



مرکز تحقیقات آموزش کشاورزی و منابع طبیعی فارس

پژوهش‌های آبخیزداری

شاپا: ۲۰۳۸-۲۹۸۱



سازمان تحقیقات آموزش و ترویج کشاورزی

پیش‌بینی رسوبات معلق با استفاده از مدل ترکیبی منحنی سنجه رسوب و شبکه عصبی مصنوعی در ایستگاه نارون افجه

گللاه غفاری ^{ID}

استادیار پژوهشی بخش تحقیقات حفاظت خاک و آبخیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان کرمانشاه، سازمان تحقیقات آموزش و ترویج کشاورزی، کرمانشاه، ایران

چکیده مبسوط

مقدمه و هدف

غلظت رسوبات معلق، یکی از مهم‌ترین سنجه‌های کیفی آب در منابع آب سطحی و یک پدیده آب‌شناختی مهم است. روش‌های سنتی پیش‌بینی مانند منحنی‌های سنجه رسوب به دلیل در نظر نگرفتن تمام سنجه‌های مؤثر، دقت کافی ندارند. در این راستا، مدل‌های ترکیبی شامل منحنی‌های سنجه رسوب (SRC) و شبکه‌های عصبی مصنوعی (ANNs) به‌عنوان روشی نوین برای پیش‌بینی دقیق‌تر غلظت رسوبات معلق پیشنهاد شده‌اند. این مدل‌ها با توانایی یادگیری الگوهای پیچیده و غیرخطی، به‌مراتب عملکرد بهتری در مقایسه با روش‌های سنتی دارند. این پژوهش با هدف توسعه و کاربرد مدل ترکیبی SRC-ANN برای پیش‌بینی غلظت رسوبات معلق انجام شد. همچنین، پیش‌بینی شد این مدل با ترکیب نقاط قوت هر دو روش، دقت پیش‌بینی را به‌طور قابل‌توجهی افزایش دهد و در مدیریت بهینه منابع آب و عملکرد صحیح سازه‌های آبی سودمند باشد.

مواد و روش‌ها

در این پژوهش، مدل ترکیبی جدیدی متشکل از منحنی سنجه رسوب و شبکه عصبی مصنوعی برای پیش‌بینی دقیق‌تر غلظت رسوبات معلق در ایستگاه آب‌سنجی نارون (افجه) استفاده شد. برای این منظور، از داده‌های آب‌دهی جریان و رسوب معلق ۲۲۲ نمونه در دوره ۵۰ ساله (۱۳۵۰ تا ۱۴۰۰) استفاده شد. همچنین، ۱۴ روش گوناگون شامل ۶ مدل منحنی سنجه رسوب، ۶ مدل شبکه عصبی مصنوعی و ۲ مدل ترکیبی برای شبیه‌سازی رسوبات معلق به‌کار گرفته شد و عملکرد هر روش با استفاده از معیارهای آماری مانند ضریب تعیین (R^2)، ضریب کارایی (ME) و میانگین درصد خطای نسبی (RME) ارزیابی شد.

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: g.ghaffari@areeo.ac.ir

استناد: غفاری، گ. ۱۴۰۴. پیش‌بینی رسوبات معلق با استفاده از مدل ترکیبی منحنی‌سنجه رسوب و شبکه عصبی مصنوعی در ایستگاه نارون افجه. پژوهش‌های آبخیزداری، ۳۸(۱): ۱۴۶-۱۲۸.
شناسه دیجیتال: 10.22092/wmrj.2024.366243.1589

تاریخ دریافت: ۱۴۰۳/۰۴/۱۸، تاریخ بازنگری: ۱۴۰۳/۰۵/۱۱، تاریخ پذیرش: ۱۴۰۳/۰۶/۲۹، تاریخ انتشار: ۱۴۰۴/۰۱/۰۱
پژوهش‌های آبخیزداری، سال ۱۴۰۴، دوره ۳۸، شماره ۱، شماره پیاپی ۱۴۶، بهار ۱۴۰۴، صفحه‌های ۱۲۸ تا ۱۴۶.

