

شاخص‌های سنجش از دوری چه اندازه می‌توانند موجب بهبود برآورد بار معلق شوند؟

علی فتح‌زاده* - دانشیار دانشکده کشاورزی و منابع طبیعی دانشگاه اردکان
مریم اسدی - دانشجوی کارشناسی ارشد آبخیزداری، دانشکده کشاورزی و منابع طبیعی دانشگاه اردکان
روح‌الله تقی‌زاده مهرجردی - استادیار دانشکده کشاورزی و منابع طبیعی دانشگاه اردکان

پذیرش مقاله: ۱۳۹۵/۰۵/۲۱ تأیید نهایی: ۱۳۹۵/۰۸/۰۶

چکیده

در این پژوهش کارایی شاخص‌های ماهواره‌ای و پارامترهای ژئومورفومتری در برآورد بار رسوبی با استفاده از مدل‌های مبتنی بر هوش مصنوعی و داده‌کاوی به چالش کشیده شده است. بدین منظور، نخست مدل‌ها به کمک پارامترهای ژئومورفومتری مستخرج از مدل رقومی ارتفاعی و شاخص‌های ماهواره‌ای بهینه‌سازی شد و نزدیک‌ترین داده‌های دبی و رسوب به زمان تصاویر ماهواره‌ای خروجی مدل در نظر گرفته شد. پس از اجرای الگوریتم‌ها، به وزن‌دهی پارامترها و تعیین میزان تأثیرشان در پیش‌بینی بار رسوبی معلق پرداخته شد. نتایج نشان داد عملکرد مدل‌ها با ورودی‌های مختلف گوناگون است. مقادیر RMSE مدل‌ها بیانگر آن است که در صورت استفاده از پارامترهای ژئومورفومتری به عنوان ورودی مدل مقدار RMSE بیشتر است و در مقابل با استفاده از برخی شاخص‌ها به عنوان ورودی مدل‌ها میزان RMSE کاهش می‌یابد؛ به طوری که در مدل فرایند گوسی با ورودی پارامترهای ژئومورفومتری مقدار $RMSE=35/10$ و در صورت ورودی شاخص‌های تصاویر ماهواره‌ای مقدار $RMSE=513/7$ است. با تلفیق پارامترهای ژئومورفومتری و شاخص‌ها میزان دقت همه مدل‌ها افزایش یافته و مدل فرایند گوسی با $RMSE=5/026$ بیشترین دقت را داشته است. نتایج حاصل از وزن‌دهی نیز نشان داد که شاخص‌های Clay index (average) و b5 (average) و NDVI (max) دارای بیشترین وزن بوده و بیشترین تأثیر را در پیش‌بینی بار رسوبی معلق داشته‌اند.

کلیدواژه‌ها: پارامترهای ژئومورفومتری، تصاویر ماهواره‌ای، داده‌کاوی، مدل رقومی ارتفاع.

مقدمه

به منظور بررسی تغییرات زیست‌محیطی مرتبط با بار رسوبی رودخانه‌ها، از جمله تغییرات مورفولوژی بستر آن‌ها، پایین‌آمدن کیفیت آب، و اثرهای منفی بر روی زیست‌آبزیان، لازم است بار رسوبی رودخانه‌ها به‌دقت نظارت و ارزیابی شود (وانگ و لیو، ۲۰۱۰؛ ایلون و همکاران، ۲۰۰۴؛ کولینز و والینگ، ۲۰۰۴؛ سچیب و همکاران، ۱۹۹۲). علاوه بر آن، طی دهه‌های اخیر، در علوم مهندسی منابع آب مسئله پیش‌بینی بار رسوبی معلق، به‌ویژه در مناطق سیل‌خیز، بسیار مورد توجه بوده است. بار رسوبی معلق یکی از مهم‌ترین اشکال رسوبات رودخانه است که در اثر تلاطم جریان در آب به صورت معلق انتقال می‌یابد. روند بار رسوبی معلق روزانه یکی از پیچیده‌ترین فرایندهای هیدرولوژیکی و زیست‌محیطی

غیرخطی به‌شمار می‌رود (رجایی و همکاران، ۲۰۱۰). اندازه‌گیری بار رسوبی معلق، با توجه به هزینه زیاد و وقت‌گیر بودن آن به راحتی میسر نیست، این امر سبب شده تا این پارامتر مهم در بسیاری از رودخانه‌ها در دسترس نباشد. پیش‌بینی بار رسوبی معلق می‌تواند در زمینه تعیین عمر سازه‌های هیدرولیکی و مدیریت منابع آبی کمک شایانی بنماید. تاکنون روش‌ها و مدل‌سازی‌های مختلفی در زمینه پیش‌بینی بار رسوبی معلق انجام شده است (ورستراتن و پسن، ۲۰۰۱؛ چوی و لی، ۲۰۱۵؛ وانگ و همکاران، ۲۰۱۵). امروزه به‌کارگیری روش‌ها و تکنیک‌های هوش مصنوعی در پیش‌بینی پدیده‌های هیدرولوژیکی بسیار متداول شده است (کیسی، ۲۰۱۲؛ لعدانی و همکاران، ۲۰۱۳). بدیهی است کاربرد پارامترهای مؤثر در فرسایش و رسوب نقش مهمی در دقت و صحت پیش‌بینی‌ها دارد. در مطالعات اخیر از پارامترهای مختلفی استفاده شده است، همچون میزان انعکاس طیفی باندهای تصاویر ماهواره‌ای، کاربری اراضی، زمین‌شناسی، و داده‌های اقلیمی (لعدانی و همکاران، ۲۰۱۳؛ ژو و همکاران، ۲۰۰۷؛ کومار و همکاران، ۲۰۱۶). از تصاویر ماهواره‌ای و شاخص‌های حاصل از آن‌ها می‌توان به منظور مدل‌سازی بار رسوبی معلق استفاده کرد. مطالعات صورت گرفته نشان‌دهنده موفقیت تصاویر ماهواره‌ای در بررسی تنوع مکانی و زمانی رسوب معلق بوده است (پارک و لترویس، ۲۰۱۴). مثلاً، هاشیموتو و اکی (۲۰۱۳)، با توجه به نقش دبی رودخانه در حمل رسوب، به برآورد دبی رودخانه ناکا در تاکاشیما با استفاده از تصاویر ماهواره‌ای مودیس پرداختند. آن‌ها با برقراری رابطه رگرسیونی بین میزان دبی از دهانه رودخانه و میزان انعکاس مودیس توانستند به رابطه مناسبی برای برآورد دبی‌های ماهانه و سالانه دست یابند.

