدل‌ها و در گام بعدی شاخص‌های مختلف فیزیوگرافی حوضه به عنوان ورودی‌های مدل‌های مختلف داده‌کاوی انتخاب گردید. در این مطالعه از پنج مدل داده‌کاوی از جمله شبکه‌ی عصبی مصنوعی، ماشین بردار پشتیبان تکاملی، درخت تصمیم، فرآیند گوسی و رگرسیون استفاده شد. نتایج نشان داد تمامی مدل‌ها از دقت قابل قبولی برخوردار بودند. در هر دو مجموعه داده، مدل ماشین بردار پشتیبان تکاملی دارای بهترین دقت بود. با به کارگیری شاخص‌های مورد اشاره دقت در تمامی مدل‌ها افزایش یافت به طوری که در مدل ماشین بردار پشتیبان تکاملی میزان میانگین مربعات خطا از ۶/۷۴ به ۳ کاهش یافت و ضریب همبستگی از ۰/۹۹۴ به ۰/۹۹۹ افزایش یافت. وزن‌دهی پارامترها نیز نشان داد که شاخص زبری دارای بیشترین وزن (۱) و کمترین وزن مربوط به نسبت کشیدگی (۰) در برآورد بار رسوبی معلق بوده است.

کلمات کلیدی: بار معلق، پارامترهای فیزیوگرافی، داده‌کاوی، ماشین بردار تکاملی، هوش محاسباتی، استان لرستان

۱- مقدمه

در اغلب رودخانه‌های طبیعی بخش اعظم رسوبات به صورت بار معلق انتقال می‌یابند. بار رسوب معلق رودخانه‌ای که حدود ۷۵ تا ۹۵ درصد کل رسوب رودخانه را شامل می‌گردد، از جنبه‌های مختلف (نظیر مهندسی منابع آب، مسائل زیست‌محیطی، کیفیت آب و غیره) حائز اهمیت بوده و می‌تواند به عنوان شاخصی از وضعیت فرسایش خاک و شرایط اکولوژیک حوضه در نظر گرفته شود (ژو و همکاران^۱، ۲۰۰۷: ۱۱۲؛ طباطبایی و همکاران، ۱۳۹۳: ۹۹). رسوبات معلق حمل شده توسط رودخانه‌ها مشکلات زیادی از جمله ترسیب در مخازن سدها و کاهش حجم مفید آنها، تغییر مسیر رودخانه به دلیل رسوبگذاری در بستر آنها، کاهش ظرفیت عبور کانال‌ها و تاسیسات انتقال آب و افت کیفیت منابع آب به لحاظ مصرف شرب و کشاورزی را به وجود می‌آورند (ذرتی‌پور، ۱۳۹۵: ۶۶؛ یانگ و همکاران^۲، ۲۰۰۹: ۲۷۵). همچنین با توجه به مسائل ناگوار و دیگر آثار محیطی برخاسته از پدیده‌ی فرسایش، برآورد بار رسوب در بسیاری از زمینه‌ها از جمله بررسی‌های ژئومورفولوژیکی فرسایش، رسوبگذاری مخازن، طراحی مخازن و سدها، برنامه ریزی حفاظت خاک و آب، ارزیابی اثرات زیست محیطی و مشکلات مواد مغذی و آلودگی‌های همراه رسوب لازم و ضروری است (اسفندیاری و قراچورلو، ۱۳۹۴: ۱۲۵). روش‌های منحنی سنج که نوعی روش برون‌یابی تلقی می‌شوند در برآورد رسوب معلق به کار می‌روند. در روش‌های منحنی سنج رابطه‌ی بین داده‌های مربوط به اندازه‌گیری‌های غلظت رسوب و دبی جریان در یک دوره‌ی آماری تعیین گشته و با تعمیم این رابطه مقادیر رسوب برون‌یابی می‌گردد. در عین حال برآورد رسوب از طریق این معادله همواره دارای خطا می‌باشد. بنابراین توسعه‌ی روش‌های کارآمد و دقیق برای برآورد رسوب که این محدودیت‌ها را نداشته باشد اهمیت زیادی دارد (اسلمن^۳، ۲۰۰۰: ۸۵؛ فقیه و همکاران، ۱۳۹۴). محققین در مورد پدیده‌ی فرسایش و انتقال رسوب در سال‌های اخیر توانسته‌اند با استفاده از روش‌های هوش مصنوعی به عنوان یک ابزار جدید، مقدار رسوبات معلق را محاسبه نمایند (کاکایی لافدانی و همکاران^۴، ۲۰۱۳: ۵۵؛ ملیسی و همکاران^۵، ۲۰۱۱: ۸۵۹؛ کیسی^۶، ۲۰۱۲: ۱۱۳).

کاربرد شبکه‌های عصبی مصنوعی اولین بار توسط فرنچ در سال ۱۹۹۲ در مباحث مربوط به منابع آب بوده است و از آن پس به‌طور چشم‌گیری در مورد پیش‌بینی سایر فرایندهای اقلیمی و هیدرولوژیکی از جمله پیش‌بینی بار رسوبی رودخانه‌ها مورد استفاده قرار گرفت (چنگ و همکاران^۷، ۲۰۱۵: ۸۷؛ فرنچ و همکاران^۸، ۲۰۰۳: ۳۲). شبکه‌های عصبی ابزار محاسباتی قوی و توانمندی هستند که در سامان‌دهی و ایجاد رابطه بین اطلاعات گوناگون قابلیت‌های بسیار خوبی را از خود ارائه داده‌اند. قابلیت‌های بالای این سامانه‌ها در نگاشت

1. Zhu et al.
 2. Yang at al.
 3. Asselman
 4. Kakaei lafdani et al.

5. Melesse et al.
 6. Kisi
 7. Chang et al.
 8. French et al.

فضاهای با بعد وسیع و همچنین در تحلیل مسائلی که درک آنها با استفاده از روابط پیچیده ریاضی دشوار است، می‌تواند مفید واقع شود. به طور کلی شبکه‌های عصبی مصنوعی در برخورد با مسائلی از قبیل شناسایی سیستم، تقریب و تخمین، بهینه‌سازی، شبیه‌سازی و پیش‌بینی رفتار و نظایر آن نتایج موفقیت‌آمیزی داشته‌اند (کلتله^۱، ۲۰۱۳: ۸۵). در طی سال‌های اخیر روش‌های داده‌کاوی از قبیل شبکه‌های عصبی مصنوعی و منطق فازی به خوبی توانسته‌اند جایگزین روش منحنی سنج که همواره با خطاهای نسبتاً زیادی همراه‌اند شوند. عطائی و همکاران (۱۳۹۸) در پژوهش خود از مدل‌های سنج رسوب، شبکه‌های عصبی مصنوعی (ANN) و برنامه‌ریزی بیان (GEP) برای تخمین بار معلق ایستگاه هیدرومتری مشیران واقع در رودخانه دره رود استفاده کردند. بدین منظور داده‌های اندازه‌گیری شده دبی جریان و بار معلق طی دوره آمار ۱۳۹۴-۱۳۵۰ به کار گرفته شدند و نتایج نشان داد که مدل GEP با دارا بودن بیشترین مقدار ضریب تعیین ($R^2=0.80$) و کمترین ریشه میانگین مربعات خطا ($RMSE=1962$) تطابق بهتری با مقادیر مشاهداتی دارند.

