



بررسی کارایی مدل‌های هوشمند در برآورد رسوبات معلق رودخانه‌ای (مطالعه موردی: حوزه آبخیز بابامان، خراسان شمالی)

پریسا عشقی^۱، جلیل فرزاد مهر^۲، محمد تقی دستورانی^۳ و زینب عرب اسدی^۴

۱- دانشجوی کارشناسی ارشد، دانشگاه تربیت مدرس، تهران

۲- استادیار، دانشگاه تربیت مدرس، (نویسنده مسوول: farzadm102000@gmail.com)

۳- استاد، دانشگاه فردوسی مشهد

۴- مربی، دانشگاه بجنورد

تاریخ دریافت: ۹۳/۱۲/۱۸ تاریخ پذیرش: ۹۴/۵/۱۹

چکیده

برآورد دقیق مقدار رسوبات حمل شده توسط رودخانه‌ها در پروژه‌های آبی، از اهمیت بسیاری برخوردار است و لذا شناسایی و پیشنهادهای روش‌های مناسب جهت برآورد دبی رسوبات معلق از اهداف مهمی تلقی می‌شود که بایستی بر اساس تحقیقات مرتبط به انجام برسد. از جمله این روش‌ها می‌توان به روش‌های یادگیری ماشین از جمله مدل درختان تصمیم‌گیری، ماشین بردار پشتیبان و شبکه عصبی مصنوعی اشاره کرد. در این پژوهش، کارایی این تکنیک‌ها در پیش‌بینی میزان دبی رسوبات معلق حوزه آبخیز بابامان بجنورد مورد بررسی قرار گرفت. داده‌های ورودی برای پیش‌بینی رسوبات معلق حوزه بابامان در این پژوهش عبارتند از: دبی جریان، دبی رسوب معلق، بارش و تبخیر، که مربوط به دوره آماری از سال ۱۳۴۹ تا سال ۱۳۸۰ است. جهت ارزیابی دقت و صحت نتایج این مدل‌ها، معیارهای آماری MAE، RMSE، R استفاده شدند. در نهایت نتایج معیارهای آماری R و RMSE به ترتیب برای مدل منحنی سنجه ۰/۸۰ و ۵۵۸۶۳/۷۷، مدل شبکه عصبی ۰/۹۸ و ۱/۲۸، مدل درخت تصمیم ۰/۹۶ و ۴۸۸۸۱/۵۶ و مدل ماشین بردار پشتیبان ۰/۹۹ و ۰/۶۹۹۸ است. مقادیر به دست آمده نشان داد که ماشین بردار پشتیبان در مقایسه با روش‌های نامبرده، تطابق بسیار بیش تری با مقادیر اندازه‌گیری شده داشته است.

واژه‌های کلیدی: بار رسوب معلق، درخت تصمیم، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، منحنی سنجه رسوب

مقدمه

فرسایش و رسوب‌گذاری، فرآیندی است که به از دست رفتن خاک‌های حاصل‌خیز حوزه‌های آبخیز و همچنین ایجاد خسارات جبران‌ناپذیر به پروژه‌های عمرانی از جمله انباشته شدن رسوبات در پشت سدها و کاهش حجم مفید آن‌ها، تخریب سازه‌ها و غیره منجر می‌شود. از طرف دیگر، حمل رسوب روی شاخص‌های کیفیت آب از لحاظ شرب و کشاورزی نیز تأثیرگذار است. لذا برآورد حجم و مقدار نزدیک به واقعیت رسوبات حمل شده در پروژه‌های آبی، آبخیزداری و بهره‌برداری از منابع آب مورد نیاز است. محققین در مورد پدیده فرسایش و انتقال رسوب در سال‌های اخیر توانسته‌اند با استفاده از روش‌های هوش مصنوعی به عنوان یک ابزار جدید، مقدار رسوبات معلق را محاسبه کنند.

یوسفی و پورشرعیاتی (۱۳)، در برآورد رسوب معلق استان لرستان با استفاده از شبکه عصبی و ارزیابی توابع آموزشی به این نتیجه رسیدند که از بین الگوریتم‌های موجود، الگوریتم TRAINLM با ضریب همبستگی $R=0/99$ و $RMSE (ton/day) = 0/10$ بهترین الگوریتم است.

نتایج تحقیق طباطبایی و همکاران (۱۲)، در برآورد غلظت رسوب معلق روزانه با استفاده از شبکه عصبی مصنوعی و خوشه‌بندی داده‌ها به روش نگاشت خودسازمان ده رودخانه کرج نشان داد که استفاده از متغیرهای بارش و دمای روزانه به همراه دبی جریان و تفکیک زمانی داده‌ها، نقش مهمی در افزایش دقت برآورد رسوب رودخانه داشته است.

دهقانی و وفاه‌خواه (۵)، در مقایسه روش‌های تخمین رسوب معلق روزانه با استفاده از روش‌های منحنی سنجه

رسوب و شبکه عصبی در استان گلستان به این نتیجه رسیدند که شبکه پرسپترون چند لایه با ورودی‌های دبی همان روز و دبی یک و دو روز قبل، از دقت بالاتری برخوردار هستند. همچنین نتایج پژوهش نشان داد که دقت روش شبکه عصبی نسبت به روش‌های منحنی سنجه رسوب، بالاتر است.