کومار و همکاران (۲۰۱۶) به بررسی دینامیک رسوب در تالاب ساحلی با استفاده از سنجش از دور پرداختند. در این مطالعه ارتباط بین میزان انعکاس باندها و میزان رسوب کل (درجا و سطحی) و همچنین تغییرات زمانی رسوب کل با توجه به میزان انعکاس باندها بررسی شد. نتایج نشان داد مدل‌های چندجمله‌ای ارتباط معنی‌داری را بین رسوب کل و میزان انعکاس برقرار کرده‌اند و تغییرات فصلی و سالانه در توزیع رسوب کل مشاهده می‌شود. نچد و همکاران (۲۰۱۰) نقشه‌برداری از کل مواد معلق با استفاده از الگوریتم ژنتیک و تصاویر ماهواره‌ای مودیس و مریس را مطالعه کردند. در این پژوهش بهترین طول باند مناسب برای مدل‌سازی بار رسوبی معلق کل تعیین شد. کمترین خطای نسبی در برآورد مجموع بار معلق^۱ برای تصاویر MODIS باند ۶۶۷ نانومتر و ۶۷۸ نانومتر و برای تصاویر مریس باندهای ۶۶۵ نانومتر و ۶۸۱ نانومتر مشخص شد.

وانگ و لیو (۲۰۱۰) با استفاده از تصاویر ماهواره‌ای مودیس برآورد بار رسوب را بررسی کردند. در این مطالعه از داده‌های ماهواره‌ای مودیس با قدرت تفکیک زمانی بالا استفاده شده است. نتایج حاصل از آن نشان داد که با توجه به تفاوت انعکاس آب در باندهای ۲ و ۵ می‌توان از آن برای پیش‌بینی بار رسوبی معلق استفاده کرد.

تصاویر ماهواره‌ای لندست با توجه به قدرت تفکیک بسیار زیاد آن‌ها از دقت مکانی بیشتری برخوردار است. دا سیلویا و همکاران (۲۰۱۵) به کالیبراسیون طیفی تصاویر ماهواره‌ای چندطیفی برای ارزیابی غلظت رسوب معلق پرداختند. در این مطالعه، از تصویر ماهواره‌ای CBERS^۲ و لندست ۵ از سال ۲۰۰۸ برای برآورد غلظت رسوب معلق و کل بار

1. Total Suspended Matter

2. China-Brazil Earth Resource Satellite

معلق رودخانه پرنایبا^۱ در برزیل استفاده شد. مقدار رسوب در سیستم تعلیق با استفاده از الگوریتم TASSAN، که در اصل برای استفاده در تصاویر لندست ۵ توسعه داده شد، محاسبه شد. نتایج نشان داد تغییر غلظت رسوب معلق به شدت تحت تأثیر بارش فصلی بوده است.

موتنهر و همکاران (۲۰۱۴) با استفاده از تصاویر ماهواره‌ای لندست ۵ مدل‌سازی تجربی بار رسوبی معلق در رودخانه آمازون را انجام دادند. در این مطالعه مدل‌های تجربی برای بازیابی اطلاعات غلظت رسوب معلق^۲ در رودخانه آب سفید آمازون، با استفاده از داده بازتاب حاصل از لندست ۵، صورت گرفت. مدل‌های رگرسیون چندگانه برای مجموعه داده‌هایی که بر اساس ویژگی‌های عمومی زمین‌شناسی حوضه زهکشی تعریف می‌شوند اجرا شد. نتایج حاکی از توانمندی تصاویر لندست ۵ برای بازیابی داده‌های سری‌های تاریخی بود.

ژانگ و همکاران (۲۰۱۴) نیز روند رسوبات رودخانه زرد را با استفاده از تصاویر ماهواره‌ای لندست ارزیابی کردند. نتایج نشان داد، با استفاده از الگوریتم اصلاح و بازیابی مدل جوئی مناسب، می‌توان از $TM^3/ETM +$ برای تعیین کمی غلظت رسوب معلق در مصب رودخانه زرد استفاده کرد.

از آنجا که میزان انعکاس طیفی در فناوری مربوط به ماهواره‌ها و سنجنده‌های آن‌ها همواره در حال تکامل و پیشرفت‌های درخور توجه بوده و نتیجه آن افزایش و بهبود رزولوشن‌های زمانی، مکانی، طیفی، و رادیومتری است و تصاویر ماهواره‌ای متأثر از ویژگی سطحی زمین (خاک، آب، و پوشش گیاهی) است، با در نظر گرفتن تأثیر ویژگی‌های سطح زمین بر میزان فرسایش و تولید رسوب در سطح حوضه‌های آبخیز، می‌توان از میزان انعکاس طیفی باندهای تصاویر ماهواره‌ای به منظور مدل‌سازی بار رسوب استفاده کرد. در این مطالعه با استخراج شاخص‌های تصاویر ماهواره‌ای و پارامترهای ژئومورفومتری حوضه‌های آبخیز، که از ویژگی‌های سطحی حوضه‌ها نشأت گرفته‌اند، به بررسی و مقایسه کارایی این پارامترها در پیش‌بینی بار رسوبی معلق پرداخته شد. از طرفی، کاربرد همه این پارامترها و شاخص‌ها به نحو چشمگیری موجب افزایش حجم داده‌های ورودی و پیچیدگی مدل خواهد شد. بدین منظور، تکنیک کاهش ویژگی برای کاهش حجم فضای اطلاعات ورودی راهکار مناسبی است. در این زمینه، کاربرد یک ابزار قوی و مناسب در فرایند شبیه‌سازی بسیار ضروری است. بنابراین، در این تحقیق از روش‌هایی نظیر شبکه عصبی مصنوعی، رگرسیون خطی، K نزدیک‌ترین همسایه، فرایند گوسی، ماشین بردار پشتیبان، و ماشین بردار پشتیبان تکاملی برای بررسی نقش این پارامترها در پیش‌بینی بار رسوبی معلق استفاده شد تا تأثیر این پارامترها در بهبود مدل‌ها ارزیابی شود.

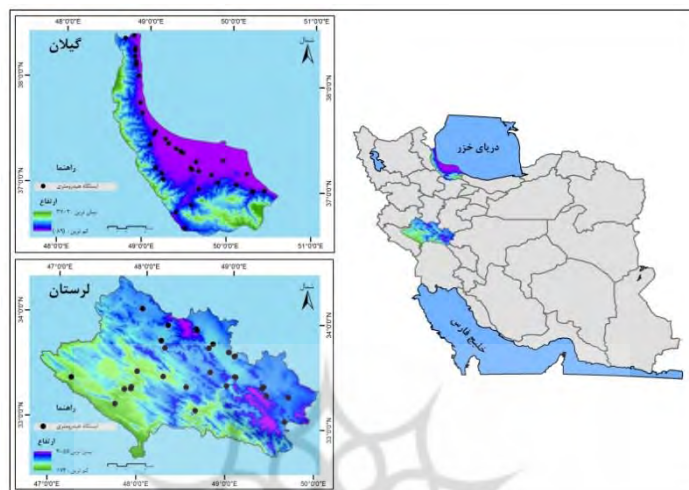
مواد و روش‌ها

مناطق مورد مطالعه

مناطق مورد مطالعه شامل ۶۸ حوضه آبخیز واقع در استان‌های گیلان و لرستان ایران است. این مناطق از نظر طول دوره

1. Parnaiba
2. Suspended Sediment Concentration
3. Enhanced Thematic Mapper

آماری، نسبت به سایر حوضه‌های کشور، شرایط مناسب‌تری دارند. حداقل ارتفاع مناطق مورد مطالعه ۸۹- متر و حداکثر آن ۴۰۷۵ متر است. این دو منطقه در دو اقلیم و شرایط پوشش گیاهی متفاوت واقع شده‌اند. شکل ۱ موقعیت مناطق مورد تحقیق و پراکنش ایستگاه‌های مطالعاتی را نشان می‌دهد.