حیات‌زاده و همکاران (۱۳۹۴) با استفاده از روش‌های منحنی سنج و شبکه‌ی عصبی با تلفیق پارامترهای مورفولوژیکی در حوضه‌ی باغ عباس به برآورد رسوب پرداختند و نتیجه گرفتند که دقت شبکه‌ی عصبی مصنوعی بیشتر از منحنی سنج رسوب می‌باشد دستورانی و همکاران (۱۳۹۱) در مطالعه‌ای تحت عنوان برآورد رسوبات معلق با استفاده از شبکه عصبی مصنوعی در حوضه آبریز جامیشان کرمانشاه، به این نتیجه رسیدند که شبکه‌ی عصبی مصنوعی نتایج قابل قبولی را برای بار معلق ارائه می‌دهد و در مقایسه با منحنی سنج رسوب دارای دقت بیشتری می‌باشد. کومار و همکاران^۲ (۲۰۱۶) جهت برآورد بار معلق رودخانه کوپیلی از روش‌های مختلف هیدرولوژیکی و داده‌کاوی استفاده کردند. مقایسه نتایج روش‌های مختلف نشان داد که روش‌های بردار پشتیبان و شبکه‌ی عصبی مصنوعی نسبت به روش‌های هیدرولوژیکی و الگوریتم‌های درختی از دقت بالاتری برخوردارند. در مطالعه‌ای دیگر ذونعمت کرمانی و همکاران^۳ (۲۰۱۶) نیز به مدل سازی غلظت رسوب معلق روزانه بر اساس مدل‌های داده محور پرداختند. آنان نیز در مطالعه‌ی خود مدل‌های شبکه عصبی مصنوعی، ماشین بردار رگرسیون و منحنی سنج رسوب مورد مقایسه قرار دادند و بر اساس معیارهای ارزیابی مدل‌ها به این نتیجه رسیدند که مدل ماشین بردار رگرسیون با تابع پایه شعاعی دارای عملکرد مناسب‌تری برای پیش‌بینی بار رسوب معلق می‌باشد. همچنین شارما و همکاران^۴ (۲۰۱۵) مدل‌سازی رواناب و بار رسوب حوضه‌ای در نیپال را به وسیله‌ی شبکه‌های عصبی مصنوعی انجام دادند. نتایج آنها نشان داد شبکه‌ی عصبی کارایی خوبی در مدل‌سازی رواناب و بار رسوب دارد. طی مطالعه دیگری توسط فلامکی و همکاران (۲۰۱۳) در مدل‌سازی بار رسوب کل رودخانه‌ها با استفاده از شبکه‌های عصبی مصنوعی به این نتیجه رسیدند که مدل‌های ارائه شده بر پایه‌ی

1. Kalteh
2. Kumar

3. Zounemat-Kermani et al.
4. Sharma et al.

شبکه‌های عصبی با مقادیر رسوب کل مشاهده شده، همخوانی بیشتری دارند و به ویژه شبکه‌ی پرسپترون چند لایه می‌تواند مقادیر رسوب را در نقاط پیک برآورد نماید.

علاوه بر اهمیت به کارگیری روش‌های مناسب برآورد بار رسوبی معلق به کارگیری پارامترهای مؤثر در رسوبدهی نیز از اهمیت زیادی برخوردار می‌باشد. قدرت حمل رسوب توسط جریان نقش مؤثری در تعیین میزان مواد رسوبی جریان دارد. از سوی دیگر عوامل دیگری همچون مشخصات فیزیوگرافی حوضه و جریان می‌تواند بر روی متوسط رسوب تولیدی حوضه تأثیرگذار باشد. فیزیوگرافی حوضه در حقیقت بررسی ویژگی‌های فیزیکی و ریخت‌شناسی یک حوضه است که اثر ویژه‌ای بر ویژگی‌های آبشناختی و رژیم آبی دارد. این ویژگی‌ها می‌تواند به طور مستقیم بر میزان تولید آبی سالانه، حجم سیلاب، شدت فرسایش خاک و میزان رسوب تولیدی هر حوضه تأثیر گذارد (احمدی‌فر و همکاران، ۱۳۹۰). در مطالعات مختلف از پارامترهای مختلفی جهت پیش‌بینی بار رسوبی استفاده شده است، پارامترهایی که هر یک بر حسب میزان تأثیرشان در بار رسوبی دقت مدل‌های داده‌کاوی را در پیش‌بینی افزایش داده است. در تحقیقی فرج‌زاده اصل و همکاران (۱۳۹۶) اقدام به تحلیل و مقایسه‌ی رسوب معلق در حوضه‌های آبخیز خزر و ایران مرکزی نمودند. نتایج نشان داد که از مدل رگرسیون چندمتغیره، بین متغیرهای بارش، دبی و رسوب سالانه در حوضه‌های مورد مطالعه رابطه‌ی معنادار و مستقیم وجود داشته و مدل‌های نسبتاً خوبی از روابط متغیرهای بارش، دبی و رسوب معلق به دست آمد.

در مطالعه دیری کاظم‌پور و همکاران (۱۳۹۶) به مدل سازی رابطه بین خصوصیات فیزیکی حوضه‌ی آبخیز و رواناب و رسوب پرداختند. نتایج نشان داد متغیرهای مساحت و شیب حوضه پارامترهای مؤثر در تولید سیلاب و متغیرهای مساحت، ارتفاع حداقل و متوسط حوضه و طول آبراهه‌ی اصلی پارامترهای مؤثر در تولید رسوب حوضه گرماب می‌باشند. در مطالعه‌ی توسط فتح‌زاده و همکاران (۱۳۹۶) به کارایی شاخص‌های ماهواره‌ای و پارامترهای ژئومورفومتری در برآورد بار رسوبی با استفاده از مدل‌های داده‌کاوی پرداخته شد. نتایج نشان داد عملکرد مدل‌ها با ورودی‌های مختلف گوناگون است به‌طوری‌که در مدل فرایند گوسی با ورودی پارامترهای ژئومورفومتری مقدار $RMSE=35/10$ و در صورت ورودی شاخص‌های تصاویر ماهواره‌ای مقدار $RMSE=513/7$ است.

تاکنون در اکثر مطالعات صورت گرفته از دبی جریان و گاهی از پارامترهای کمکی نظیر پارامترهای ژئومورفومتری و زمین‌شناسی استفاده شده است و جای پارامترهای فیزیوگرافی که بیان‌کننده‌ی ویژگی‌های فیزیکی حوضه‌ی آبریز می‌باشند به عنوان یک عامل مؤثر دیگر خالی بوده است. لذا در این پژوهش به بررسی میزان تأثیر این عامل در تلفیق با مدل‌های داده‌کاوی جهت برآورد بار رسوبی معلق پرداخته شد. مدل‌های داده‌کاوی مورد نظر شامل شبکه‌ی عصبی مصنوعی، ماشین بردار پشتیبان تکاملی، درخت تصمیم M5، فرآیند

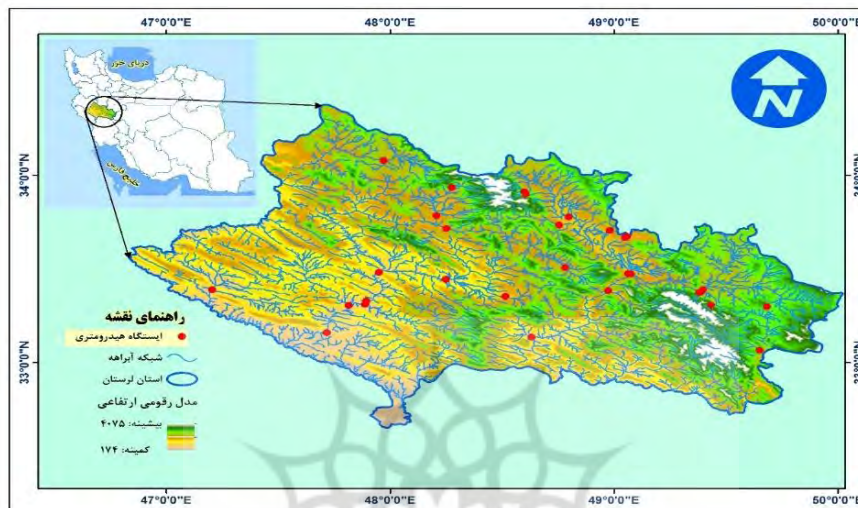
گوسی و رگرسیون بودند که با استخراج مشخصات فیزیوگرافی حوضه‌ها کارآیی آنها در برآورد رسوب معلق این حوضه‌ها به چالش کشیده شد.

۲- مواد و روش

تعیین پارامترهای دقیق و مناسب که تأثیر زیادی در رسوب‌زایی حوضه‌ی آبریز داشته باشند نقش به‌سزایی در افزایش دقت مدل‌های داده‌کاوی دارد. پارامترهای فیزیوگرافی که بیانگر ویژگی‌های فیزیکی حوضه آبریز هستند می‌تواند به عنوان یک فاکتور تعیین‌کننده در میزان رسوب‌زایی حوضه‌ی آبریز مطرح گردد. لذا در این مطالعه داده‌های دبی و رسوب را پس از تهیه از سازمان تماپ در قالب داده‌های سالانه مرتب کرده سپس جهت محاسبه پارامترهای فیزیوگرافی، ابتدا شبکه‌ی آبراهه هر یک از حوضه‌ها با استفاده از نرم‌افزار Arc Hydro استخراج و در نهایت با استفاده از معادلات مربوطه پارامترها برآورد گردید. پس از آماده‌سازی داده‌ها و به دست آوردن شاخص‌های فیزیوگرافی ابتدا مدل‌ها بر روی داده‌های دبی اعمال گردید و نتایج مدل‌ها و ارزیابی مدل‌ها در قالب نمودار ارائه گردید. سپس مدل‌ها بر روی مجموعه داده‌های رسوب یک بار به تنهایی و بار دیگر به منظور تأثیر پارامترهای فیزیوگرافی در پیش‌بینی، بر روی داده‌های رسوب و پارامترهای فیزیوگرافی باهم اجرا گردید. همچنین وزن دهی پارامترها نیز انجام شد.