فلامکی و همکاران (۶) در مدل‌سازی بار رسوب کل رودخانه‌ها با استفاده از شبکه‌های عصبی مصنوعی به این نتیجه رسیدند که مدل‌های ارائه شده بر پایه شبکه‌های عصبی با مقادیر رسوب کل مشاهده شده، هم‌خوانی بیش‌تری دارند و به ویژه شبکه MLP می‌تواند مقدار رسوب را در نقاط پیک به خوبی برآورد نماید.

اکبری و طالبی (۱)، در برآورد رسوبات معلق سد ایلام با استفاده از مدل درختان تصمیم‌گیری به این نتیجه رسیدند که این مدل در مقایسه با روش مرسوم منحنی سنجه رسوب، تطابق بسیار بیش‌تری با مقادیر اندازه‌گیری شده داشته است. کاکائی لعدانی و همکاران (۷)، در پیش‌بینی حجم رسوبات معلق با استفاده از مدل‌های GMDH و SVM^۱ به این نتیجه رسیدند که این دو مدل در پیش‌بینی حجم رسوبات معلق رودخانه دویرج، عملکرد بالایی دارند. دستورانی و همکاران (۴)، در مطالعه برآورد رسوبات معلق با استفاده از شبکه عصبی مصنوعی در حوزه آبخیز جامیشان نتیجه گرفتند که شبکه عصبی مصنوعی، نتایج قابل قبولی را جهت شبیه‌سازی بار معلق در ایستگاه حیدرآباد ارائه می‌کند. نتایج پژوهش طلوعی و همکاران (۱۱) با استفاده از شبکه عصبی مصنوعی و علم زمین‌آمار و با ادغام آنالیز سری‌های زمانی با آنالیز سری‌های مکانی به ارائه یک مدل جامع، جهت تخمین

1- MLP: Multi-Layer

2- GMDH: Group Method of Data Handling

3- SVM: Support Vector Machine

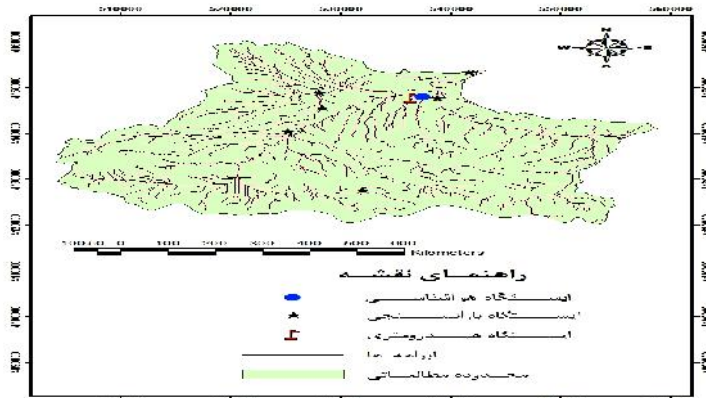
بنابراین با توجه به اهمیت میزان تولید رسوب معلق و هم‌چنین کمبود امکانات موجود در ایستگاه‌های هیدرومتری جهت تعیین مقدار رسوب واقعی، این مطالعه با هدف کلی شناخت و آزمون تعدادی از روش‌های هوشمند در برآورد میزان رسوب بار معلق و مقایسه نتایج آن‌ها با مقادیر مشاهده شده در ایستگاه‌های اندازه‌گیری و نیز روش منحنی سنجه رسوب به اجرا در آمده است.

مواد و روش‌ها منطقه مورد مطالعه

رودخانه بابامان در فاصله ۱۲ کیلومتری شمال شرقی بجنورد، به اترک می‌پیوندد. این رودخانه جریانات رودخانه‌های فیروزه در بخش جنوبی و چهارخوار در بخش جنوب شرقی و بش قارداش در بخش انتهایی حوزه بابامان را جمع‌آوری و به سمت رود اترک هدایت می‌کند. مختصات نقطه خروجی حوزه که محل ایستگاه هیدرومتری بابامان است دارای طول جغرافیایی (UTM) ۵۳۸۸۴۴ و عرض جغرافیایی (UTM) ۴۱۴۷۶۳۲ است. ایستگاه هیدرومتری، هواشناسی و باران‌سنجی در داخل حوزه و در نزدیکی خروجی حوزه قرار دارند. مساحت حوزه ۱۲۳۳۲/۶ کیلومتر مربع است. شکل ۱ موقعیت جغرافیایی محدوده مورد مطالعه را نشان می‌دهد.

بار معلق ماهانه در طول رودخانه آجی‌چای، نشان‌دهنده مناسب‌تر شدن شبکه عصبی در صورت استفاده از علم زمین‌آمار در برآورد مکانی بار معلق ماهانه بود. نتایج هنگ و سواتساکی (۸)، در تخمین رسوب معلق با استفاده از شبکه عصبی، نشان‌دهنده مناسب بودن شبکه عصبی و توانایی افزایش کارایی مدل با استفاده از اطلاعات کلیدی است.