© نویسندگان

ناشر: مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان فارس



نتایج و بحث

نتایج نشان داد که در میان روش‌های منحنی سنجه رسوب، دقیق‌ترین شبیه‌سازی از وضعیت آب‌دهی رسوب مشاهده‌شده در مقایسه با دیگر روش‌ها مربوط به روش میانگین دسته‌ها با ضریب تعیین (R^2) ۰/۸۴، ضریب کارایی (ME) ۰/۸۲ و میانگین درصد خطای نسبی (RME) ۲۱۱/۸۷ بود. همچنین، در میان روش‌های شبکه عصبی مصنوعی، دقیق‌ترین شبیه‌سازی مربوط به روش CANFIS با ضریب کارایی (ME) ۰/۸۱۲۳ و میانگین درصد خطای نسبی (RME) ۲۴۸/۷۲ بود. سرانجام، به‌منظور بهبود نتایج پیش‌بینی‌ها از مدل‌های ترکیبی ۱ و ۲ استفاده شد. نتایج نشان داد که بهترین برآورد از رسوب معلق مربوط به روش ترکیبی ۱ با ضریب

کارایی (ME) ۰/۸۷۶۱ و میانگین درصد خطای نسبی (RME) ۵۹/۶۳ بود.

در روش نامبرده هم برآورد اندازه‌های آب‌دهی‌های اوج و هم برآورد اندازه‌های آب‌دهی‌های پایه بسیار دقیق بود و به‌عنوان دقیق‌ترین روش برای پیش‌بینی رسوبات معلق معرفی شد. این نتایج بیانگر آن بود که با استفاده از مدل ترکیبی ۱ می‌توان دقت پیش‌بینی‌ها را به‌طور قابل توجهی بهبود داد و میان داده‌های پیش‌بینی شده و داده‌های مشاهده‌شده تناسب بهتری ایجاد کرد.

نتیجه‌گیری و پیشنهادها

از میان روش‌های منحنی سنجه رسوب، روش منحنی سنجه رسوب میانگین دسته‌ها به‌دلیل در نظر گرفتن توزیع داده‌ها و انعطاف‌پذیری، به‌عنوان بهترین روش برای پیش‌بینی رسوب معلق معرفی شد. عملکرد شبکه‌های عصبی مصنوعی نیز در شبیه‌سازی رسوبات معلق مربوط به آب‌دهی‌های پایه و بهنجار خوب بود، اما در پیش‌بینی رسوبات معلق در شرایط سیلابی ضعیف‌تر عمل کرد. دقیق‌ترین روش برای پیش‌بینی رسوب معلق، مدل ترکیبی ۱ معرفی شد که در آن از ترکیب روش‌های منحنی سنجه و شبکه عصبی مصنوعی استفاده شد. انتخاب روش نامناسب برای پیش‌بینی رسوبات می‌تواند منجر به نتایج نادرست شود. همچنین، بررسی تأثیر متغیرهای دیگر افزون بر آب‌دهی جریان بر رسوب نیز ضروری است. نتایج این پژوهش نشان داد می‌توان با استفاده از مدل‌های ترکیبی دقت پیش‌بینی رسوبات معلق را به‌طور قابل توجهی افزایش داد و از آن به‌عنوان ابزاری مؤثر برای مدیریت و پیش‌بینی رسوبات معلق و بهبود مدیریت منابع آب استفاده کرد. پیشنهاد می‌شود برای توسعه و بهینه‌سازی روش‌های ترکیبی، در ایستگاه‌های آب‌سنجی به‌ویژه در آب‌دهی‌های زیاد و شرایط سیلابی، از امکانات پیشرفته نمونه‌گیری و تعداد نمونه‌های بیشتر استفاده شود. همچنین، پیشنهاد می‌شود مهندسان و مدیران منابع آب از نتایج این پژوهش برای توسعه راهکارهای بهینه برای مدیریت رسوبات معلق، بهره‌برند.

واژگان کلیدی: ایستگاه آب‌سنجی، آب‌دهی، شبیه‌سازی، غلظت رسوب، مدل‌سازی

مقدمه

غلظت رسوبات معلق، یکی از مهم‌ترین سنجه‌های کیفی آب در منابع آب سطحی و یک پدیده آب‌شناختی مهم است (ژنگ ۲۰۲۳). همچنین، در تعامل با ویژگی‌های مشخصات جریان، فرسایش، انتقال رسوب و طراحی زیرساخت‌ها، بر پایداری مهندسی رود نیز تأثیرگذار است (هورنیک و همکاران ۱۹۸۹). اندازه‌های زیاد غلظت رسوبات معلق می‌تواند بر زیرساخت‌ها مانند سدها، کارایی و طول عمر آن‌ها تأثیرگذار باشد. کیفیت آب رودها برای حفظ بوم‌نظام‌ها و فعالیت‌های انسانی