۲-۱- معرفی منطقه‌ی مورد مطالعه

با توجه به اهمیت بار رسوبی معلق در اقلیم‌های مرطوب و پر آب، استان لرستان به عنوان منطقه‌ی مطالعاتی انتخاب گردید. ۳۰ حوضه‌ی آبریز در استان لرستان به مساحت ۲۸۰۶۴۰ کیلومتر مربع انتخاب شد، که در محدوده‌ی عرض جغرافیایی ۳۲ درجه و ۳۷ دقیقه تا ۳۴ درجه و ۲۲ دقیقه شمالی و طول جغرافیایی ۴۶ درجه و ۵۱ دقیقه تا ۵۰ درجه و ۳۰ دقیقه شرقی واقع شده است. این استان دارای شرایط آب و هوایی معتدل کوهستانی بوده است و متوسط بارندگی منطقه ۵۵۰ تا ۶۰۰ میلی‌متر می‌باشد. موقعیت ایستگاه‌ها در منطقه‌ی مطالعاتی در شکل ۱ ارائه شده است:



شکل (۱): موقعیت ایستگاه‌های مطالعاتی در محدوده استان لرستان و در ایران
Fig(1): Location of study stations in Lorestan province and in Iran

در این مطالعه از آمار و اطلاعات رسوب ۳۳ ساله (۱۳۶۰-۱۳۹۳) مربوط به ۳۰ ایستگاه هیدرومتری واقع در استان لرستان استفاده گردید پس از تعیین ایستگاه‌های هیدرومتری مناسب که دارای دوره‌ی آماری و اطلاعات مناسب بودند مقادیر حداقل، حداکثر و میانگین داده‌های دبی و رسوب نیز محاسبه شد.

۲-۲- پارامترهای فیزیوگرافی

استخراج پارامترهای فیزیوگرافی منطقه مورد مطالعه با استفاده از آخرین توانمندی‌های نرم‌افزار ArcGIS انجام گرفت. تعدادی از این پارامترها و شاخص‌ها شامل مساحت و محیط حوضه، طول، ضریب فرم و ضریب فشردگی، ضریب گردی، نسبت کشیدگی، تراکم زهکشی، نسبت رلیف، شاخص زبری و غیره می‌باشد:

۲-۳- مدل‌های داده‌کاوی

در این مطالعه به منظور مدل‌سازی روابط بین شاخص‌های فیزیوگرافی و رسوب، از مدل‌های داده‌کاوی استفاده شد. به منظور اجرای این مدل‌ها از نرم‌افزار رپید ماینر (V.7) استفاده شد. مراحل داده‌کاوی شامل: آماده‌سازی داده، پردازش و مدل‌سازی و تجزیه و تحلیل نتایج می‌باشد. با برآورد شاخص‌های فیزیوگرافی برای هر یک از زیرحوضه‌های مطالعاتی و آماده‌سازی مجموعه داده‌های ورودی و خروجی مناسب، داده‌ها با تنظیم الگوریتم‌های در نظر گرفته شده به منظور پیش‌بینی بار رسوبی معلق مورد استفاده قرار گرفت. الگوریتم‌های استفاده شده در این مطالعه عبارتند از:

جدول (۱): اطلاعات ایستگاه‌های هیدرومتری
Table (1): Information of hydrometric stations

ردیف	کد ایستگاه	رودخانه	رسوب متوسط (میلی‌گرم بر لیتر)	دبی متوسط (مترمکعب بر ثانیه)
۱	۲۱-۱۸۱	مادیان رود	۲۷۰/۱	۱/۰۹
۲	۲۱-۲۶۷	تیره	۴۰۴۳/۸۹	۲۴/۶۰
۳	۲۱-۲۸۹	سرخاب	۷۷۶۷/۹۰	۱۱/۹۶
۴	۲۱-۲۶۱	سیلاخور	۱۴۳/۷۶	۶/۶۰
۵	۲۱-۲۷۹	ماربره	۸۸۱/۳۸	۷/۳۲
۶	۲۱-۴۰۰	کاکلستان	۳۷۴/۷۵	۴/۹۱
۷	۲۱-۱۸۳	کشکان	۵۶۴۹۴/۲۴	۷۴/۲۱
۸	۲۱-۲۵۹	گله رود	۵/۲۲	۲/۰۸
۹	۲۱-۹۶۸	قلیان	۲۱۸/۱۲	۱۰/۷۵
۱۰	۲۱-۴۶۳	تیره	۱۳۰۸/۳۱	۷/۲۵
۱۱	۲۱-۲۵۵	تیره	۲۳۶/۲۹	۴/۳۵
۱۲	۲۱-۱۷۳	کشکان	۶۰۵۱/۶۶	۲۶/۳۳
۱۳	۲۱-۱۴۵	بادآور	۶۵/۴۴	۲/۸۱
۱۴	۲۱-۱۶۳	دره دزدان	۲۸۸/۰۷	۱/۳۲
۱۵	۲۱-۲۷۵	دره تخت	۹/۶۱	۱/۳۸
۱۶	۲۱-۱۷۹	چلهول	۷۲۸۷/۳	۶/۰۳
۱۷	۲۱-۲۷۱	ازنا	۵۰۳/۵	۳/۸۶
۱۸	۲۱-۴۶۱	آبسر	۲۶/۲۴	۲/۳۴
۱۹	۲۱-۱۷۵	خرم آباد	۳۳۶۱/۶۷	۱۰/۸۴
۲۰	۲۱-۲۷۳	کمندان	۵/۶۶	۱/۵۲
۲۱	۲۱-۲۷۷	ماربره	۷۶۹/۵۷	۸/۲۱
۲۲	۲۱-۲۶۵	بیاتون	۳/۸۳	۰/۴۲
۲۳	۲۱-۹۶۶	کاکا شرف	۳۳۶/۲۲	۱/۰۶
۲۴	۲۱-۱۷۷	کشکان	۱۲۰۰/۸۷	۳۲/۱۶
۲۵	۲۱-۱۶۹	هررود	۲۴۵۲/۱۹۷	۱۴/۳۷
۲۶	۲۱-۱۶۷	هررود	۳۵/۴۳	۴/۴۰
۲۷	۲۱-۱۷۱	دوآب الشتر	۱۶۹/۶۴	۷/۹۲
۲۸	۲۱-۲۸۱	آب سبزه	۷۷/۱۴	۸/۰۷
۲۹	۲۱-۹۵۴	کهمان	۱۸/۸۲	۲/۵۲
۳۰	۲۱-۲۵۷	سراب سفید	۶/۵۱	۱/۶۳

شبکه‌ی عصبی مصنوعی^۱ (ANN)، ماشین بردار پشتیبان تکاملی^۲ (ESVM)، مدل درختی M5، فرآیند گوسی^۳ (GP)، رگرسیون^۴ (LR).

۲-۴- وزن دهی

تمامی پارامترهای ورودی مدل دارای تأثیر و اهمیت یکسانی در پیش‌بینی نمی‌باشند. برخی از پارامترها دارای همبستگی و ارتباط بیشتری با خروجی مدل بوده و تأثیر بیشتری در پیش‌بینی‌ها داشته است. به منظور تعیین شاخص مؤثر در برآورد بار رسوبی معلق، وزن‌دهی شاخص‌ها با استفاده از الگوریتم ماشین بردار پشتیبان انجام شده است. این الگوریتم ضرایب بردار نرمال یک ماشین بردار پشتیبان خطی را به‌عنوان وزن ویژگی تعیین می‌کند.