سنتیل کومار و همکاران (۹)، در مدل‌سازی رسوب با استفاده از شبکه عصبی مصنوعی، منطق فازی و الگوریتم درخت تصمیم در حوزه کاسل هند به این نتیجه دست یافتند که مدل M_5 درخت تصمیم نسبت به شبکه عصبی و منطق فازی، از دقت و صحت بالاتری برخوردار است. شعبانی و شعبانی (۱۰)، در تخمین رسوبات معلق با استفاده از شبکه عصبی و منحنی سنجه در حوزه خوارستان به این نتایج دست یافتند که شبکه عصبی مصنوعی، مناسب‌تر از منحنی سنجه است. باتاچاریا و همکاران (۲)، در برآورد بار رسوب بستر و بار کل با استفاده از دو مدل شبکه عصبی و درخت، به مقایسه نتایج آن‌ها با روش‌های تجربی و داده‌های اندازه‌گیری شده واقعی پرداختند. نتایج حاصل نشان داد که مدل درخت تصمیم و شبکه عصبی (در هر دو مورد بار بستر و بار کل) نسبت به روش‌های تجربی، تطابق بهتری با داده‌های واقعی دارند،



شکل ۱- موقعیت جغرافیایی محدوده مورد مطالعه
Figure 1. The geographical location of the study area

داده‌های مجموع بارش دو روز قبل و میانگین دبی دو روز قبل تا میانگین دبی پنج روز قبل و مجموع بارش تا پنج روز قبل به عنوان متغیر ورودی به مدل وارد شده است. رسوب معلق هم به عنوان متغیر خروجی مدل است.

به این ترتیب پس از تحلیل‌های انجام شده که در طی اجرای روش‌های هوشمند و نتایج این روش‌ها به دست آمد، بهترین ورودی با پارامترهای دبی جریان، بارش، تبخیر، میانگین دبی پنج روز گذشته و مجموع بارش پنج روز گذشته تعیین شده است. تمامی داده‌ها به صورت روزانه مورد استفاده قرار گرفتند. با توجه به این که بازسازی داده‌ها به ویژه داده‌های رسوب همراه با خطاست در این پژوهش بازسازی صورت نگرفته است و فقط از داده‌های اندازه‌گیری موجود

روش پژوهش

در این پژوهش جهت برآورد رسوبات معلق از آمار ایستگاه هیدرومتری و هواشناسی بابامان واقع بر رودخانه چناران بجنورد که در نزدیکی خروجی حوزه قرار دارند، و مدل‌های شبکه عصبی، درخت تصمیم‌گیری و ماشین‌های بردار پشتیبان استفاده شده است. داده‌های ورودی برای پیش‌بینی رسوبات معلق حوزه بابامان در این پژوهش عبارتند از: دبی جریان (مترمکعب بر ثانیه)، دبی رسوب معلق (تن در روز)، بارش و تبخیر (میلی‌متر)، که مربوط به دوره آماری از سال ۱۳۴۹ تا سال ۱۳۸۰ است. جدول ۱ پارامترهای آماری داده‌های مورد استفاده را نشان می‌دهد. سپس برای بهبود نتایج مدل‌ها، با ثابت بودن دبی متناظر در هر بار اجرای مدل،

است که آمار پارامترهای دیگر آن از جمله دبی جریان، بارش و تبخیر نیز موجود بود، انتخاب شد. ۷۵ درصد داده‌ها جهت آموزش و ۲۵ درصد داده‌ها جهت آزمون صحت سنجی مدل‌ها استفاده شد.

استفاده شده است. همچنین داده‌های استفاده شده در این پژوهش تمام روزها را شامل نمی‌شود و فقط شامل روزهایی است که رسوب معلق برداشت شده و دبی متناظر با آن هم موجود است. تعداد کل داده‌های اندازه‌گیری شده مربوط به رسوب در کل دوره آماری ۴۹ تا ۸۰، تعداد ۱۴۷ داده بوده

جدول ۱- مقادیر پارامترهای آماری داده‌های مورد استفاده

Table 1. Values of statistical parameters of the used data

تبخیر	بارش	دبی	خصوصیات آماری	
۱/۸۵	۰/۵۸	۱/۴۷	میانگین	مرحله آموزش
۰	۰	۰/۵۴	حداقل	
۹/۲۰	۱۳	۷/۶۲	حداکثر	
۱/۳۷	۳/۰۷	۰/۸۴	ضریب تغییرات	مرحله آزمون
۳	۲/۴۵	۳/۵۳	میانگین	
۰	۰	۰/۴۹	حداقل	
۸/۷	۱۷	۹/۱۲	حداکثر	
۰/۷۹	۱/۶۶	۰/۶۱	ضریب تغییرات	