شکل ۱. موقعیت منطقه و ایستگاه‌های مورد مطالعه

پردازش داده‌ها

استخراج داده‌های ژئومورفومتری

پس از تعیین مناطق مورد مطالعه پارامترهای ژئومورفومتری آن‌ها استخراج شد. استخراج پارامترهای ژئومورفومتری از مدل رقومی ارتفاعی ۳۰ متری منطقه که از سایت USGS تهیه شده بود، با استفاده از نرم‌افزار ساگا صورت گرفت. پارامترهای ژئومورفومتری بیانگر ویژگی‌های سطحی منطقه‌اند (جدول ۱).

جدول ۱. پارامترهای ژئومورفومتری مستخرج از DEM

Analytical Hillshading	MRRTF ¹
Aspect	MRVBF ²
Catchment Area	Plan Curvature
Channel Network Base Level	Profile Curvature
Convergence Index	Relative Slope Position
Cross-Sectional Curvature	Slope

1. Multi resolution ridge top flatness index

2. Multi resolution index off valley bottom flatness

ادامه جدول ۱. پارامترهای ژئومورفومتری مستخرج از DEM

Discharge	Strahler Order
Drainage Density	Stream Power Index
Flow Accumulation	Suspension Load
Flow Directions	Tangential Curvature
General Curvature	Topographic Wetness Index
Longitudinal Curvature	Vertical Distance to Channel Network
LS Factor	Watershed Basins

به منظور استخراج شاخص‌های تصاویر ماهواره‌ای از تصاویر ماهواره‌ای لندست ۸ در تاریخ‌های ۱۶ آگوست و ۲۷ سپتامبر سال ۲۰۱۳ استفاده شد. این تصاویر نیز از سایت USGS تهیه شد. سپس، پیش‌پردازش‌ها و تصحیحات لازم انجام شد.

شاخص نرمال شده پوشش گیاهی (NDVI)

شاخص NDVI یکی از کاربردی‌ترین شاخص‌ها در جهان است که به طور وسیع در مسائل گوناگون به کار می‌رود. این شاخص به روز و همکاران (۱۹۷۳) نسبت داده شده است. شاخص NDVI نسبت به تغییر در مقدار بیومس، مقدار کلروفیل، و تنش در مقدار آب تاج پوشش واکنش نشان می‌دهد. شاخص NDVI اساساً بر پایه رفتارهای مختلف نمایش داده شده به وسیله اختلاف در طول موج‌های الکترومغناطیس گسیل شده از گیاهان است: کلروفیل II داخل گیاه انرژی واقع در طول موج قرمز را جذب می‌کند؛ در حالی که مزوفیل II در بخش مادون قرمز امواج را منعکس می‌کند. این شاخص از رابطه ۱ به دست می‌آید:

$$NDVI = \frac{P_{nir} - P_{red}}{P_{nir} + P_{red}} \quad (1)$$

P_{red} و P_{nir} به ترتیب بازتابندگی در باندهای مادون قرمز نزدیک و قرمز است. مقادیر این شاخص بین -۱ تا ۱ است. اگر مقدار این شاخص $1 < NDVI < 0$ نشان دهنده پوشش گیاهی، $0 < NDVI < 1$ نشان دهنده خاک و اگر $1 < NDVI < 1$ نشان دهنده وجود خاک است. محدوده تغییرات معمولاً برای پوشش گیاهی ۰/۲ تا ۰/۸ است (رحمانی و همکاران، ۱۳۹۰).

شاخص Clay Index

کولکزیک و لوگان (۱۹۸۹) یک الگوریتم شاخص رس را بر مبنای رویکرد الیویدج و لیون با پردازش داده‌های تصاویر ماهواره‌ای (TM) انجام دادند. آن‌ها، با اعمال تصحیحات اتمسفری بر روی باندها، طبقه‌بندی نظارت شده با آموزش را با

استفاده از مجموعه مناطق دارای پوشش گیاهی، مناطق دارای رخنمون خاک، و زمینه‌های آب انجام دادند. رسم اریب و رگرسیون باند ۵ به ۷ در مقابل باند ۴ به ۳ برای همه پیکسل‌ها آموزش داده شد؛ رابطه ۲ آن را نشان می‌دهد.

$$CI = \left(TM \frac{5}{7} \right) - K_1 - \left(K_2 - \left(TM \frac{4}{3} \right) \right) \quad (2)$$

در رابطه ۲، K_1 عرض از مبدأ خط گیاهی و K_2 شیب است. شاخص را برای همه پیکسل‌ها می‌توان محاسبه کرد (رنکز، ۱۹۹۹).

کاربری اراضی

از طبقه‌بندی تصاویر ماهواره‌ای نقشه‌های موضوعی به دست می‌آید که نشان‌دهنده توزیع جغرافیایی پدیده‌هایی است از قبیل خاک، آب، و گیاه. طبقه‌بندی نظارت‌شده دقیق‌ترین روش طبقه‌بندی به منظور تعیین کاربری اراضی است و از آن در مطالعات اخیر استفاده شده است (کوسکو و آنا، ۲۰۰۷). در این مطالعه نیز به منظور تعیین کاربری اراضی در مناطق مطالعاتی طبقه‌بندی نظارت‌شده انجام شد. کاربری‌های شناسایی شده در منطقه شامل جنگل، مرتع، صخره، اراضی شهری، و اراضی کشاورزی است.

داده‌های دبی و رسوب

با تهیه شاخص‌ها، نزدیک‌ترین داده‌های رسوب و دبی برداشت‌شده در ایستگاه‌های هیدرومتری به تاریخ تصاویر نیز به عنوان خروجی وارد مجموعه داده‌ها شد.

آنالیز مؤلفه اصلی^۱

با توجه به تأثیر مقادیر آماری پارامترها و شاخص‌ها در برآورد بار رسوبی، مقادیر آماری هر یک از آنان محاسبه و به عنوان پارامترهای ورودی مدل در نظر گرفته شد. این امر موجب افزایش حجم پارامترهای ورودی شد (مجموع پارامترهای ورودی مدل ۱۵۸ پارامتر است). با توجه به افزایش حجم اطلاعات ورودی مدل‌ها، به منظور کاهش پیچیدگی تحلیل متغیرها و تفسیر بهتر اطلاعات، از آنالیز مؤلفه اصلی - که از روش‌های آماری چندمتغیره است - استفاده شد (کمدوبین و همکاران، ۲۰۰۵). در این روش متغیرهای اولیه به طور مستقیم به کار نمی‌روند، بلکه نخست به مؤلفه‌هایی تبدیل می‌شوند. سپس، این مؤلفه‌ها به جای متغیرهای اولیه استفاده می‌شوند. به سبب کاربرد همه متغیرها در تشکیل مؤلفه‌ها، اطلاعات متغیرهای اولیه با کمترین تلفات ارائه می‌شود.