۲-۵- ارزیابی مدل

به منظور ارزیابی مدل‌ها و مقایسه‌ی نتایج آن‌ها از معیارهای ارزیابی (RMSE) Root Mean Squared Error، (NMAE) Normalized Mean absolute error و (AE) absolute error و (r) Correlation Coefficient استفاده شد که روابط آنها بدین شرح می‌باشد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_o - X_i)^2}{n}} \quad (1)$$

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x}_i) \cdot (X_o - \bar{x}_o)}{\sqrt{\sum_{i=1}^n (x_i - \bar{x}_i)^2 \sum_{i=1}^n (y_i - \bar{y}_o)^2}} \quad (2)$$

$$NMAE = \frac{\bar{E}}{r_{max} - r_{min}} \quad (3)$$

$$AE = \frac{x_i - X_o}{X_o} = \frac{x_i}{X_o} - 1 \quad (4)$$

1. Artificial Neural Network
2. Support Vector Machine Evolutionary

3. Gaussian Process
4. Liner Regression

که در این معادلات X_0 مقادیر مشاهده‌ای، x_i داده‌های پیش‌بینی شده، \bar{x}_i میانگین داده‌های پیش‌بینی شده، \bar{x}_0 میانگین داده‌های مشاهده شده، n تعداد داده‌ها می‌باشد.

۳- یافته‌ها و بحث

۳-۱- نتایج مدل‌های داده‌کاوی بر روی دبی با استفاده از پارامترهای فیزیوگرافی

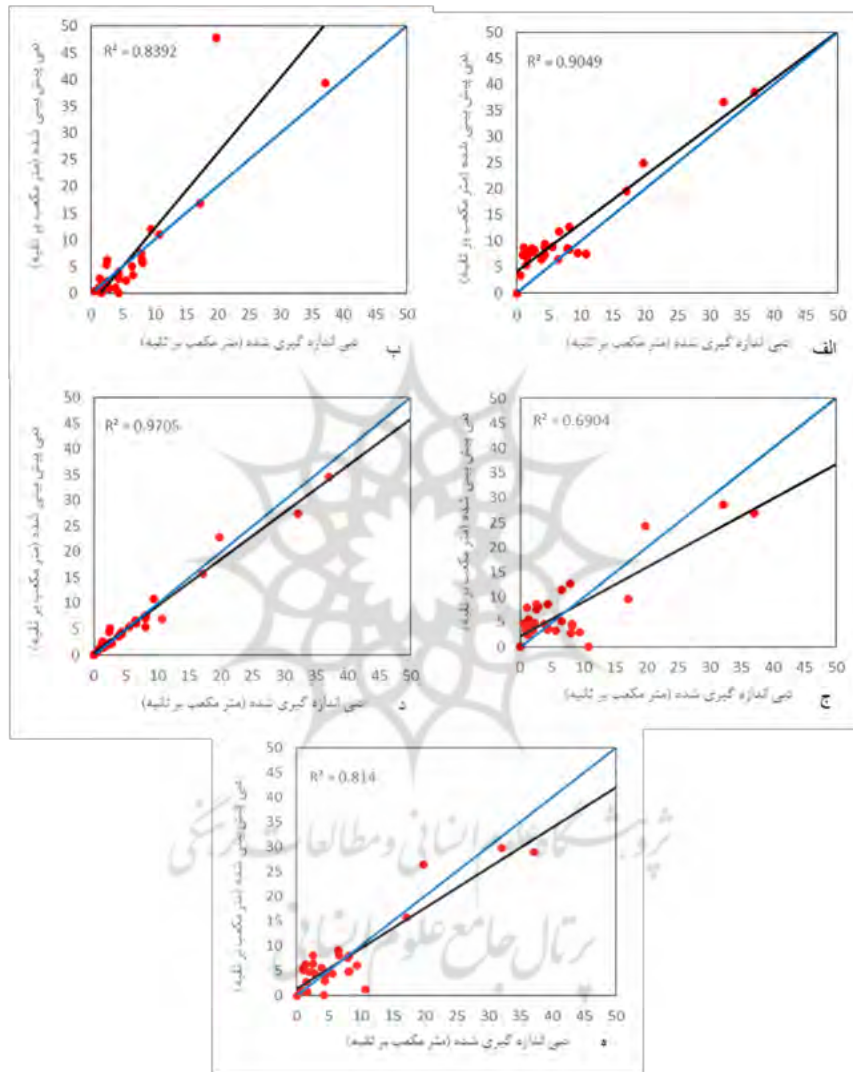
در رابطه با پیش‌بینی دبی پس از آماده‌سازی مجموعه داده‌ها، پنج مدل از سری مدل‌های داده‌کاوی مورد استفاده قرار گرفت. پس از اعمال مدل‌ها، نتایج با استفاده از معیارهای ارزیابی مورد بررسی قرار گرفت. نتایج این جدول نشان می‌دهد از بین مدل‌های استفاده شده، مدل گوسی با میزان همبستگی $0/985$ در کنار روش شبکه‌ی عصبی مصنوعی بهترین عملکرد در برآورد دبی جریان براساس پارامترهای فیزیوگرافی را دارد. همچنین بررسی مقادیر مجموع مربعات خطای باقیمانده نشان می‌دهد مدل‌های گوسی و رگرسیون با کمترین میزان RMSE با مقادیر $1/613$ و $3/743$ بهترین عملکرد را داشته‌اند (جدول ۲).

جدول (۲): نتایج معیارهای ارزیابی حاصل از اعمال مدل بر روی مجموعه داده‌ها

Table (2): Results of evaluation criteria obtained from applying the model to the data set

Model	ANN	ESVM	M5	GP	LR
RMSE	4/519	6/491	4/829	1/613	3/743
r	0/953	0/916	0/827	0/985	0/9
NMAE	0/704	0/535	0/72	0/186	0/515
AE	4/019	3/053	4/111	1/062	2/944

تحلیل شکل ۲ نیز نشان می‌دهد روش گوسی و شبکه‌ی عصبی مصنوعی بیشترین تشابه را بین مقادیر واقعی دبی و مقادیر پیش‌بینی شده آن نشان می‌دهد. به عبارتی در مدل‌های مذکور بیشترین تشابه و کمترین فاصله و زاویه بین خطوط مقادیر واقعی و مقادیر برآوردی دیده می‌شود. کمترین میزان همبستگی و بیشترین میزان اختلاف بین مقادیر واقعی و مقادیر برآوردی نیز در روش‌های ماشین بردار پشتیبان و درخت تصمیم دیده می‌شود.



شکل (۲): نمودار پراکندگی مقادیر مشاهده شده و پیش بینی شده دبی توسط مدل های الف: شبکه عصبی مصنوعی، ب: ماشین بردار پشتیبان تکاملی، ج: درخت تصمیم M5، د: فرآیند گوسی، ه: رگرسیون

Fig(2): Distribution diagram of observed and predicted values of discharge by models A: Artificial Neural Network, B: Evolutionary Support Vector Machine, C: Decision Tree M5, D: Gaussian Process, E: Regression

۳-۲- نتایج وزن دهی پارامترهای فیزیوگرافی در دبی

از آن جایی که پارامترها اهمیت یکسانی ندارند باید مورد وزن دهی قرار گیرند که این کار به وسیله ماشین بردار پشتیبان انجام شد و نتایج آن به صورت جدول زیر می باشد (جدول ۳).

جدول (۳): نتایج حاصل از وزن دهی
Table (3): The results of the weighting

وزن	پارامتر
۰	نفوذ
۰/۰۱۳	نسبت کشیدگی
۰/۰۵۶	شکل حوضه
۰/۰۶۶	ضریب گردی
۰/۱۰۹	زبری
۰/۱۶۳	شاخص رلیف
۰/۲۴۰۷	ثابت نگهداری کانال
۰/۲۴۰۸	تراکم زهکشی
۰/۲۷۹	نسبت سازگاری
۰/۲۹۶	ضریب فشردگی
۰/۴۹۹	فراوانی شاخه‌ها
۰/۶۴۷	شاخص سرگردانی
۱	بافت