بسیار مهم است (جورج ۱۹۸۹). آلاینده‌های موجود در آب می‌توانند زیرساخت‌ها را نابود کنند و به حیات آبریان آسیب برسانند. درک الگوها و تغییرات جریان برای مهندسی مؤثر رودها ضروری است. نوسانات جریان می‌تواند بر انتقال رسوب، فرسایش و فرآیندهای رسوب تأثیرگذار باشد. فرسایش در امتداد ساحل رودها و پویایی انتقال رسوب بر پایداری کانال‌های رود تأثیرگذار است (کریستین و همکاران ۱۹۹۸). مدیریت صحیح حمل و نقل رسوب برای حفظ قابلیت کشتیرانی و مهار سیل حیاتی است و در طراحی سازه‌هایی مانند پل‌ها،

برای مدل‌های منحنی سنجه $0.87/1$ و روش وایزی آماری 90% بود. لی و همکاران (۲۰۱۹) نشان دادند که دقت مدل‌های ترکیبی برای پیش‌بینی رسوبات معلق در مقایسه با مدل‌های تک منظوره، بیشتر بود و پس از استفاده از مدل‌های ترکیبی ضریب کارایی مدل ناش-ساتکلیف (NSE) از 0.76 به 0.89 افزایش یافت. در هند سنتی کومار و همکاران (۲۰۲۱) با تلفیق مدل‌های منحنی سنجه رسوب و ماشین بردار پشتیبان، مدلی با دقت بیشتر برای پیش‌بینی رسوبات رود کآوری پیشنهاد دادند. در کره جنوبی، لی و همکاران (۲۰۲۱) از ترکیب مدل‌های منحنی سنجه رسوب و شبکه عصبی برای پیش‌بینی رسوبات معلق رود هان استفاده کردند. نتایج آنها نشان داد دقت مدل پیشنهادی در مقایسه با مدل‌های جداگانه بیشتر بود و میانگین خطای مطلق (MAE) از 234 به 167 کاهش یافت. ونگ و همکاران (۲۰۲۲) با استفاده از دستورالعمل یادگیری عمیق و داده‌های سنجش‌ازدور، یک مدل برآوردگر رسوبات معلق بر پایه هوش مصنوعی توسعه دادند که ضریب کارایی ناش-ساتکلیف (NSE) آن 0.93 و میانگین خطای مطلق (MAE) 43 به دست آمد. ژنگ (۲۰۲۳) رسوبات معلق را با استفاده از هوش مصنوعی در آبخیز وی جیا بون پیش‌بینی کردند و با استفاده از سری زمانی ماهانه مشاهده شده آب‌دهی رود و رسوبات معلق نمودند و کارایی مدل با استفاده از ضریب کارایی مدل ناش-ساتکلیف (NSE)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) ارزیابی شد. نتایج نشان داد که شبکه عصبی مصنوعی می‌تواند به‌عنوان ابزاری مناسب برای پیش‌بینی رسوبات معلق استفاده شود. مرادی نژاد و همکاران (۲۰۲۳) در پژوهشی اقدام به بررسی کارایی روش‌های برآورد رسوب معلق در ایستگاه پل دوآب رود قره چای در دو سال آبی $1395-1396$ نمودند و برای این هدف از روش‌های شبکه عصبی مصنوعی، نروفازی، منحنی سنجه رسوب و همچنین مدل وایزی چندمتغیره استفاده نمودند. نتایج نشان داد که روش نروفازی بر اساس ورودی‌های آب‌دهی و رسوب و مدل‌های شبکه عصبی مصنوعی بر اساس ورودی‌های آب‌دهی، نسبت به وایزی چند