فرایند مدل‌سازی

در این مطالعه به منظور بررسی پارامترهای ورودی در پیش‌بینی بار رسوبی معلق از مدل‌های مختلف داده‌کاوی همچون

رگرسیون خطی، فرایند گوسی، شبکه عصبی مصنوعی، k نزدیک‌ترین همسایه، ماشین بردار پشتیبان، و ماشین بردار پشتیبان تکاملی استفاده شد.

• رگرسیون خطی^۱

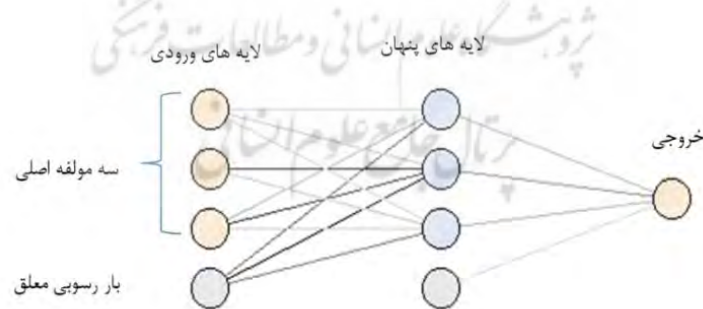
رگرسیون خطی برای مدل کردن مقدار یک متغیر کمی وابسته، که بر رابطه خطی‌اش با یک یا چند متغیر مستقل بنا شده، به کار می‌رود. در مدل رگرسیون خطی فرض بر این است که رابطه‌ای خطی (یا خط مستقیم) بین متغیر وابسته و هر متغیر مستقل وجود دارد. رابطه^۳ این معادله را نشان می‌دهد.

$$Y_i = a_0 + a_1x_{i,1} + a_2x_{i,2} + \dots + a_nx_{i,n} + e_i \quad (3)$$

که در آن y_i مقدار مورد نام متغیر کمی وابسته است، p تعداد پیشگوه‌هاست، b_j مقدار ضریب زام است، X_{ij} مقدار مورد نام از پیشگوی زام است، e_i خطای در مقدار مشاهده‌شده برای مورد نام است.

• شبکه عصبی مصنوعی^۲

شبکه‌های عصبی مصنوعی از جمله مدل‌های محاسباتی‌اند که می‌توانند رابطه بین ورودی‌ها و خروجی‌های یک سیستم فیزیکی را- حتی اگر پیچیده و غیرخطی باشد- با شبکه‌ای از گره‌ها، که همگی به هم متصل‌اند، تعیین کنند. ساختار شبکه‌های عصبی به نحوی است که نورون‌ها در دسته‌هایی که لایه نامیده می‌شوند مرتب می‌گردند. معماری معمول برای این شبکه‌ها شامل سه لایه ورودی، پنهان، و خروجی است. لایه ورودی داده‌ها را در شبکه توزیع می‌کند. لایه پنهان داده‌ها را پردازش می‌کند و لایه خروجی نتایج را به ازای ورودی‌های مشخص استخراج می‌کند. همچنین، هر شبکه می‌تواند چندین لایه داشته باشد. شکل ۲ ساختار شبکه اعمال شده بر روی داده‌ها را نشان می‌دهد.



شکل ۲. ساختار شبکه مورد استفاده

• K نزدیک‌ترین همسایه^۳

الگوریتم k نزدیک‌ترین همسایه شامل انتخاب تعداد مشخصی از بردار داده‌ها و سپس بازنمونه‌گیری تصادفی از آن

مجموعه برای شبیه‌سازی دوره زمانی متعاقب یک دوره معین است. از مزایای کاربرد این الگوریتم در پیش‌بینی‌ها می‌توان اشاره کرد به اجرای ساده، عدم نیاز به مرحله تخمین پارامترها، قابلیت مدل‌سازی غیرخطی، مؤثر بودن، و عملکرد با بازدهی بالا در برخورد با دسته‌های زیادی از داده‌ها.

• فرایند گوسی^۱

فرایند گوسی یک روش یادگیری ماشینی غیرپارامتری قوی برای ایجاد مدل‌های احتمال‌گرایانه جامع از مسائل دنیای واقعی است. فرایند گوسی فرایندی تصادفی است و متشکل از مقادیر تصادفی در هر نقطه در یک دامنه زمانی یا مکانی؛ به طوری که هر یک از متغیرهای تصادفی دارای توزیع نرمال است. به علاوه، هر مجموعه متناهی از این متغیرهای تصادفی دارای توزیع نرمال چندمتغیره است. فرایندهای گوسی توزیعات گوسی چندمتغیره را به بعدیت نامتناهی توسعه می‌دهند. به طور رسمی، یک فرایند گوسی داده‌هایی تولید می‌کند که در طول این طیف قرار دارد؛ به طوری که هر زیرمجموعه متناهی دامنه یک توزیع گوسی چندمتغیره را دنبال می‌کند.

• ماشین‌های بردار پشتیبان^۲

ماشین‌های بردار پشتیبان دسته‌ای از روش‌های یادگیری با ناظر هستند که برای مسائل طبقه‌بندی و رگرسیون به کار می‌روند. واپنیک و همکارانش در سال ۱۹۹۵ این روش را معرفی کردند (هوانگ و چنگ، ۲۰۰۷). این روش بر پایه نظریه یادگیری محاسباتی توسعه یافته است؛ در حالتی که داده‌ها به صورت خطی به شکل رابطه ۴ قابل ارائه‌اند:

$$y = \text{sign} \left[\sum_{i=1}^N y_i \alpha_i (X * X_i) + b \right] \quad (4)$$

در رابطه ۲، پارامترهای ابر صفحه هستند. اگر داده‌ها به صورت خطی تفکیک‌پذیر نباشند، رابطه ۴ به رابطه ۵ تغییر می‌یابد:

$$y = \text{sign} \left[\sum_{i=1}^N y_i \alpha_i K(X, X_i) + b \right] \quad (5)$$

$K(X, X_i)$ تابع کرنلی است که برای ایجاد تابع ماشین‌هایی با انواعی مختلف از سطوح تصمیم‌گیری غیرخطی در فضای داده‌ها ضرب‌های داخلی تولید می‌کند. انتخاب مناسب تابع کرنل امکان استفاده از یک تابع غیرخطی در فضای ورودی‌ها را برای تبدیل به تابع خطی در فضای ویژگی‌ها فراهم می‌کند.