۳-۳ نتایج پیش‌بینی دبی با استفاده از داده‌های اقلیمی

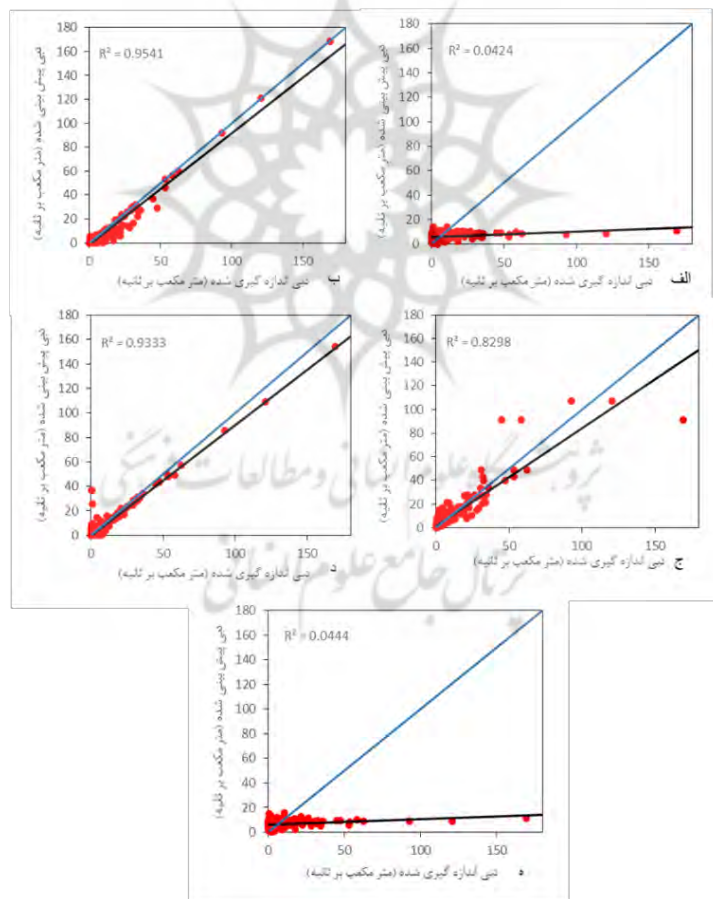
به منظور پیش‌بینی دبی جریان با استفاده از پارامترهای اقلیمی، این پارامترها از جمله بارش، دما، رطوبت، تبخیر و سرعت باد به عنوان ورودی در مدل قرار گرفت. نتایج نشان داد که از بین مدل‌های به کار گرفته شده مدل ماشین بردار پشتیبان با میانگین مربعات خطا $3/464$ و همبستگی $0/977$ به عنوان بهترین مدل عمل کرده است. هم‌چنین مدل گوسی پس از آن با میانگین مربعات خطا $3/675$ و همبستگی $0/966$ عملکرد خوبی در پیش‌بینی دبی جریان دارد. نتایج معیارهای ارزیابی کلیه مدل‌ها در جدول ۴ آمده است. شکل ۳ نیز نشان می‌دهد که بیشترین تشابه و کمترین فاصله بین مقادیر واقعی و پیش‌بینی شده دبی توسط مدل ماشین بردار پشتیبان و پس از آن مدل‌های گوسی و درخت تصمیم می‌باشد. در حالی که بیشترین اختلاف و کمترین همبستگی بین مقادیر برآورد شده و واقعی در مدل‌های شبکه عصبی مصنوعی و رگرسیون وجود دارد.

جدول (۴): نتایج معیارهای ارزیابی حاصل از اعمال مدل با ورودی داده‌های اقلیمی
Table (4): Results of evaluation criteria after modeling with climate data input

Model	ANN	ESVM	M5	GP	LR
RMSE	۱۳/۰۷۳	۳/۴۶۴	۵/۵۰۹	۳/۶۷۵	۱۳/۰۵۳
r	۰/۲۰۶	۰/۹۷۷	۰/۹۱۱	۰/۹۶۶	۰/۲۱۱
NMAE	۰/۹۷۴	۰/۳۲۱	۰/۲۹۴	۰/۳۸۵	۰/۹۸۸
AE	۶/۲۰۵	۲/۰۴۲	۱/۸۷	۲/۴۵۱	۶/۲۹۲

۳-۴- نتایج اعمال مدل بر روی داده‌های رسوب با ورودی دبی

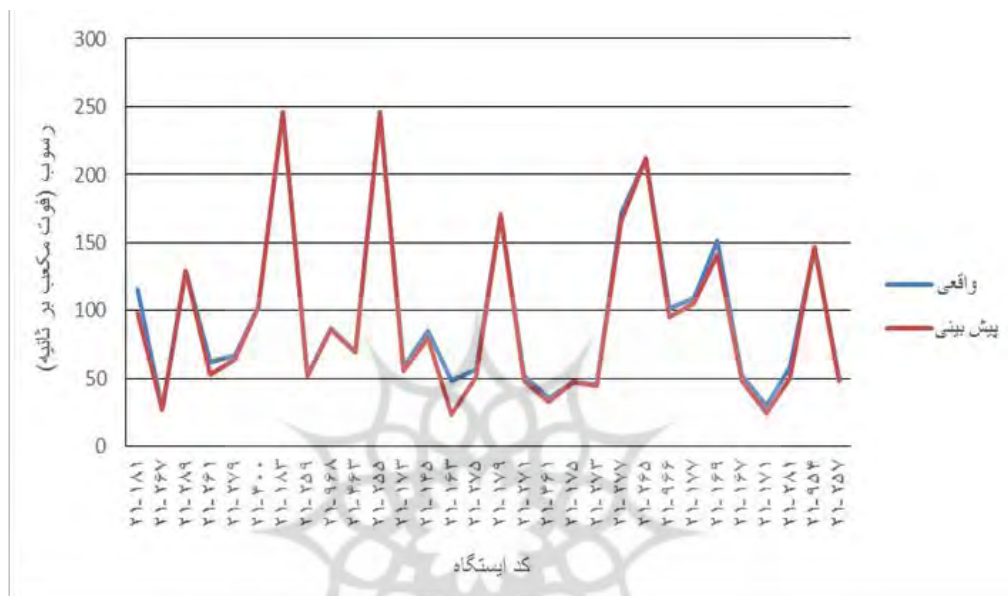
در این بخش مدل‌ها بر روی مجموعه داده‌هایی که تنها از دبی به عنوان پارامتر مؤثر در برآورد رسوب معلق به عنوان ورودی مدل‌ها استفاده نموده بود اعمال شد. با اعمال مدل‌های مختلف بر روی داده‌ها این نتیجه به دست آمد که مدل ماشین بردار پشتیبان به عنوان بهترین مدل در پیش‌بینی بار رسوبی معلق می‌باشد. این مدل قادر بوده با استفاده از ورودی دبی بار رسوبی معلق را با میانگین مربعات خطا $۶/۷۳۶$ و همبستگی $۰/۹۹۴$ برآورد نماید. پس از آن مدل گوسی نسبت به سایر مدل‌ها کمترین میزان میانگین مربعات خطا برابر $۸/۵۵۱$ و بیشترین همبستگی $۰/۹۹۹$ را دارا می‌باشد (شکل ۴).



شکل (۳): نمودار پراکندگی مقادیر مشاهده شده و پیش‌بینی شده دبی با ورودی داده‌های اقلیمی توسط مدل‌های الف: شبکه

عصبی مصنوعی، ب: ماشین بردار پشتیبان تکاملی، ج: درخت تصمیم M5، د: فرآیند گوسی، ه: رگرسیون

Fig (3): Distribution diagram of observed and predicted values of discharge with the Input of climatic data by models
A: Artificial Neural Network, B: Evolutionary Support Vector Machine, C: Decision Tree M5, D: Gaussian Process,
E: Regression



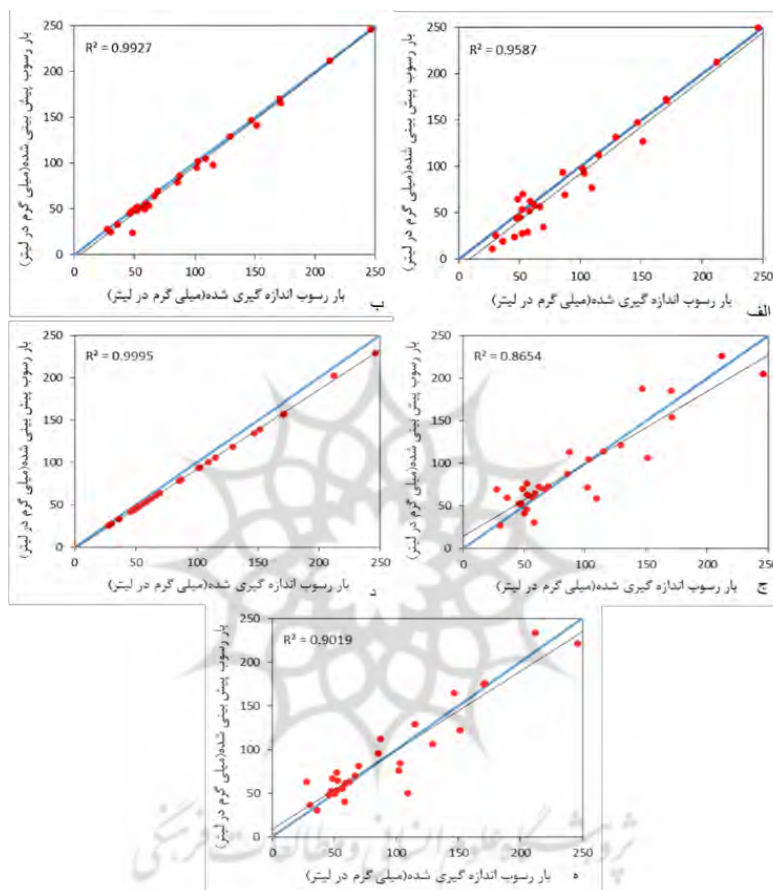
شکل (۴): روند پیش‌بینی بار رسوبی معلق با استفاده از مدل ماشین بردار تکاملی بدون در نظر گرفتن پارامترهای فیزیوگرافی
Fig(4): Trend of predicting suspended sediment load using the Evolutionary Vector Machine model Regardless of Physiographic Parameters