در مدل منحنی سنج رسوب، یک رابطه رگرسیونی بین داده‌های متناظر دبی جریان و دبی رسوب معلق استخراج می‌شود (این داده‌ها همان داده‌های کنار گذاشته شده برای کالیبراسیون مدل‌ها هستند). سپس بر اساس این رابطه، مقدار دبی روزانه رسوب معلق در روزهایی که غلظت رسوب اندازه‌گیری نشده است، برآورد می‌شود. پس از به دست آوردن معادله خط در روش منحنی سنج رسوب، داده‌های دبی جریان مربوط به روزهایی که برای مرحله آزمون انتخاب شده در این رابطه قرار داده می‌شود. بدین صورت که تک تک داده‌های دبی مرحله آزمون در معادله حاصل از منحنی سنج به جای X قرار می‌گیرند و رسوب متناظر مربوطه محاسبه می‌شود. رابطه ۵ معادله منحنی سنج رسوب را نشان می‌دهد:

$$Q_s = aQ_w^b \quad \text{رابطه (۵)}$$

که در آن، Q_s : دبی رسوب برحسب میلی‌گرم در لیتر یا تن در روز، Q_w : دبی جریان برحسب مترمکعب بر ثانیه و a و b : ضرایب ثابت معادله هستند.

شبکه عصبی

شبکه‌های عصبی مصنوعی، الگویی برای پردازش اطلاعات هستند که با تقلید از شبکه عصبی بیولوژیکی مغز انسان ساخته شده‌اند. عنصر کلیدی این الگو، ساختار جدید سیستم پردازش اطلاعات آن است که از تعداد زیادی عنصر (نورون) با ارتباطات قوی داخلی که هماهنگ با هم برای حل مسایل مخصوص کار می‌کنند، تشکیل شده است. بوئر و همکاران (۳)، در این پژوهش از ساختار شبکه عصبی پرسپترون چند لایه با تابع سیگموئید و الگوریتم انتشار به عقب استفاده شده است.

ساختار شبکه عصبی مصنوعی به شرح زیر است:

(الف) لایه‌ی ورودی: دریافت اطلاعات ورودی که به شبکه تغذیه شده است.

(ب) لایه‌ی پنهان: بین لایه ورودی و خروجی قرار می‌گیرد و محاسبات در این لایه صورت می‌گیرد.

برای اجرا و محاسبات روش‌های نامبرده از نرم‌افزار مطلب (۲۰۱۲)، استفاده شد. شرط لازم برای اجرای مدل‌های ذکر شده، نرمال‌سازی داده‌ها قبل از استفاده در مدل است. این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد، کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند برای نرمال‌سازی داده‌های تحقیق زدو و همکاران (۱۵) از رابطه (۱) استفاده نمودند.

$$X_n = \left(\frac{X - X_{\min}}{X - X_{\max}} \right) \quad \text{رابطه (۱)}$$

که این رابطه، x : معرف داده مشاهده شده، X_{\min} و X_{\max} به ترتیب حداقل و حداکثر مقدار داده‌های مشاهده شده و X_n : داده نرمال شده است. در ادامه، نتایج این مدل‌ها با روش مرسوم منحنی سنج رسوب مقایسه شد. برای ارزیابی و مقایسه کارایی مدل‌های مورد استفاده، از معیارهای آماری ضریب همبستگی (R)، جذر میانگین مربعات خطا ($RMSE$) و خطای مطلق (MAE) طبق روابط زیر استفاده شده است:

$$R = \frac{\sum (O_i - O)(P_i - P)}{\sqrt{\sum (O_i - \bar{O})^2 (P_i - P)^2}} \quad \text{رابطه (۲)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad \text{رابطه (۳)}$$

$$MAE = \frac{\sum |O_i - P_i|}{n} \quad \text{رابطه (۴)}$$

که در این روابط، O : مقادیر مشاهده شده و P : مقادیر برآورد شده، \bar{O} : میانگین مقادیر مشاهده شده و \bar{P} : میانگین مقادیر شبیه‌سازی شده و n : تعداد نمونه‌ها است. به‌منظور آشنایی بیشتر با روش مدل‌سازی مورد استفاده در این پژوهش، توضیح اجمالی در مورد هر کدام به‌صورت ذیل بیان می‌شود.

مدل منحنی سنج رسوب

ماشین بردار پشتیبان

هدف این روش، تشخیص و متمایز کردن الگوهای پیچیده در داده‌هاست. اولین الگوریتم برای طبقه‌بندی و دسته‌بندی الگوها در سال ۱۹۳۶ توسط فیشر^۳ ارائه شد و معیار آن برای بهینه کردن، کم کردن خطای طبقه‌بندی داده‌های آموزشی بوده است. ماشین بردار پشتیبان، یکی از روش‌های یادگیری با نظارت^۴ است که از آن برای طبقه‌بندی^۵ و رگرسیون^۶ استفاده می‌کند. SVM نیز مانند شبکه‌های پرسپترون چند لایه و توابع پایه‌ی شعاعی، می‌تواند برای کلاس‌بندی الگوها و برازش غیرخطی مورد استفاده قرار گیرد. نظریه ماشین‌های بردار پشتیبان، یک روش نسبتاً جدید طبقه‌بندی است که در سال‌های اخیر کانون توجهات پژوهشگران این حوزه بوده است (۱۴).

نتایج و بحث

نتایج مدل‌های منحنی سنج، شبکه عصبی مصنوعی، درخت تصمیم و ماشین بردار پشتیبان و مقادیر مربوط به معیارهای خطای مدل‌های نامبرده در جدول‌های ۲، ۳، ۴ و ۵ نشان داده شده است. شکل (۲) منحنی سنج حاصل از داده‌های آموزشی را نشان می‌دهد.