• ماشین بردار پشتیبان تکاملی^۳

مدل ماشین بردار تکاملی از یک استراتژی تکاملی برای بهینه‌سازی استفاده می‌کند. این مدل یک الگوریتم تکاملی را برای حل مشکل بهینه‌سازی دوگانه ماشین بردار پشتیبان ارائه می‌دهد. اجرای این الگوریتم در بسیاری از مجموعه

1. Gaussian Process

2. Support Vector Machine

3. Support Vector Machine Evolutionary

داده‌ها بسیار سریع‌تر و آسان‌تر از ماشین بردار ساده است. به علاوه، این سیستم قادر به یادگیری با هسته است که نیمه‌متناهی مثبت نیستند و از آن می‌توان برای یادگیری چندمنظوره استفاده کرد، که موجب می‌شود تا انتخاب پارامتر C قبل از یادگیری غیرضروری باشد. EVSM بهترین استفاده را از IGA در بهینه‌سازی پارامترهای سیستم با طراحی مدل کروموزومی GA کارآمد دارد و همچنین همچون یک عملگر هوشمند است. ESVM با تجزیه و تحلیل فرکانس از ویژگی‌های انتخاب شده یک مجموعه کوچک از ویژگی‌های مؤثر را شناسایی می‌کند و از این رو باعث بهبود دقت طبقه‌بندی می‌شود (هانگ و چنچ، ۲۰۰۷). IGA مورد استفاده به طور مختصر ارائه می‌شود؛ در حالی که قابلیت طرح‌های آزمایشی متعامد و برتری متقاطع هوشمند را می‌توان در مطالعات دیگر یافت (هو و همکاران، ۲۰۰۴؛ هوانگ و چنگ، ۲۰۰۷).

ارزیابی مدل

مدل‌ها با استفاده از روش Leaving one Out ارزیابی شد. در این روش هر بار یکی از داده‌ها به عنوان داده آزمایشی از سایر داده‌ها جدا می‌شود و فرایند یادگیری با مابقی داده‌ها ($n-1$) انجام می‌گیرد. با توجه به به کارگیری مجموعه داده‌ها در فرایند ارزیابی مدل‌ها، نتایج قابل اعتماد خواهد بود.

به منظور ارزیابی نتایج الگوریتم‌های اعمال شده بر روی داده‌ها، از معیارهای ارزیابی Root mean squared error (RMSE)، relative error (Re)، Correlation coefficient (r) و Absolute error (AE) استفاده شد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (o_i - p)^2}{n}} \quad (6)$$

$$Re = \frac{p - o}{o} = \frac{p}{o} - 1 \quad (7)$$

$$r = \frac{\sum_{i=1}^n (p_i - \bar{p})(o_i - \bar{o})}{\sqrt{\sum_{i=1}^n (p_i - \bar{p})^2 \sum_{i=1}^n (o_i - \bar{o})^2}} \quad (8)$$

$$Re = p - \quad (9)$$

که در این معادلات o مقادیر مشاهده‌ای، p داده‌های پیش‌بینی شده، \bar{p} میانگین داده‌های پیش‌بینی شده، \bar{o} میانگین داده‌های مشاهده شده، و n تعداد داده‌هاست.

وزن‌دهی پارامترها

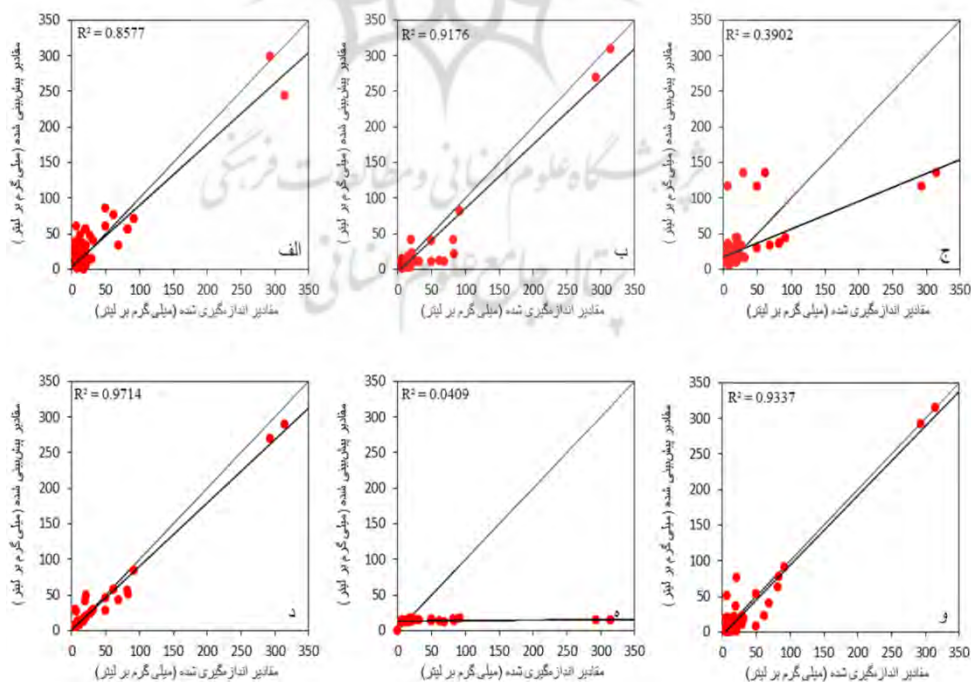
همه پارامترهای ورودی مدل دارای تأثیر و اهمیت یکسانی در پیش‌بینی نیستند. برخی از پارامترها همبستگی و ارتباط بیشتری با خروجی مدل دارند و در پیش‌بینی‌ها تأثیر بیشتری داشته‌اند. وزن‌دهی پارامترها یکی از تکنیک‌های داده‌کاوی است. در این مطالعه به منظور وزن‌دهی از الگوریتم ماشین بردار پشتیبان استفاده شد. این الگوریتم ضرایب بردار نرمال یک ماشین بردار پشتیبان خطی را به عنوان وزن ویژگی تعیین می‌کند (صنّعی آباده و همکاران، ۱۳۹۳).

یافته‌های پژوهش

در بررسی پارامترهای مناسب برای برآورد بار رسوبی معلق، نخست الگوریتم‌های مختلف بر روی داده‌های پارامترهای ژئومورفومتری اعمال شد و با استفاده از معیارهای ارزیابی مناسب دقت هر یک از مدل‌ها در پیش‌بینی بار رسوبی معلق با استفاده از پارامترهای ژئومورفومتری ارزیابی شد. نتایج نشان داد، با استفاده از پارامترهای ژئومورفومتری، مدل فرایند گوسی با $RMSE= ۳۵/۱۰$ و $R= ۰/۹۸۶$ بهترین مدل در پیش‌بینی بار رسوبی معلق است (جدول ۲، شکل ۳).