نتایج حاصل از اعمال مدل‌ها بر روی این مجموعه داده در جدول ۵ ارائه شده است. نمودارها در شکل ۵ نیز نشان می‌دهد که تشابه بین مقادیر واقعی و پیش‌بینی شده رسوب در مدل ماشین بردار پشتیبان و پس از آن فرایند گوسی نسبت به سایر مدل‌ها بیشتر می‌باشد. با به کار بردن پارامترهای فیزیوگرافی در سایر مدل‌ها نیز اختلاف کمتری بین مقادیر واقعی و برآورد شده مشاهده می‌شود. پراکنش مقادیر پیش‌بینی شده و مشاهده‌ای در شکل ۵ ارائه شده است.

جدول (۵): نتایج معیارهای ارزیابی حاصل از اعمال مدل بر روی مجموعه داده‌ها با ورودی دبی

Table (5): Results of evaluation criteria applied to the model based on the input data set with discharge

Model	ANN	ESVM	M5	GP	LR
RMSE	۱۵/۱۴۸	۶/۷۳۶	۱۵/۱۵	۸/۵۵۱	۱۹/۳۶۲
r	۰/۹۶۹	۰/۹۹۴	۰/۹۵۴	۰/۹۹۹	۰/۹۲۴
NMAE	۱۷/۴۷	۵/۹۷	۸/۰۴	۸/۲۶	۱۵/۷۳
AE	۱۱/۲۹۲	۳/۹۲۵	۷/۹۶۱	۷/۴۶	۱۴/۷۰۶



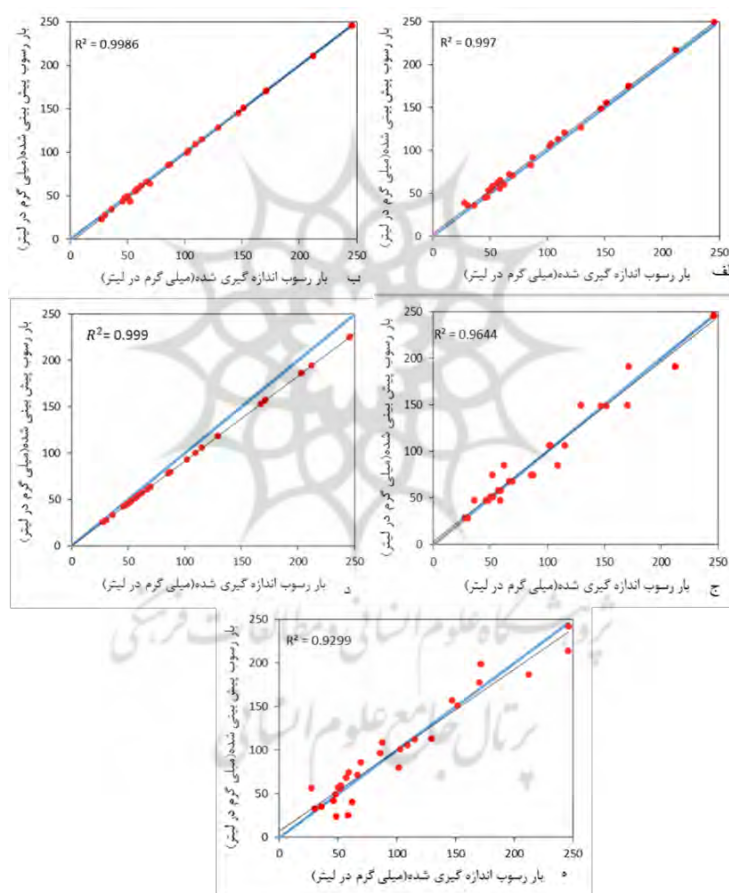
شکل (۵): نمودار پراکندگی مقادیر مشاهده شده و پیش‌بینی شده‌ی بار رسوب معلق توسط مدل‌های الف: شبکه عصبی مصنوعی، ب: ماشین بردار پشتیبان تکاملی، ج: درخت تصمیم M5، د: فرآیند گوسی، ه: رگرسیون، بدون در نظر گرفتن پارامترهای فیزیوگرافی

Fig (5): Distribution diagram of observed and predicted values of suspended sediment load by models A: Artificial Neural Network, B: Evolutionary Support Vector Machine, C: Decision Tree M5, D: Gaussian Process, E: Regression. Regardless of physiographic parameters

۳-۵- نتایج اعمال مدل بر روی داده‌های رسوب با ورودی پارامترهای فیزیوگرافی

به منظور بررسی تأثیر پارامترهای فیزیوگرافی بر دقت پیش‌بینی مدل‌ها از این پارامترها به عنوان ورودی استفاده گردید. نتایج حاصله نشان داد در این مجموعه داده‌ها با اعمال مدل‌ها دقت پیش‌بینی در کلیه مدل‌ها افزایش یافته به طوری که در مدل ماشین بردار پشتیبان میانگین مربعات خطا از ۶/۷۳۶ به ۳/۰۴ کاهش پیدا کرده است و مقدار همبستگی از ۰/۹۹۴ به ۰/۹۹۹ افزایش یافته است.

استفاده از پارامترهای فیزیوگرافی مقدار خطا را در مدل شبکه عصبی مصنوعی نیز به مقدار قابل توجهی کاهش داده است. به طور کلی دقت در تمام مدل‌ها بهبود یافته است. همان‌طور که مشاهده می‌شود مقادیر دو معیار NMAE و AE در تمامی مدل‌ها کاهش یافته است. نتایج کلیه مدل‌ها در جدول ۶ ارائه شده است.



شکل (۶): نمودار پراکندگی مقادیر مشاهده شده و پیش‌بینی شده‌ی بار رسوب معلق توسط مدل‌های الف: شبکه عصبی مصنوعی، ب: ماشین بردار پشتیبان تکاملی، ج: درخت تصمیم M5، د: فرآیند گوسی، ه: رگرسیون، با در نظر گرفتن پارامترهای فیزیوگرافی

Fig (6): Distribution Diagram of Observed and Predicted Values of Suspended Sediment Load by Models A: Artificial Neural Network, B: Evolutionary Support Vector Machine, C: Decision Tree M5, D: Gaussian Process, E: Regression, Considering physiographic parameters

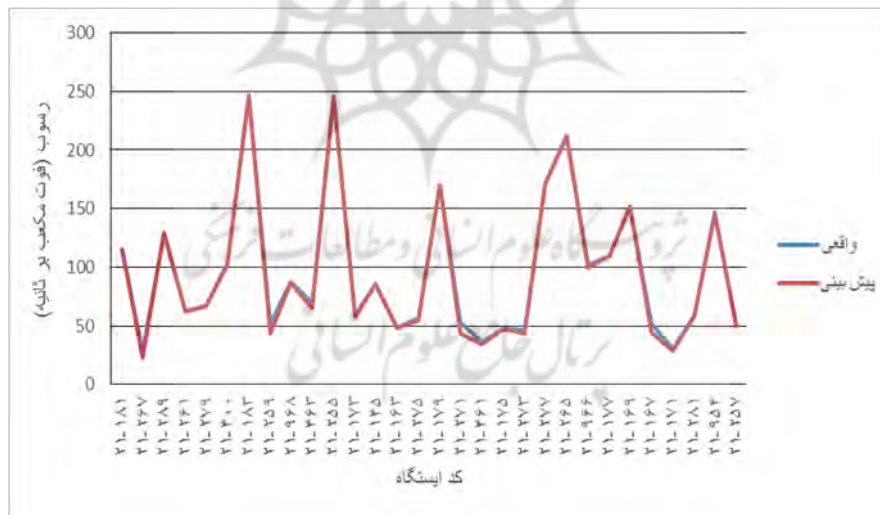
جدول (۶): نتایج معیارهای ارزیابی حاصل از اعمال مدل بر روی مجموعه داده‌ها با ورودی پارامترها