آبشارها و سنگ‌ها باید نیروهای آبی و بارهای رسوب را در نظر گرفت (آی‌تک و اوزگور ۲۰۰۸). از این‌رو، پیش‌بینی دقیق رسوبات معلق برای مدیریت بهینه منابع آب و عملکرد صحیح سازه‌های آبی اهمیت زیادی دارد. رسوبات معلق شامل روش‌های آماری، معادلات وایزی و منحنی‌های سنجه رسوب است. اما، این روش‌ها به دلیل در نظر نگرفتن تمام سنجه‌های مؤثر، دقت کافی ندارند (چن و چاو ۲۰۰۶)، از این‌رو، در دو دهه گذشته، به استفاده از مدل‌های هوش مصنوعی همچون شبکه‌های عصبی مصنوعی توجه فراوانی شده است. شبکه‌های عصبی با توانایی یادگیری الگوهای غیرخطی پیچیده، عملکرد بهتری در مقایسه با روش‌های سنتی دارند (سیگیزلو ۲۰۰۵). از سوی دیگر، ترکیب روش‌های سنتی با دستورالعمل‌های هوش مصنوعی می‌تواند منجر به بهبود قابل توجهی در دقت پیش‌بینی‌ها شود. در سال‌های گذشته، استفاده از مدل‌های ترکیبی و هوش مصنوعی برای پیش‌بینی رسوبات معلق رواج یافته است. در پژوهش‌های پرشماری گزارش شده است که دقت این مدل‌ها در مقایسه با روش‌های سنتی بیشتر است. در این راستا، ایرانی و همکاران (۲۰۱۹)، به منظور برآورد بار معلق رسوب در آبخیز قره‌سو از روش منحنی سنجه رسوب استفاده کردند. این پژوهشگران از داده‌های رسوب دوره ۲۶ ساله $1370-1396$ در ایستگاه آب‌سنجی دوآب مرک استفاده کردند و با تجزیه و تحلیل روابط وایزی و رسم منحنی سنجه‌های یک خطی، دو خطی، و حد میانگین دسته‌ها دریافتند که بیشترین دقت در برآورد آب‌دهی رسوب مربوط به روش حد وسط دسته‌ها با R^2 برابر 0.98 بود. در استان مازندران، مردوخ‌پور و همکاران (۲۰۱۹) اندازه برآورد رسوب را با بهره‌گیری از روش منحنی سنجه و مقایسه نتایج با روش‌های وایزی و شبکه عصبی مصنوعی در رود بابل را ارزیابی کردند. نتایج آنها نشان داد که غلظت بار معلق رسوب به دست آمده از مدل‌های شبکه عصبی مصنوعی به داده‌های واقعی غلظت رسوب نزدیک‌تر بود و ضریب همبستگی از شبکه عصبی مصنوعی $0.92/8$ به دست آمد. این در حالی بود که ضریب همبستگی

رسوب معلق در مقایسه با وایازی چند خطی سنتی نشان دادند (بسطامی و فاتیح ۲۰۲۴).

بر پایه پژوهش‌های انجام‌شده مدل‌های ترکیبی و هوش مصنوعی می‌توانند ابزارهای قدرتمندی برای پیش‌بینی رسوبات معلق در رودها باشند. دقت این مدل‌ها در مقایسه با روش‌های سنتی بیشتر است و در حل چالش‌های مرتبط با پیش‌بینی رسوبات معلق سودمند است و می‌توان در مدیریت بهتر منابع آب و حفظ محیط زیست از آنها بهره برد.

در مدل‌های ترکیبی، روش‌های گوناگون پیش‌بینی را با یکدیگر ترکیب می‌کنند تا از مزایای هر روش بهره‌مند شوند. در مدل‌های هوش مصنوعی نیز از دستورالعمل‌های یادگیری ماشین برای پیش‌بینی رسوبات معلق استفاده می‌شود. استفاده از مدل‌های ترکیبی برای پیش‌بینی رسوبات معلق مزایای پرشماری مانند دقت بیشتر، نیاز به داده‌های میدانی کمتر، پیچیدگی کمتر در محاسبات و امکان پیش‌بینی در مقیاس‌های زمانی و مکانی متفاوت دارد.

در این راستا، هدف این پژوهش، پیشنهاد یک مدل ترکیبی نوین برای پیش‌بینی دقیق غلظت رسوبات معلق با استفاده از منحنی سنجه رسوب و شبکه عصبی مصنوعی بود. همچنین، پیش‌بینی شد عملکرد این مدل ترکیبی، در مقایسه با مدل‌های سنتی و ANN جداگانه بهتر باشد.