جدول ۲. نتایج مدل‌ها در پیش‌بینی رسوب معلق با استفاده از ورودی پارامترهای ژئومورفومتری

مدل	RMSE	AE	RE	r
شبکه عصبی مصنوعی	۱۷/۱۴	۱۰/۵۱	۵۳/۷۸	۰/۹۵
نزدیک‌ترین همسایه K	۴۱/۸۵	۲۰/۵۳	۱۰۰/۲۷	۰/۶۲
رگرسیون خطی	۲۰/۲۱	۱۵/۳۱	۱۱۴/۹۴	۰/۹۲
فرایند گوسی	۱۰/۳۵	۵/۴۰	۲۸/۰۴	۰/۹۸
ماشین بردار پشتیبان	۵۵/۴	۱۹/۷۴	۵۴/۹	۰/۲۵
ماشین بردار پشتیبان تکاملی	۱۴/۶۴	۹/۳۵	۶۰/۶۷	۰/۹۶



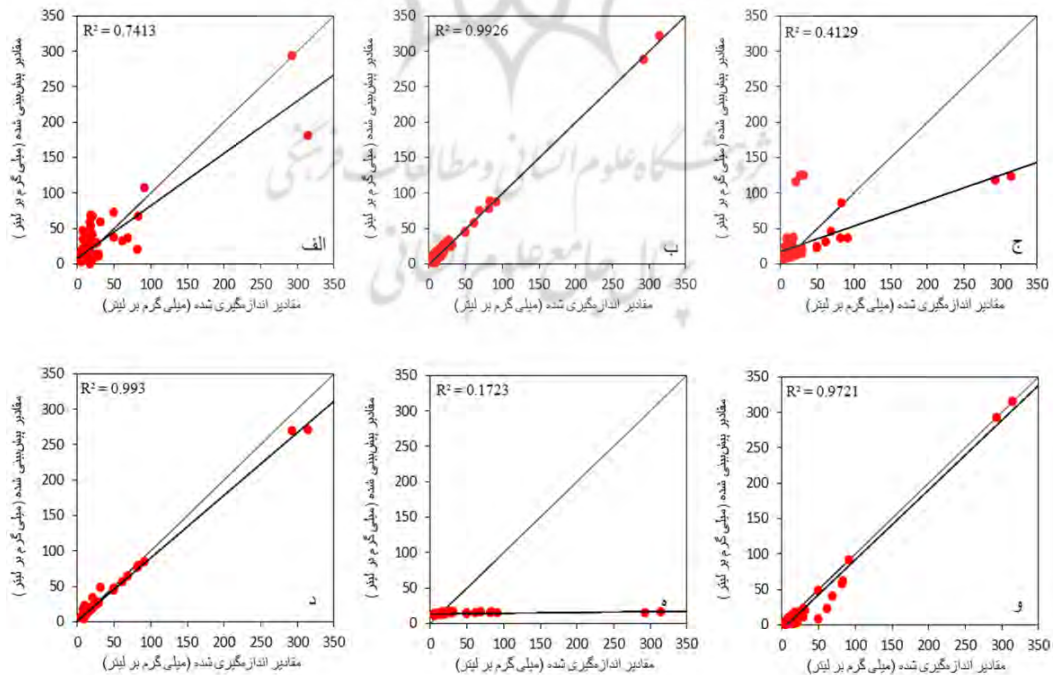
شکل ۳. نمودار پراکنش مقادیر مشاهده‌ای و پیش‌بینی شده با مدل الف) رگرسیون خطی؛ ب) شبکه عصبی مصنوعی؛ ج) نزدیک‌ترین همسایه؛ د) فرایند گوسی؛ ه) ماشین بردار پشتیبان؛ و) ماشین بردار پشتیبان تکاملی، با استفاده از پارامترهای ژئومورفومتری

در مرحله بعدی کار مدل‌ها بر روی داده‌های ورودی شاخص‌های تصاویر ماهواره‌ای اعمال شد. جدول ۳ نتایج حاصل از آن را نشان می‌دهد.

جدول ۳. نتایج مدل‌ها در پیش‌بینی رسوب معلق با استفاده از ورودی شاخص تصاویر ماهواره‌ای

مدل	RMSE	AE	RE	r
شبکه عصبی مصنوعی	۱۴/۳۳	۱۰/۹۲	۹۰/۴۷	۰/۹۷
نزدیک‌ترین همسایه K	۴۱/۳۰	۱۹/۴۸	۷۹/۱۸	۰/۶۴
رگرسیون خطی	۲۷/۲۵	۱۹/۰۱	۱۲۶/۲۲	۰/۸۶
فرایند گوسی	۷/۵۱	۳/۴۷	۱۴/۸۴	۰/۹۹
ماشین بردار پشتیبان	۵۵/۲۰	۱۹/۳۷	۵۱/۱۵	۰/۴۰
ماشین بردار پشتیبان تکاملی	۱۱/۵۸	۷/۳۷	۳۹/۰۷	۰/۹۸

نتایج حاصل از اجرای مدل‌ها بر روی داده‌های پارامترهای ژئومورفومتری نیز نشان داد که مدل فرایند گوسی با $RMSE=۵۱۳/۷$ و $R=۹۹۷/۰$ دارای بیشترین دقت برای پیش‌بینی بار رسوبی معلق با استفاده از این پارامترهاست. البته، بعد از این مدل مدل‌های ماشین بردار پشتیبان تکاملی و شبکه عصبی نیز دقت قابل قبولی دارند. شکل ۴ پراکنش مقادیر داده‌های واقعی و پیش‌بینی شده در مدل‌های اجرا شده را نشان می‌دهد:

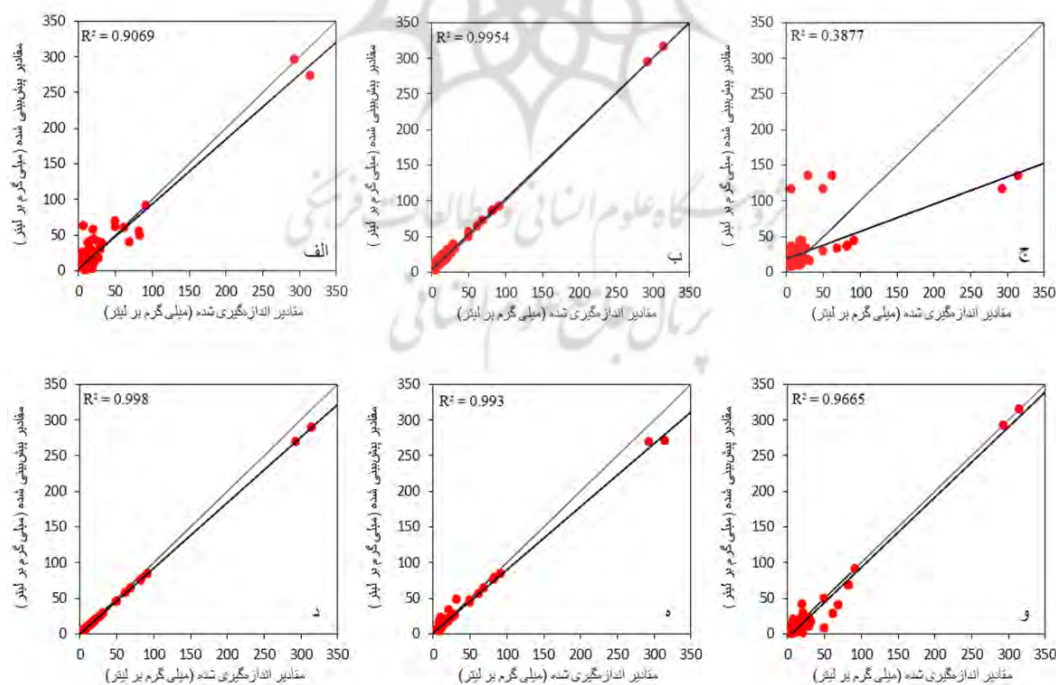


شکل ۴. نمودار پراکنش مقادیر مشاهده‌ای و پیش‌بینی شده با مدل الف) رگرسیون خطی؛ ب) شبکه عصبی مصنوعی؛ ج) نزدیک‌ترین همسایه؛ د) فرایند گوسی؛ ه) ماشین بردار پشتیبان؛ و) ماشین بردار پشتیبان تکاملی، با استفاده از شاخص‌های تصاویر ماهواره‌ای