Table (6): Results of the evaluation criteria applied to the model based on the data set with parameter input

Model	ANN	ESVM	M5	GP	LR
RMSE	۴/۹۳۵	۳/۰۴	۱۱/۵۲۲	۴/۰۹۷	۱۶/۱۶۵
r	۰/۹۹۸	۰/۹۹۹	۰/۹۸۲	۰/۹۹۸	۰/۹۶۴
NMAE	۰/۰۸۱	۰/۰۳۵	۰/۱۵۶	۰/۰۲۴	۰/۲۵۳
AE	۴/۰۱۲	۱/۷۲۳	۷/۷۸۲	۱/۳۸۴	۱۲/۵۶۷

شکل ۶ نیز نشان می‌دهد که در مدل‌های ماشین بردار پشتیبان، فرآیند گوسی و شبکه عصبی مصنوعی کمترین فاصله و زاویه و بیشترین تشابه بین مقادیر واقعی و پیش‌بینی شده نسبت به دو مدل درخت تصمیم و رگرسیون وجود دارد.

روند مقادیر مشاهده‌ای و پیش‌بینی شده با استفاده از مدل ماشین بردار پشتیبان در شکل ۷ ارائه شده است.



شکل (۷): مقادیر واقعی و پیش‌بینی شده توسط مدل ماشین بردار پشتیبان تکاملی با در نظر گرفتن پارامترهای فیزیوگرافی
Fig (7): Actual and Predicted Values by the Evolutionary Support Vector Machine Model Considering the physiographic parameters

۳-۶- نتایج وزن‌دهی پارامترها در رسوب

همان‌طور که گفته شد پارامترها نقش و اهمیت یکسان در پیش‌بینی بار رسوبی معلق ندارند به همین دلیل این پارامترها وزن‌دهی شدند. با توجه به جدول ۷، شاخص زبری با وزن (۱) بیشترین تأثیر را در پیش‌بینی مقدار رسوب دارا می‌باشد. پس از شاخص زبری، پارامترهای رلیف، بافت و تراکم زهکشی به ترتیب با وزن‌های ۰/۷۲۵،

۰/۶۷۹ و ۰/۵۹۹ دارای بیشترین تأثیر می‌باشند. کمترین وزن نیز مربوط به پارامترهای نسبت کشیدگی، نفوذ و شکل حوضه با وزن‌های ۰، ۰/۱۴۰ و ۰/۱۵۵ می‌باشد.

جدول (۷): نتایج حاصل از وزن‌دهی پارامترها
Table (7): Results of Weighting Parameters

وزن	پارامتر
۰	نسبت کشیدگی
۰/۱۴۰	نفوذ
۰/۱۵۵	شکل حوضه
۰/۱۹۷	شاخص سرگردانی
۰/۲۰۱	ثابت نگهداری کانال
۰/۴۰۸	ضریب گردی
۰/۴۱۰	ضریب فشردگی
۰/۴۵۷	نسبت سازگاری
۰/۵۴۸	فراوانی شاخه‌ها
۰/۵۹۹	تراکم زهکشی
۰/۶۷۹	بافت
۰/۷۲۵	شاخص رلیف
۱	زبری

۴- نتیجه‌گیری

نتایج این تحقیق نشان می‌دهد که از بین مدل‌های استفاده شده، مدل ماشین بردار پشتیبان تکاملی بهتر از سایر مدل‌ها برای پیش‌بینی عمل کرده است. یون و همکاران (۲۰۱۱) و میسرا و همکاران (۲۰۰۹) نیز با مقایسه‌ی دو مدل شبکه‌ی عصبی مصنوعی و ماشین بردار پشتیبان در پیش‌بینی رواناب و بار رسوب نتیجه گرفتند که ماشین بردار پشتیبان نسبت به شبکه‌ی عصبی مصنوعی بهتر می‌باشد. نتایج ارزیابی مدل‌ها نیز نشان داد که مدل ماشین بردار پشتیبان تکاملی در حالت اول که تنها از دبی جهت برآورد بار رسوبی معلق استفاده شد با میانگین مربعات خطا ۶/۷۳۶ و همبستگی ۰/۹۹۴ و در حالت دوم با به کارگیری شاخص‌های فیزیوگرافی منطقه با میانگین مربعات خطا ۳/۰۴ و همبستگی ۰/۹۹۹ به عنوان بهترین مدل در پیش‌بینی عمل کرده است. نتایج نشان داد که به کارگیری پارامترهای فیزیوگرافی به منظور پیش‌بینی موجب بالا رفتن دقت و عملکرد بهتر مدل‌ها می‌شود به طوری که مطالعه کرح و همکاران (۲۰۰۶) نیز بر این مورد صدق می‌کند. نتایج تحلیل تأثیر پارامترهای فیزیوگرافی بر دبی جریان نشان داد که از بین شاخص‌های استفاده شده، شاخص‌های نسبت بافت حوضه، شاخص سرگردانی و فراوانی شاخه‌ها با مقادیر ۱، ۰/۶۴۷ و ۰/۴۹۹ بیشترین درصد را در

برآورد دبی جریان با استفاده از پارامترهای فیزیوگرافی داشته و پارامترهای نفوذ، نسبت کشیدگی، شکل حوضه و ضریب گردی با مقادیر ۰/۰۱۳، ۰/۰۵۶ و ۰/۰۶۶ کمترین مشارکت و تأثیر در برآورد دبی جریان با استفاده از پارامترهای مذکور را دارد.

همچنین در مطالعات فتحزاده و همکاران (۱۳۹۶) و اسدی و همکاران (۱۳۹۶) به کارگیری پارامترهای ژئومورفومتری باعث افزایش دقت در پیش‌بینی بار رسوبی معلق شده است. با توجه به این نکته که شناسایی عوامل مؤثر در بهبود دقت مدل‌ها مؤثر می‌باشد، می‌توان با مطالعات دقیق‌تر، پارامترهای مناسب و مؤثر در فرسایش و رسوب را انتخاب تا با به کارگیری آنان نتایج برآورد از دقت بالاتری برخوردار گردد.

مورات و سیگیزوگلو (۲۰۰۷) نیز به منظور پیش‌بینی بار رسوبی از ویژگی‌های ژئومورفولوژی حوضه استفاده کردند و این نتیجه به دست آمد که استفاده از این داده‌ها موجب افزایش دقت در برآوردها می‌شود.

همچنین بررسی تأثیر پارامترها بر روی میزان پیش‌بینی بار رسوبی معلق نشان داد که شاخص زبری بیشترین تأثیر را در برآورد بار رسوبی دارد. این پارامتر بر روی سرعت جریان و اصطکاک بستر رودخانه‌ها تأثیرگذار بوده و دارای نقش و تأثیر بیشتری نسبت به سایر پارامترها در میزان رسوب تولیدی بوده است. همچنین پارامترهای رلیف، بافت، تراکم زهکشی و فراوانی شاخه‌ها بعد از شاخص زبری دارای تأثیر بیشتری در برآورد بار رسوبی معلق زیر حوضه‌ها بوده است. تعیین پارامترهای مؤثر و به کارگیری آنان و حذف پارامترهایی که دارای تأثیر کمی بوده می‌تواند از پیچیدگی اجرای مدل بکاهد و از طرف دیگر بر دقت مدل‌ها بیفزاید. از آنجایی که در حوضه های آبریز ایران از نظر آمار و اطلاعات بار رسوبی حوضه‌ها با محدودیت روبه‌رو می‌باشیم و اطلاعات موجود نیز از دقت بالایی برخوردار نمی‌باشند تعیین پارامترهای مؤثر در میزان رسوب‌زایی حوضه آبریز می‌تواند در زمینه مطالعات رسوب‌زایی حوضه آبریز به محققین کمک نماید همچنین به کارگیری مدل‌های هوش مصنوعی با دقت بالاتر می‌تواند باعث ارتقا دقت داده‌های بار رسوبی گردد.