ج) لایه‌ی خروجی^۱: آخرین لایه در مدل است که نتایج مدل به صورت داده، شکل، نمودار و یا نقشه تنظیم شده و ارائه می‌شود.

درخت تصمیم‌گیری


یادگیری درخت تصمیم‌گیری، روشی برای تخمین توابع با مقدار گسسته که به داده‌های معشوش مقاوم بوده و قادر به یادگیری اصطلاحات دارای دو شاخه مختلف است تعریف می‌شود (۱۴). درختان تصمیم استقرایی، مجموعه‌ای از داده‌های معلوم را می‌گیرد و یک درخت تصمیم را از آن استنتاج می‌کند. سپس درخت می‌تواند به صورت مجموعه قوانینی برای پیش‌بینی نتیجه ویژگی‌های معلوم استفاده شود. مجموعه داده‌های اولیه که درخت به وسیله آن ایجاد می‌شود، به عنوان داده‌های آموزشی شناخته می‌شوند (۱۴). درخت تصمیم، الگوریتم‌های مختلفی را دارا می‌باشد. در این تحقیق از الگوریتم CART استفاده شده است. روش درختان رگرسیونی و طبقه‌بندی (CART) اولین بار به وسیله براین و همکاران در سال ۱۹۸۴ پیشنهاد شد (۱۴). درخت‌های تصمیم تولید شده توسط CART شامل دقیقاً دو شاخه برای هر گره تصمیم هستند. در این روش طبقه‌بندی، از داده‌های تاریخی برای ساخت اصطلاحاً درختان تصمیم استفاده می‌کند. آن گاه درختان تصمیم برای طبقه بندی داده‌های جدید استفاده می‌شود (۱۴).

جدول ۲- مقادیر معیارهای خطا در روش منحنی سنج رسوب

RMSE (ton/day)	MAE (ton/day)	R	ورودی
۵۵۸۶۳/۷۷	۶۳۵۵/۹۳۹	-۰/۸۰	دبی آب

جدول ۳- نتایج معیارهای آماری خطا مربوط به مدل شبکه عصبی مصنوعی در ترکیبات ورودی مختلف در مرحله آزمون

RMSE(ton/day)	MAE (ton/day)	R	ورودی
۲/۴۷۱	۲۳۶۲/۸۸۴	-۰/۸۹	دبی همان روز، بارش، تبخیر، میانگین دبی دو روز گذشته و مجموع بارش دو روز گذشته
۳/۲۳	۲۷۰/۶۹۵	-۰/۹۱	دبی همان روز، بارش، تبخیر، میانگین دبی سه روز گذشته و مجموع بارش سه روز گذشته
۲/۱۷	۲۹۶/۷۸۳	-۰/۹۲	دبی همان روز، بارش، تبخیر، میانگین دبی چهار روز گذشته و مجموع بارش چهار روز گذشته
۱/۲۸	۱۰۵/۸۷۱	-۰/۹۸	دبی همان روز، بارش، تبخیر، میانگین دبی پنج روز گذشته و مجموع بارش پنج روز گذشته



شکل ۲- منحنی سنج حاصل از داده‌های آموزشی.

Figure 2- Rating Curve obtained from training data

- | | | |
|-------------------|---------------|------------------------|
| 1- Output Layer | 2- Fisher | 3- Supervised Learning |
| 4- Classification | 5- Regression | |

جدول ۴- نتایج معیارهای آماری خطا مربوط به مدل درخت تصمیم در ترکیبات ورودی مختلف در مرحله آزمون
Table 4. The results of statistical errors of decision tree model in different input combinations in testing phase

RMSE (ton/day)	MAE (ton/day)	R	ورودی
۵۰۰۴۴/۷۷	۷۷۶۵/۸۱۱	۰/۴۱	دبی همان روز، بارش، تبخیر، میانگین دبی دو روز گذشته و مجموع بارش دو روز گذشته
۵۰۰۴۹/۳۴	۷۸۶۶/۵۱۴	۰/۶۷	دبی همان روز، بارش، تبخیر، میانگین دبی سه روز گذشته و مجموع بارش سه روز گذشته
۵۰۰۴۶/۳۴	۷۸۴۰/۰۵۴	۰/۶۹	دبی همان روز، بارش، تبخیر، میانگین دبی چهار روز گذشته و مجموع بارش چهار روز گذشته
۴۸۸۱/۵۶	۵۲۶۴	۰/۹۶	دبی همان روز، بارش، تبخیر، میانگین دبی پنج روز گذشته و مجموع بارش پنج روز گذشته

جدول ۵- نتایج معیارهای آماری خطا مربوط به مدل ماشین بردار پشتیبان در ترکیبات ورودی مختلف در مرحله آزمون
Table 5. The results of statistical errors of support vector machine model in different input combinations in testing phase