مواد و روش‌ها

معرفی منطقه مطالعه‌شده

در این پژوهش، از داده‌ها و اطلاعات مربوط به ایستگاه آب‌سنجی نارون (افجه) که در زیر آبخیز افجه، یکی از زیرآبخیزهای اصلی آبخیز سد لتیان در استان تهران است، استفاده شد. آبخیز سد لتیان با مساحت ۶۹۶۸۱ هکتار در منطقه‌ای کوهستانی با شیب زیاد و بلندی ۲۵۵۵ متر از سطح دریا است. اقلیم غالب منطقه در بلندی‌های بیش از ۲۰۰۰ متر مرطوب فراسرد و در مناطق با بلندی کمتر از ۲۰۰۰ متر نیمه‌مرطوب فراسرد است.

متغیره و منحنی سنجه رسوب، دارای دقت مطلوب‌تری بود. برای اندازه‌های بالاتر از میانگین درازمدت سری آماری، اندازه‌های شبیه‌سازی‌شده با مدل شبکه عصبی مصنوعی و برای اندازه‌های پایین‌تر از میانگین و بار رسوب سالانه هم برآورد نروفازی نسبت به اندازه‌های مشاهداتی نزدیک‌تر بود. درحالی‌که برای اندازه‌های حدی بیشینه، تفاوت معنی‌داری میان مدل‌های شبکه عصبی مصنوعی، نروفازی و وایازی خطی مشاهده نشد (مرادی نژاد و همکاران ۲۰۲۳).

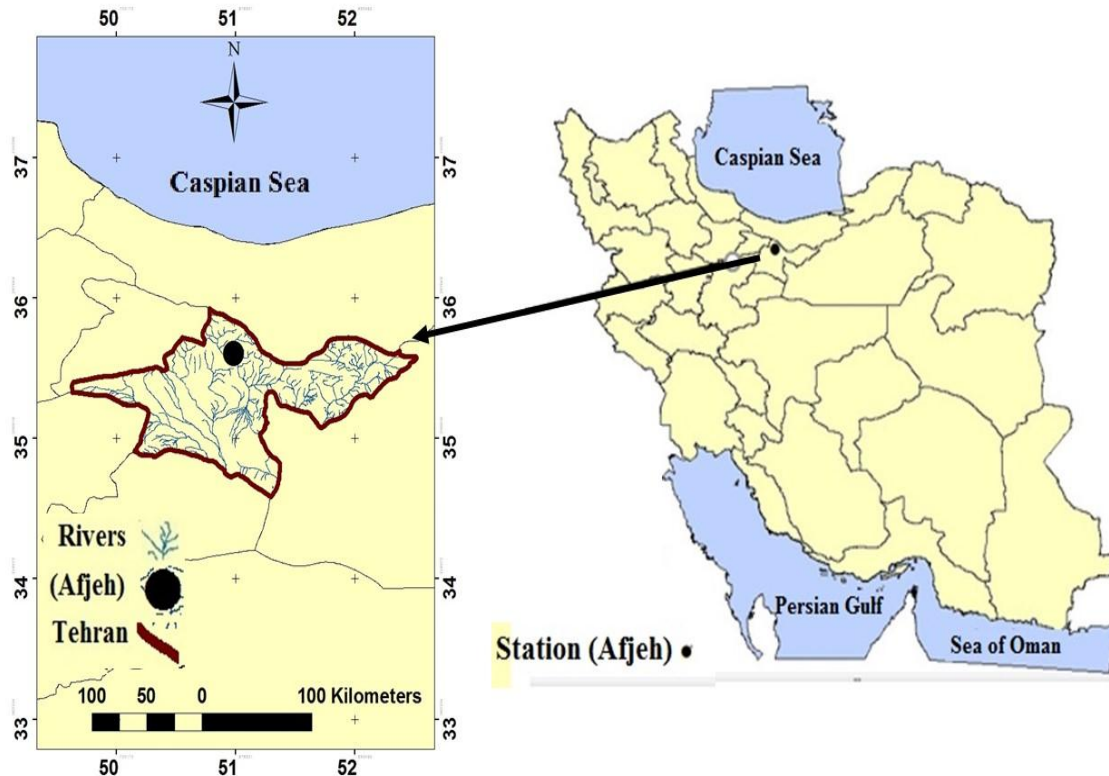
بالول و همکاران (۲۰۲۳) در پژوهشی اقدام به برآورد رسوب معلق در آبخیز ایسر در شمال‌غربی الجزایر با استفاده از روش‌های منحنی سنجه نمودند. آنها در مجموع ۲۰۲۶ جفت داده‌های آب‌دهی آب و غلظت رسوب معلق را از سال ۱۹۸۸ تا ۲۰۰۴ برای تجزیه و تحلیل استفاده نمودند. در این مطالعه داده‌ها به چهار مقیاس زمانی کل دوره، سالانه، فصلی و ماهانه تقسیم شدند تا تأثیر زمان بر برآورد رسوب را ارزیابی کنند. نتایج به‌دست آمده نشان داد مدل توانی خطی در داده‌های ماهانه بهترین برآورد عملکرد کل رسوب معلق را با نرخ خطای ۱۶٪ - ارائه داد. مدل‌های توسعه یافته در مقیاس فصلی کارایی بالایی داشتند و ضرایب نزدیک به ۰/۹۵ را نشان داد که نشان دهنده عملکرد پیش‌بینی دقیق مدل است (بالول و همکاران ۲۰۲۳).