سپس، شاخص تصاویر ماهواره‌ای و پارامترهای ژئومورفومتری به عنوان ورودی با هم تلفیق شد و مدل‌ها بر روی آن‌ها اجرا گردید. نتایج حاصل از آن‌ها نیز نشان داد که مدل فرایند گوسی با $RMSE=0.26/5$ و $R=99/0$ دارای بیشترین دقت در پیش‌بینی بار رسوبی معلق است. در این سری از داده‌ها نیز مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان دقت قابل قبولی دارند (جدول ۴، شکل ۵).

جدول ۴. نتایج مدل‌ها در پیش‌بینی رسوب معلق با استفاده از ورودی پارامترهای ژئومورفومتری و شاخص تصاویر ماهواره‌ای

مدل	RMSE	AE	RE	r
شبکه عصبی مصنوعی	۱۱/۷۹	۸/۶۸	۶۰/۵۷	۰/۹۷
نزدیک‌ترین همسایه K	۴۱/۹۳	۲۰/۹۰	۱۰۳/۳۲	۰/۶۲
رگرسیون خطی	۱۶/۳۵	۱۱/۸۷	۹۳/۱۸	۰/۹۵
فرایند گوسی	۵/۰۲	۲/۳۷	۸/۱۲	۰/۹۹
ماشین بردار پشتیبان	۵۵/۳	۱۹/۴۵	۰/۵۱	۰/۳۱
ماشین بردار پشتیبان تکاملی	۱۱/۷۲	۷/۶۲	۴۰/۹۶	۰/۹۸



شکل ۵. نمودار پراکنش مقادیر مشاهده‌ای و پیش‌بینی شده با مدل (الف) رگرسیون خطی؛ (ب) شبکه عصبی مصنوعی؛ (ج) نزدیک‌ترین همسایه؛ (د) فرایند گوسی؛ (ه) ماشین بردار پشتیبان؛ (و) ماشین بردار پشتیبان تکاملی، با استفاده از تلفیق پارامترهای ژئومورفومتری و شاخص‌های تصاویر ماهواره‌ای

وزن دهی

نتایج وزن دهی پارامترها نیز نشان داد که شاخص‌های $\text{Clay index(average)}$ و $b5(\text{average})$ و Ndvi(max) به ترتیب دارای بیشترین وزن اند؛ یعنی بیشترین تأثیر را در پیش‌بینی بار رسوبی معلق داشته‌اند و پارامترهای $\text{Vertical Curvature (min)}$ و $\text{Distance to Channel Network (CV)}$ و $\text{Cross-sectional Curvature(Average)}$ و $\text{Longitudinal Curvature (min)}$ به ترتیب دارای کمترین وزن و کمترین تأثیر در پیش‌بینی بار رسوبی معلق اند.

بحث و نتیجه‌گیری

به کارگیری مدل‌های داده‌کاوی، در مقایسه با سایر روش‌های برآورد بار رسوبی معلق، از دقت بسیار زیادی برخوردار است (رجایی، ۲۰۱۱؛ کیسی، ۲۰۱۲؛ ذونعمت کرمانی و همکاران، ۲۰۱۶). در این مطالعه از پارامترهای ژئومورفومتری و شاخص‌های تصاویر ماهواره‌ای به منظور بهینه‌سازی مدل‌های داده‌کاوی برآورد رسوب استفاده شد. استفاده از شاخص‌های تصاویر ماهواره‌ای و پارامترهای ژئومورفومتری به عنوان ورودی مدل باعث افزایش دقت الگوریتم‌های داده‌کاوی در پیش‌بینی رسوب معلق شد. نتایج حاصل از مطالعه نشان داد که شاخص‌های تصاویر ماهواره‌ای تأثیر بیشتری در پیش‌بینی بار رسوبی معلق دارند و استفاده از این شاخص‌ها نسبت به پارامترهای ژئومورفومتری در افزایش دقت مدل‌ها مؤثرتر است؛ به طوری که، با در نظر گرفتن شاخص‌های تصاویر ماهواره‌ای، مدل فرایند گوسی با $\text{RMSE}=513/7$ و نیز در صورت استفاده از پارامترهای ژئومورفومتری مدل فرایند گوسی با $\text{RMSE}=35/10$ دارای بیشترین میزان دقت است. با تلفیق پارامترهای ژئومورفومتری و شاخص‌ها میزان دقت همه مدل‌ها افزایش یافته و مدل فرایند گوسی با $\text{RMSE}=0/26/5$ بیشترین دقت را داشته است. اما، به طور کلی می‌توان نتیجه گرفت که مدل‌های اجرا شده در این مطالعه نسبت به مدل‌هایی که داده‌های ورودی آن‌ها صرفاً داده‌های اقلیمی بوده است از دقت بیشتری برخوردار بوده‌اند (ذونعمت کرمانی و همکاران، ۲۰۱۶؛ لیو و همکاران، ۲۰۱۳؛ کوبانر و همکاران، ۲۰۰۹؛ لیو و همکاران، ۲۰۱۳). نتایج حاصل از وزن دهی نیز نشان از تأثیرگذاری بیشتر شاخص‌های تصاویر ماهواره‌ای در پیش‌بینی بار رسوبی معلق دارد. شاخص‌های $\text{Clay index(average)}$ و $b5(\text{average})$ و NDVI (max) دارای بیشترین وزن و اثر در پیش‌بینی بار رسوبی معلق بودند. بدین ترتیب، نتایج نشان داد که پارامترهای ژئومورفومتری و شاخص‌های تصاویر ماهواره‌ای می‌توانند به نحو چشمگیری باعث افزایش دقت مدل‌های پیش‌بینی رسوب معلق شوند. در پایان پیشنهاد می‌شود برخی پارامترهای دیگر نظیر خاک‌شناسی منطقه نیز به عنوان ورودی مدل‌ها در نظر گرفته شوند و تأثیر آن‌ها در بهبود مدل ارزیابی شود.

منابع

- صنعی آباد، م؛ محمودی، س. و طاهرپرور، م. (۱۳۹۳). *داده‌کاوی کاربردی*، ویراست دوم، تهران: نیاز دانش.
 رحمانی، ن؛ شاهدی، ک. و میریعقوب‌زاده، م. (۱۳۹۰). ارزیابی شاخص‌های پوشش گیاهی مورد استفاده در سنجش از دور (مطالعه موردی: حوضه هریسک)، هجدهمین همایش ژئوماتیک، تهران، دانشگاه علم و صنعت ایران.