RMSE (ton/day)	MAE (ton/day)	R	ورودی
۲/۱۹۹۹	۱۶۶۶/۲۹۷	۰/۹۹۳	دبی همان روز، بارش، تبخیر، میانگین دبی دو روز گذشته و مجموع بارش دو روز گذشته
۱/۱۷۰۹	۲۴۷/۹۲۱	۰/۹۹۹	دبی همان روز، بارش، تبخیر، میانگین دبی سه روز گذشته و مجموع بارش سه روز گذشته
۰/۹۳۹۶	۱۸۲/۳۱۶	۰/۹۹	دبی همان روز، بارش، تبخیر، میانگین دبی چهار روز گذشته و مجموع بارش چهار روز گذشته
۰/۶۹۹۸	۲۴/۷۸	۰/۹۹۹۹	دبی همان روز، بارش، تبخیر، میانگین دبی پنج روز گذشته و مجموع بارش پنج روز گذشته

با توجه به شکل ۳ و جدول ۶ مشاهده می‌شود که روش بردار پشتیبان و سپس روش شبکه عصبی مصنوعی به ترتیب نتایج دقیق‌تری را جهت پیش‌بینی رسوب نشان می‌دهند. با توجه به بخش نتایج و شکل ۳ می‌توان بیان کرد که: مدل منحنی سنجه رسوب در این پژوهش روش مناسبی نیست. زیرا این روش بسیاری از نقاط با دبی‌های زیاد را بیش‌تری از مقادیر مشاهده‌ای و بسیاری از نقاط با دبی‌های کم را کم‌تر از نقاط مشاهده‌ای برآورد کرده است. که این امر می‌تواند یکی از ضعف‌های منحنی سنجه در برآورد رسوبات معلق باشد.

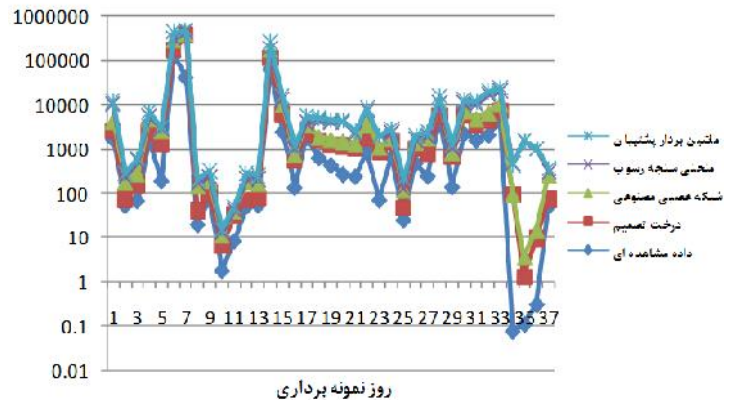
جدول ۶ مقادیر R، RMSE و MAE به دست آمده از مدل‌های استفاده شده در تحقیق را نشان می‌دهد. مقایسه نتایج معیارهای خطا، گویای آن است که مدل ماشین بردار پشتیبان نسبت به سایر مدل‌ها از دقت بیش‌تری برخوردار می‌باشد. همچنین شکل ۳ مقایسه خروجی روش‌های مورد استفاده در این پژوهش، با داده‌های آزمون را نشان می‌دهد. همان‌طور که مشخص است، روش بردار پشتیبان نسبت به سایر روش‌های مورد استفاده تطابق بیش‌تری با داده‌های مشاهده‌ای دارد. این امر، نشان‌دهنده کارایی بالای این روش نسبت به سایر روش‌هاست.

جدول ۶- نتایج مقایسه روش‌های نامبرده در بهترین حالت
Table 6. Results of comparison for the mentioned methods for the best condition

RMSE (ton/day)	MAE (ton/day)	R	مدل
۵۵۸۶۳/۷۷	۶۳۵۵/۹۳۹	۰/۸۰	منحنی سنجه
۱/۲۸۲۱	۱۰۵/۸۷۱	۰/۹۹	شبکه عصبی مصنوعی
۴۸۸۱/۵۶	۵۲۶۴	۰/۹۶	درخت تصمیم
۰/۶۹۹۹	۲۴/۷۸	۰/۹۹	ماشین بردار پشتیبان

مصنوعی، رسوب معلق مربوط به دبی‌های بالا را به خوبی شبیه‌سازی کرده است. این امر در مورد دبی‌های کم هم صادق است، اما در بعضی نقاط با دبی‌های کم، نقاطی به صورت استثناء نیز وجود دارند که مناسب عمل نکرده است.

در این رابطه اکبری و طالبی (۱) نیز به این نتیجه رسیدند که منحنی سنجه، بار معلق حوزه را به خصوص در موارد سیلابی که در برنامه‌ریزی‌ها حائز اهمیت بوده بسیار کمتر از مقدار مشاهده‌ای برآورد کرده است. روش شبکه عصبی



شکل ۳- مقایسه خروجی روش‌های نامبرده
Figure 3. Comparison of the out puts for mentioned methods

۱- اول ماشین بردار پشتیبان نسبت به روش شبکه عصبی مصنوعی، درخت تصمیم و منحنی سنجه، کارایی و دقت بالایی دارد.