بسطامی و فاتیح (۲۰۲۴) در پژوهشی اقدام به برآورد بار رسوب معلق با استفاده از روش‌های سنتی وایازی چند خطی و یادگیری ماشین مانند ماشین‌های بردار پشتیبانی و درخت تصمیم M5 نمودند و برای پیش‌بینی تخلیه روزانه رسوب معلق از داده‌های ورودی مانند آب‌دهی روزانه رود، دمای آب و غلظت رسوب معلق استفاده شد. برای مقایسه عملکرد روش‌ها از معیارهای ارزشیابی نظیر ضریب تعیین، خطای میانگین مربعات ریشه و میانگین خطای مطلق استفاده شد. نتایج آنها نشان داد که به‌طور کلی، رویکردهای یادگیری ماشین، به‌ویژه ماشین‌های بردار پشتیبانی و درخت تصمیم M5 قابلیت پیش‌بینی بهتری برای تخلیه

جدول ۱- چکیده‌ای از خصوصیات گیتاشناسی آبخیز افجه.

Table 1- Summary of physiographic characteristics of the Afjeh Watershed.

Area (km ²)	Perimeter (km)	Compactness coefficient (Cc)	Time of concentration (Tc)	Slope S (%)	Drainage Density (D)	Basin Length (km)
40.6	33	1.45	15	9.2	0.74	13



شکل ۱- موقعیت منطقه مطالعه شده در کشور.

Figure 1- Location of the study area in the country.

۱- منحنی‌های سنجه رسوب

در این روش، رابطه‌ای تجربی میان آبدهی جریان و آبدهی رسوب برقرار می‌شود. برای رسم منحنی سنجه رسوب از روش اداره اصلاح اراضی آمریکا استفاده می‌شود. در این روش با انتقال داده‌های هم‌زمان آبدهی جریان و غلظت رسوب معلق متناظر با آن روی صفحه مختصات لگاریتمی و رسم بهترین خط از میان ابر داده‌ها، بر مبنای روش حداقل مربعات، معادله‌نمایی منحنی سنجه رسوب به دست می‌آید. این روش با استفاده از داده‌های مشاهده‌ای، منحنی‌هایی را برای پیش‌بینی اندازه رسوبات معلق در آبدهی‌های گوناگون پیشنهاد می‌دهد. ابتدا داده‌های موجود دسته‌بندی شده و منحنی‌های سنجه بر اساس آن‌ها رسم می‌شود (لدنزا

در این پژوهش، برای تحلیل و پیش‌بینی رسوبات معلق، از داده‌های ایستگاه آب‌سنجی نارون (افجه) استفاده شد. ابتدا، آمار موجود از نظر پیوستگی، داده‌های پرت، کیفیت و همگنی در طول دوره آماری بررسی شد تا از داده‌های قابل اعتماد و منسجم اطمینان به دست آید. داده‌های متناظر آبدهی جریان (برحسب مترمکعب در ثانیه) و آبدهی رسوب (برحسب تن در روز) مربوط به ۲۲۲ نمونه که به‌طور هم‌زمان از سال ۱۳۵۰ تا ۱۴۰۰ اندازه‌گیری شده بودند، استفاده شد. سپس، سه روش گوناگون برای شبیه‌سازی رسوبات معلق به کار گرفته شد که شامل منحنی‌های سنجه رسوب، شبکه‌های عصبی مصنوعی و روش‌های ترکیبی بودند.