همانطور که نتایج نشان می‌دهد به کارگیری پارامترها و مدل‌های مناسب جهت برآورد بار رسوبی معلق موجب افزایش دقت پیش‌بینی‌ها گشته و نتایج حاصل از آن قابل استفاده در مطالعات و برنامه‌ریزی‌های حوضه آبریز بوده است. به کارگیری مجموعه کاملی از عوامل تأثیرگذار می‌تواند دقت مدل‌ها را ارتقا داده و نتایج قابل اعتمادتری را ارائه نماید. پیشنهاد می‌گردد با تعیین پارامترها و شاخص‌ها و ارزش و اهمیت هر یک از آنها در تعیین میزان بار رسوبی حوضه‌ی آبریز جهت افزایش کارایی نتایج مطالعات اقدام نمود.

- Ahmadifard, F., Ghazanfari, P., & Malekirad, Z. (2011). Relationship between Physiographic and Geological Features in Baghakmesh Watershed of Jajroud River, 6th Iranian National Geological Conference. Shiraz.
- Arab Ameri, A., Pourghasemi, H.R. and Cerda, A., (2018). Erodibility prioritization of sub-watersheds using morphometric parameters analysis and its mapping, *Science of the Total Environment*, 613-614, 1385-1400.
- Asadi, M., Fathzadeh, A., & Taghizadeh Mehrjardi, R. (2017). Optimization of Suspended Load Estimation Models Using Morphological Context Parameters and Feature Reduction Technique. *Iran Soil and Water Research*, 3(48), 669-678.
- Asadi, M., Fathzadeh, A., & Taghizadeh Mehrjardi, R. (2017). The Effects of the Daily, Monthly, and Annual Time Scales on the Suspended Sediment Load Prediction. *Hydrogeomorphology*, 4(10), 121-143.
- Asselman, N., (2000). Fitting and interpretation of sediment rating curves, *Journal of hydrology*, 23(4): 228-248.
- Ataei, Y., Nikpoor, MR., Kanooni, A., & Hoseini, Y. (2019). Estimation of River Suspended Load using ANN, GEP and Rating Curve. 2nd International and 6th National Iranian Congress on Organic vs. Conventional Agriculture, Ardabil, Iran, 1-10.
- Chang, F.J., Tsai, Y.H., Chen, P.A., Coynel, A. and Vachaud, G., (2015). Modeling water quality in an urban river using hydrological factors-data driven approaches, *Journal of environment management*, 151, 87-96.
- Cheng, M.Y., Wu, Y.W., (2009). Evolutionary support vector machine inference system for construction management, *Automation in Construction*, 18(5), 597-604.
- Dastorani, M., & Azimi Fashi, K., & Talebi, A., & Ekhtesasi, M. (2013). Estimation of Suspended Sediment using Artificial Neural Network (Case Study: Jamishanwatershed in Kermanshah). *Journal of Watershed Management Research*, 3(6), 61-74.
- Esfandiari, F., & Gharachorlo, M. (2015). Investigation of Spatio-Temporal Relationships of Suspended Sediment Load with Basin Rainfall (Case Study: Gharasoo Watershed). *Hydrogeomorphology*, 2(4), 125-142.
- Faghih, H., Amini, A., Haidari, F., Khalili, K. (2016). Assessing the Artificial Neural Network Efficiency to Estimate Suspended Sediment Load using Classified Data. *Environment and Water Engineering*, 1(1), 51-64.
- Falamaki, A., & Eskandari, M., & Baghlani, A., & Ahmadi, S. (2013). Modeling Total Sediment Load in Rivers Using Artificial Neural Networks. *Journal of Soil and Water Resources Conservation*, 2(3), 0-0.
- Falamaki, A., M. Eskandari, A. Baghlani and A. ahmadi. (2013). Modeling total sediment load in rivers using artificial neural networks. *Journal of water and soil conservation*, 2: 13-26

- Farajzadeh, M., Hodaei, A., Mollashahi, M., Rajabi Rostam Abadi, N. (2017). The Analysis and Comparison of the Suspended Sediment in the Caspian Sea and Central Iran Drainage Basins. *Hydrogeomorphology*, 4(11), 59-81.
- Fathzadeh, A., & Asadi, M., & Taghizadeh Mehrjardi, R. (2017). How Much the Remote Sensing Indices Can Improve Suspended Sediment Predictions? *Physical Geography Research Quarterly*, 49(1), 21-24.
- French, M.N., Krajewski, W.F. and Cuykendall, R.R., (2003), Rainfall forecasting in space and time using artificial neural network, *Journal of hydrology*, 137(1): 31-41.
- Hayatzadeh M, Chezgi J, Dastorani M. (2015). Evaluation of Sediments Using Rating Curve and Artificial Neural Network Methods by Combining Morphological Parameters of Basin (Case Study: Bagh Abbas Basin). *JWSS*, 19 (72), 217-228.
- Huang, H.L. and Chang, F.L., (2008). Evolutionary support vector machine for automatic feature selection and classification of microarray data, *Biosystems*, 90(2), 516-528.
- Kakaei, Lafdani, E., Moghaddamnia, A., Ahmadi, A., (2013), Daily suspended sediment load prediction using artificial neural networks and support vector machines, *Journal of Hydrology*, 478: PP. 50-62.
- Kalteh, A.M., (2013). Monthly river flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform, *Comput. Geoscience*, 54(5): 1-8.
- Kisi, O., (2010). River suspended sediment concentration modeling using a neural differential evolution approach, *Journal of Hydrology*, 1389(1), 227-235.
- Kisi, O., (2012). Modeling discharge-suspended sediment relationship using least square support vector machine, *Journal of Hydrology*, 456: 110-120.
- Kumar, D., A. Pandey, N. Sharma and W. Flugel. (2016). Daily suspended sediment simulation using machine learning approach. *Catena*, 138: 77-90.
- Leo, Q.J., She, Z.H., Fang, N.F., Zho, H.D. and Ai, L., (2013). Modeling the daily suspended sediment concentration in a hyper concentrated river on the loess plateau using the Wavelet-ANN approach, *Geomorphology*, 186: 181-190.
- Melesse, A.M., Ahmad, S., McClain, M.E., Wang, X. and Lim, Y.H. (2011). Suspended sediment load prediction of river systems: An artificial neural network approach, *Agricultural Water Management*, 98(5): 855-866.
- Misra, D.T., Oommen, A. and Mishra, S.K., (2009). Application and analysis of support vectors machine based simulation for runoff and sediment yield, *bios stems engineering*, 103: 527-535.
- Rajaei, T., Mirbagheri, S.A. and Zounemat-kermani, M., (2009). Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models, *Science of the total environment*, 407: 4916-4927.

- Rasmussen, C.E., and Williams, C.K.I., (2006). Gaussian Processes for Machine Learning, the MIT Press, Massachusetts Institute of Technology.
- Sharma, N., Zakauallah, M.D., Tiwari, H. and Kumar, D., (2015). Runoff and sediment yield modeling using ANN and support vector machines: a case study from Nepal watershed, *Earth Sys.*, 1(1): 1-8.
- Tabatabaei, M., Slaimani, K., Habibnezhadroushan, M., & Kavvan, A. (2015). Estimation of Daily Suspended Sediment Concentration Using Artificial Neural Networks and Data Clustering by Self-Organizing Map (Case Study: Sierra Hydrometry Station- Karaj Dam Watershed). *Jwmr*, 5 (10), 98-116.
- Yang, C.T., Marsooli, R. and Aalami, T., (2009). Evaluation of total load sediment transport formulas using ANN, *International Journal of Sediment Research*, 24: 274-286.
- Yoon, H., Jun, S.C., Hyun, Y., Bae, G.O. and Lee, K.K., (2011). A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer, *Journal of Hydrology*, 396: 128-138.
- Zho, Y.M., Lu, X.X. and Zhou, Y., (2007). Suspended sediment flux modeling with artificial neural network: An example of the longchuanjiang river in the upper Yangtze catchment China, *Geomorphology*, 84(1): 111-125
- Zoratipoor, A. (2016). Comparison of the Efficiency of Neurophasic Methods, Artificial Neural Networks and Statistical Models in Estimating Suspended Sediment in Rivers. *Journal of Range and Watershed Management*, 69(1), 65-78.
- Zounemat kermani, M, Kisi, Ö. Adamowski, J. and Ramezani Charmahineh, A., (2016). Evaluation of data driven models for river suspended sediment concentration modeling, *Journal of hydrology*, 535, 457-472.