۲- با توجه به مقادیر آماری، شبکه عصبی مصنوعی ($R=0/80$) و $RMSE = 55863/77$ و $MAE = 105/871$ نسبت به منحنی سنجه رسوب ($R=0/80$) و $RMSE = 55863/77$ و $MAE = 6355/939$ برتری دارد.

۳- شبکه عصبی مصنوعی، کارایی بهتری نسبت به درخت تصمیم دارد.

نتیجه به دست آمده از این تحقیق نشان می‌دهد که روش‌های ماشین یادگیری دارای دقت و صحت بالاتری نسبت به روش منحنی سنجه هستند. با توجه به نتایج به دست آمده، علت برتری نتایج برخی مدل‌ها نسبت به برخی دیگر در این تحقیق را می‌توان به شرح زیر بیان کرد: مدل ماشین‌های بردار پشتیبان نسبت به شبکه عصبی مصنوعی از دقت و کارایی بیش‌تری برخوردار است. زیرا مدل ماشین بردار پشتیبان، بهترین مرز تصمیم را برای جداکردن داده‌ها تعیین می‌کند، در صورتی که شبکه عصبی مصنوعی به اولین مرز تصمیم جداکننده که می‌رسد یادگیری را پایان می‌دهد. که در این صورت ممکن است مرز تصمیم به دست آمده، مرز مناسبی نباشد. زمان اجرای ماشین‌های بردار پشتیبان به تعداد دسته‌های موجود وابسته است و به مدت زمان کمتری نیاز دارد، در صورتی که زمان اجرای شبکه عصبی مصنوعی علاوه بر تعداد ورودی‌های آموزشی به تعداد نرون‌های لایه پنهان، تابع آموزشی، ضریب یادگیری و مومنتم که به صورت آزمون و خطا به دست می‌آیند، وابسته است.

مدل درخت تصمیم یادگیری نسبت به روش‌های دیگر آسان‌تر و سریع‌تر است. با توجه به موارد ذکر شده در بالا، می‌توان بیان کرد که: حجم داده‌های مورد استفاده و جامع بودن آن‌ها برای یادگیری درخت تصمیم تأثیر مستقیم داشته و در صورت کافی نبودن داده‌ها درخت تصمیم یادگیری دچار پدیده بیش پردازش می‌شود.

فلامکی و همکاران (۶)، در تحقیق خود نشان دادند که مدل‌های ارائه شده بر پایه شبکه عصبی به ویژه شبکه MLP با مقادیر رسوب مشاهده شده هم‌خوانی بیش‌تری دارد و می‌تواند مقدار رسوب را در نقاط پیک به خوبی برآورد کند. اما دستورانی و همکاران (۴) به این نتیجه رسیدند که شبکه عصبی، نقاط اوج را به درستی پیش‌بینی نمی‌کند و در سایر نقاط نیز، شبکه عصبی برآوردی کم‌تر و یا بیش‌تری از مقادیر مشاهده‌ای دارد، به عبارتی شبکه عصبی، رسوب معلق مربوط به دبی‌های پایه و نرمال را به خوبی شبیه‌سازی کرده است، ولی در شبیه‌سازی رسوب در مواقع سیلابی چندان موفق نبوده است. همچنین با توجه به شکل ۳ در رابطه با درخت تصمیم یادگیری می‌توان ذکر کرد که این روش برای دبی‌های با مقادیر حداکثر و حداقل توانایی پیش‌بینی درستی ندارد و بعضی از نقاط را بیش‌تر از مقادیر مشاهده‌ای برآورد کرده است، زیرا به نظر می‌رسد درخت تصمیم توانایی برون یابی ضعیفی دارد به همین علت نمی‌تواند مقادیر حد، حداکثرها و حداقل‌ها را به درستی پیش‌بینی کند. در رابطه با مدل ماشین بردار با توجه به شکل ۳ و شاخص‌های آماری $R=0/99$ و $MAE = 24/78$ و $RMSE = 0/699$ می‌توان بیان کرد که این مدل برای تمامی دبی‌ها با مقادیر زیاد و کم به خوبی عمل کرده و در شبیه‌سازی رسوب بسیار موفق بوده است. دهقانی و وفاخواه (۵) به این نتیجه رسیدند که شبکه عصبی با ورودی‌های دبی همان روز، دبی ۱ و ۲ روز قبل از دقت بالاتری برخوردارند اما در این پژوهش پارامترهای ورودی میانگین دبی پنج روز قبل و مجموع بارش پنج روز قبل نتایج را در روش‌های مورد نظر بهبود بخشید. سنتیل کومار و همکاران (۹)، در تحقیق خود به این نتیجه رسیدند که درخت تصمیم M_5 نسبت به شبکه عصبی و منطق فازی از دقت و صحت بالاتری برخوردار است که این نتیجه، عکس نتایج به دست آمده در این تحقیق است. شبکه عصبی نسبت به درخت تصمیم در این تحقیق از صحت و دقت بالاتری برخوردار است.