ث- ضریب اصلاحی سنجهای

برای اصلاح اثر تبدیل لگاریتمی (توماس ۱۹۸۵) به نقل از میلر (۱۹۵۳) ضریب اصلاحی (۲) را پیشنهاد کرد.

$$CF_1 = EXP[2.65S^2] \quad (2)$$

S: اشتباه استاندارد برآورد منحنی سنجۀ رسوب در لگاریتم پایه ۱۰ است و با استفاده از رابطه ۳ محاسبه می‌شود.

$$S^2 = \frac{\sum (\log c_i - \log \hat{c}_i)^2}{(n - 2)} \quad (3)$$

N: تعداد نمونه‌های غلظت، $\log \hat{c}_i$: لگاریتم اندازه برآوردی غلظت و $\log c_i$: لگاریتم اندازه مشاهده‌ای غلظت است (بالول و همکاران ۲۰۲۳).

ج- ضریب اصلاحی غیر سنجهای

کوخ و اسمیلی (۱۹۸۶) با رد توزیع بهنجار خطاهای باقی‌مانده، ضریب اصلاحی غیر سنجهای CF_2 را برای حذف اریبی داده‌ها توصیه کرد که با استفاده از رابطه ۴ و ۵ محاسبه می‌شود (هین و لی ۲۰۲۳).

$$CF_2 = \frac{1}{n} \sum 10^{\varepsilon_i} \quad (4)$$

$$\varepsilon_i = \log c_i - \log \hat{c}_i \quad (5)$$

ε_i : خطای برآورد و بقیه علائم مشابه قبل است.

۱- استفاده از روش شبکه‌ی عصبی مصنوعی

این روش به‌منظور مدل‌سازی پیچیدگی‌های موجود در روابط میان آب‌دهی جریان و آب‌دهی رسوب استفاده شد. شبکه‌های عصبی با قابلیت یادگیری و تطبیق با داده‌های پیچیده، توانایی پیش‌بینی دقیق‌تری در مقایسه با روش‌های سنتی دارند. در این پژوهش، شبکه عصبی مصنوعی با استفاده از داده‌های آموزشی تنظیم و بهینه‌سازی شد. سپس، برای پیش‌بینی آب‌دهی رسوب استفاده شد. در روش شبکه عصبی ابتدا برای آموزش شبکه تعدادی از داده‌ها که معرف شرایط مسئله بودند برای آموزش انتخاب شد و دیگر داده‌ها برای آزمون عملکرد شبکه آموزش‌دیده به‌کار برده شدند. نکته مهم در انتخاب داده‌های آموزش آن بود که گستره وسیعی از انواع داده‌ها را شامل شود. در این پژوهش ۷۵٪ داده‌ها به‌عنوان داده‌های آموزشی استفاده شد و ۲۵٪ داده‌ها برای آزمون کارایی مدل شبکه عصبی

و لاپولیتانو (۲۰۰۶). سپس، دقت این منحنی‌ها با استفاده از معیارهای آماری گوناگون ارزیابی می‌شود. برای این منظور در این پژوهش از ۶ نوع منحنی سنجۀ رسوب به‌شرح زیر استفاده شد.

الف- منحنی سنجۀ رسوب یک‌خطی

در این روش معمولاً داده‌های غلظت یا آب‌دهی رسوب و آب‌دهی جریان متناظر آن‌ها به یک محور مختصات تمام لگاریتمی منتقل می‌شود و بهترین خط برازش با استفاده از روش حداقل مربعات از میان نقاط، عبور داده می‌شود (بالول و همکاران ۲۰۲۳).

ب- عبور دادن بیش از یک خط از میان نقاط

گاهی پراکنش نقاط روی نمودار به شکلی است که امکان برازش یک خط مستقیم به آن وجود ندارد. در این حالت اگر وضعیت پراکنش نقاط اجازه دهد، می‌توان مجموعه نقاط را به چند دسته تقسیم کرد و به هر یک خط مستقیم جداگانه‌ای برازش داد.

پ- روش میانگین دسته‌ها

در این روش که آنرا جانسون (۱۹۹۶) پیشنهاد کرد، آب‌دهی‌های جریان با یک نمو معین به تعدادی دسته تقسیم می‌شود و برای آب‌دهی میانگین هر دسته، آب‌دهی رسوب میانگین اندازه‌گیری‌شده همان دسته تعیین می‌شود و سرانجام منحنی سنجۀ رسوب با استفاده از آن‌ها با روش حداقل مربعات به‌دست می‌آید.