- Camdevyren, H.; Demyr, N.; Kanik, A. and Kesky, S. (2005). Use of principal componentscores in multiple linear regression models for prediction of Chlorophyll-a in reservoirs, *Ecological Modelling*, 181(4): 581-589.
- Choi, S.U. and Lee, J. (2015). Assessment of total sediment load in rivers using lateral distribution method, *Journal of Hydro-environment Research*, 9(3): 381-387.
- Collins, A.L., Walling, D.E. (2004). Documenting catchment suspended sediment sources: problems, approaches and prospects, *Prog Phys Geogr*, 28:159-196.
- Cortes, C. and Vapnik, V. (1995). Support-vector network, *Mach. Learn*, 20: 273-297.
- Cobaner, M.; Unal, B. and Kisi, O. (2009). Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydro-meteorological data, *Journal of hydrology*, 367(1): 52-61.
- Da Silva, A.G.A.; Amaro, V.E.; Statterger, K.; Schwarzer, K.; Vital, H. and Heise, B. (2015). Spectral calibration of CBERS 2B multispectral satellite images to assess suspended sediment concentration, *ISPRS Journal of Photogrammetry and Remote Sensing*, 104: 53-62.
- Hashimoto, K. and Oki, K. (2013). Estimation of discharges at river mouth with MODIS image, *International Journal of Applied Earth Observation and Geoinformation*, 21: 276-281.
- Huang, H.L. and Chang, F.L. (2007). ESVM: Evolutionary support vector machine for automatic feature selection and classification of microarray data, *Biosystems*, 90(2): 516-528.
- Ho, S.-Y.; Shu, L.-S. and Chen, J.-H. (2004). Intelligent evolutionary algorithms for large parameter optimization problems, *IEEE Trans. Evolutionary Comput*, 8(6): 522-541.
- Kamusoko, C. and Aniya, M. (2007). Land use/cover change and landscape fragmentation analysis in the Bindura District, Zimbabwe, *Land degradation & development*, 18(2): 221-233.
- Kowalczyk, P. and Logan, K. (1989). TM processing for routine use in mineral exploration, in *Proceedings of the 7th Thematic Conference on Remote Sensing for Exploration Geology*, Vol. I, Environmental Research Institute of Michigan, Ann Arbor, Mich., pp. 323-329.
- Kumar, A.; Equeenuddin, S.M.; Mishra, D.R. and Acharya, B.C. (2016). Remote monitoring of sediment dynamics in a coastal lagoon: Long-term spatio-temporal variability of suspended sediment in Chilika, *Estuarine, Coastal and Shelf Science*, 170: 155-172.
- Kisi, O. (2012). Modeling discharge-suspended sediment relationship using least square support vector machine, *Journal of hydrology*, 456: 110-120.
- Lafdani, E.K.; Nia, A.M. and Ahmadi, A. (2013). Daily suspended sediment load prediction using artificial neural networks and support vector machines, *Journal of Hydrology*, 478: 50-62.
- Liu, Q.J.; Shi, Z.H.; Fang, N.F.; Zhu, H.D. and Ai, L. (2013). Modeling the daily suspended sediment concentration in a hyperconcentrated river on the Loess Plateau, China, using the Wavelet° ANN approach, *Geomorphology*, 186: 181-190.
- Montanher, O.C.; Novo, E.M.; Barbosa, C.C.; Rennó, C.D. and Silva, T.S. (2014). Empirical models for estimating the suspended sediment concentration in Amazonian white water rivers using Landsat 5/TM. *International Journal of Applied Earth Observation and Geoinformation*, 29: 67-77.
- Nechad, B.; Ruddick, K.G. and Park, Y. (2010). Calibration and validation of a generic multisensor algorithm for mapping of total suspended matter in turbid waters, *Remote Sensing of Environment*, 114(4): 854-866.
- Ouillon S.; Douillet, P. and Andrefouet, S. (2004). Coupling satellite data with in situ measurements and numerical modeling to study fine suspended-sediment transport: a study for the lagoon of New Caledonia, *Coral Reefs*, 23: 109-122.
- Park, E. and Latrubesse, E.M. (2014). Modeling suspended sediment distribution patterns of the Amazon River using MODIS data, *Remote Sensing of Environment*, 147: 232-242.
- Rahmani, N.; Shahedi, K. and Miryaghoub zadeh, M. (1390). Assessment vegetation indexes used in remote sensing (case study of the basin Harisak), Eighteenth Geomatics, Tehran, Iran University of Science and Technology (In Persian).

- Rajaei, T.; Nourani, V.; Zounemat-Kermani, M. and Kisi, O. (2010). River suspended sediment load prediction: Application of ANN and wavelet conjunction model, *Journal of Hydrologic Engineering*, 16(8): 613-627.
- Rajaei, T. (2011). Wavelet and ANN combination model for prediction of daily suspended sediment load in rivers, *Science of the total environment*, 409(15): 2917-2928.
- Rencz, A.N. (1999). *Remote sensing for the earth sciences: manual of remote sensing*, Vol. 3 (No. Ed. 3). John Wiley and sons, p 409.
- Rouse, J.W.; Haas, R.H.; Schell, J.A. and Deering, D.W. (1973). Monitoring vegetation systems in the great plains with ERTS, *Third ERTS Symposium*, NASA SP-351 I: 309-317.
- Sani Abade, M.; Mahmoudi, S. and Taherparvar, D. (1393). *Data mining applications* (second edition), Publishing need knowledge, Tehran. (In Persian).
- Schiebe, F.R; Harrington, Jr J.A. and Ritchie, J.C. (1992). Remote sensing of suspended sediments: the Lake Chicot, Arkansas project, *Int J Remote Sens*, 13: 1487-509.
- Verstraeten, G. and Poesen, J. (2001). Factors controlling sediment yield from small intensively cultivated catchments in a temperate humid climate, *Geomorphology*, 40(1): 123-144.
- Wang, J.J. and Lu, X.X. (2010). Estimation of suspended sediment concentrations using Terra MODIS: An example from the Lower Yangtze River, China, *Science of the Total Environment*, 408(5): 1131-1138.
- Wang, Y.G.; Wang, S.S. and Dunlop, J. (2015). Statistical modelling and power analysis for detecting trends in total suspended sediment loads, *Journal of Hydrology*, 520: 439-447.
- Zhang, M.; Dong, Q.; Cui, T.; Xue, C. and Zhang, S. (2014). Suspended sediment monitoring and assessment for Yellow River estuary from Landsat TM and ETM+ imagery, *Remote Sensing of Environment*, 146: 136-147.
- Zhu, 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.
- Zounemat-Kermani, M.; Kisi, O.; Adamowski, J. and Ramezani-Charmahineh, A. (2016). Evaluation of data driven models for river suspended sediment concentration modeling, *Journal of Hydrology*, 535: 457-472.