به طور کلی می‌توان گفت که:

منابع

1. Akbari, Z. and A. Talebi. 2010. Estimation of Suspended Sediment Using Regression Decision Trees Method (Case Study Ilam Dam Basin Science and Technology of Agriculture and Natural Resources Journal, 17: 109-121 (In Persian).
2. Bhattacharya, B., R.K. Price and D.P. Solomatine. 2007. Machine Learning Approach to Modeling Sediment Transport. Journal of Hydraulic Engineering. 133: 440-450.
3. Bauer, P., S. Noatak and R.Winkler. 2007. Fuzzy Mathematical Methods for Soil Survey and Land Evaluation. Journal of Soil science, 40: 477-492.
4. Dastorani, M., Kh. Azimi Fashi, A. Talebi and M. Ekhtesasi. 2012. Suspended Sediment Estimation Using Artificial Neural Network (Case Study: Jamyshan watershed in Kermanshah). Journal of Watershed Management, 3: 61-74 (In Persian).
5. Dehghani, N. and M. Vafakhah. 2013. Comparison of Daily Suspended Sediment Load Estimations by Sediment Rating Curve and Neural Network Models (Case Study: Ghazaghli Station in Golestan Province). Journal of Water and Soil Conservation, 20: 221-230 (In Persian).
6. 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 (In Persian).
7. Kakaei Lafdani, E., A. Pournemat, Roudsari, K. Qaderi and A. Moghaddam Nia. 2013. Predicting the Volume of Suspended Sediments using GMDH and SVM Models Based on Principal Component Analysis. 9th International River Engineering Conference Shahid Chamran University, Ahwaz, pp: 22-24 (In Persian).
8. Heng, S. and T. Suetsugi. 2013. Using Artificial Neural Network to Estimate Sediment Load in Ungauged Catchments of the Tonle Sap River Basin, Cambodia, Journal of Water Resource and Protection, 5: 111-123.
9. Senthil Kumar, A.R., C.S. Ojha, P. Manish Kumar Goyal, R.D. Singh and P.K. Swamee. 2012. Modeling of Suspended Sediment Concentration at Kasol in India Using ANN, Fuzzy Logic and Decision Tree Algorithms. American Society of Civil Engineers, 17: 394-404.
10. Shabani, M. and N. Shabani. 2012. Estimation of Daily Suspended Sediment Yield Using Artificial Neural Network and Sediment Rating Curve in Kharestan Watershed, Iran, Australian Journal of Basic and Applied Sciences, 6: 157-164 (In Persian).
11. Toloei, S., D. Hossenzadeh, M. Ghorbani, A. Fakhrefard and F. salmasi. 2011. Estimate Temporal and Spatial Suspended load river AJICHAJ with Use from Geostatistics and Artificial neural Network. Issue Science Water and Soil, 21: 12-25 (In Persian).
12. Tabatabaei, M., K. Solaimani, M. Habibnejad Roshan and A. Kavian. 2014. 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). Journal of Watershed Management, 5: 98-116 (In Persian).
13. Yosefi, M. and R. Poorshariaty. 2014. Suspended Sediment Estimation Using Neural Network and Algorithms Assessment (Case Study: Lorestan Province), Watershed Management Journal, 5: 85-67. (In Persian).
14. Yosefi, M., A. Talebi and R. Poorshariaty. 2014. Application of Artificial Intelligence in Water and Soil Sciences. Yazd University publication, Yazd, Iran, 516 pp (In Persian).
15. Zhu, Y.M., X.X. Lu and Y. Zhou. 2007. Suspended Sediment Flux Modeling with Artificial Neural Network: An Example of the Longchunajianj River in the Upper Yangtze Catchment. Geomorphology, 84: 111-125.

The Effectiveness of Intelligent Models in Estimating the River Suspended Sediments (Case Study: Babaaman Basin, Northern Khorasan)

Parisa Eshghi¹, Jalil Farzadmehr², Mohammad Taghi Dastorani³ and Zeynab Arabasadi⁴

1- M.Sc. Student, Torbat-e Heydarie University

2- Assistant Professor, Torbat-e Heydarie University, (Corresponding author: Farzadm102000@gmail.com)

3- Associate Professor, Ferdowsi University of Mashhad

4- Instructor, University of Bojnord, Bojnord

Received: March 9, 2015

Accepted: August 10, 2015

Abstract

Accurate estimation of the sediment volume carried by the rivers is important in water related projects and recognition and suggestion proper methods for estimating suspended sediment goals which should be conducted by related researches. Among the methods that have been recently used to model suspended sediment, machine learning based methods such as decision trees, support vector machine, and artificial neural networks are importance. In the present study, the applicability of such techniques in predicting suspended sediment load of Babaaman watershed in Bojnord, Iran has been evaluated. Input data for predicting Babaaman watershed' suspended sediments in this project are: Debi, suspended load, raining and evaporation, which are related to the statistical period 1349 to 1380. In order to assess the accuracy and precision of the model results, statistical measures including R, RMSE, and MAE have been utilized. Consequently, the results of statistical value of R and RMSE for sediment rating curve method 0.80 and 55863.77, neural network 0.98 and 1.28, decision tree model 0.96 and 48881.56 and support vector machine 0.99 and 0.6998. The obtained values reveal that the support vector machine was more consistent with the measured values compared to the above-mentioned methods.

Keywords: Artificial Neural Network, Decision Tree, Sediment Rating Curve, Suspended Load, Support Vector Machine