ت- ضریب اصلاحی فائو

در این روش ابتدا بهترین خط با معادله $Q_s = aQ_w^b$ در روش حداقل مربعات به اندازه‌های لگاریتمی (نه اندازه‌های واقعی) Q_s غلظت رسوب و Q_w آب‌دهی برازش داده می‌شود. ولی از معادله نامبرده که از نقاط میانگین $\log Q_s$ و میانگین $\log Q_w$ عبور می‌کند، استفاده نمی‌شود و به‌جای آن معادله خطی موازی که از میانگین Q_s و میانگین Q_w متناظر با آن می‌گذرد، استفاده می‌شود. از این‌رو، معادله جدید به‌شکل رابطه ۱ است.

$$Q_s = aQ_w^b \quad (1)$$

اندازه \hat{a} از تقسیم میانگین Q_s ها بر میانگین Q_w های متناظر اندازه‌گیری‌شده به‌دست می‌آید (لدنزا و لاپولیتانو ۲۰۰۶).

این خطا به روزرسانی می‌شود (ریشاب و همکاران ۲۰۲۴).

۳- شبکه عصبی پیش‌خور تعمیم‌یافته (GFF)^۲

شبکه عصبی پیش‌خور تعمیم‌یافته (GFF) یک معماری شبکه عصبی است که در آن اتصالات لایه‌ها محدود به لایه بعدی نیستند، بلکه می‌توانند از هر لایه به گره‌های چندین لایه بالاتر متصل شوند و لازم نیست فقط به لایه بعدی وصل شوند. در مقایسه با شبکه‌های پیش‌خور معمولی که در آن‌ها اتصالات فقط به لایه بعدی است، با این ساختار می‌توان انعطاف‌پذیری بیشتری برای یادگیری الگوهای پیچیده فراهم کرد (جانوس و همکاران ۲۰۱۳).

۴- شبکه عصبی تابع پایه شعاعی (RBF)^۳

معماری این شبکه شامل یک لایه ورودی، یک لایه پنهان و یک لایه خروجی است. در لایه پنهان، هر نرون از یک تابع پایه شعاعی مانند تابع گوسی به‌عنوان تابع فعال‌سازی استفاده می‌کند. با تابع RBF فاصله میان ورودی و یک نقطه مرجع (مرکز)، محاسبه می‌شود و خروجی آن بر اساس این فاصله تعیین می‌شود. مراکز نرون‌های لایه پنهان معمولاً با استفاده از دستورالعمل‌هایی مانند k-means روی داده‌های آموزشی تعیین می‌شوند (سريلانتها و سودها ۲۰۲۴).

۵- شبکه‌های عصبی خودسازمان‌دهنده

(SOFMs)^۴

این روش یک روش یادگیری ماشین بدون نظارت است که برای تولید نمایش کم‌بعدی (معمولاً دو بعدی) از داده‌های بعد بیشتر، درحالی‌که ساختار پستی‌بلندی داده‌ها حفظ می‌شود، استفاده می‌شود. در SOFMs از یادگیری رقابتی به‌جای یادگیری اصلاح خطا مانند پس انتشار استفاده می‌شود (پورخسرویان و همکاران ۲۰۲۴).

۶- شبکه عصبی (CANFIS)^۵

می‌توان با این شبکه و ترکیب شبکه‌های عصبی (ANN) و سامانه‌های استنتاج فازی (FIS) عملکرد شبکه را بهبود بخشید و از وزن‌های وابسته به الگو میان

استفاده شد. سنجه‌های مؤثر در مدل‌سازی شبکه‌های عصبی مصنوعی شامل ساختار شبکه عصبی، ورودی‌های اعمال‌شده، شیوه آموزش و تعداد بردارهای خروجی هر شبکه، تعداد لایه‌های مخفی، تعداد نرون‌های لایه‌ها و تعداد نرون‌های لایه‌های میانی بودند (مصطفی و همکاران ۲۰۲۴). در این پژوهش داده‌های آب‌دهی (مترمکعب در ثانیه) و رسوب هم‌زمان لحظه‌ای (تن در روز) به‌ترتیب به‌عنوان عناصر ورودی و خروجی ساختار در نظر گرفته شد. برای این منظور ابتدا، داده‌ها تصادفی شدند. سپس، بهنجارسازی داده‌ها قبل از استفاده در شبکه (این کار به‌ویژه زمانی که دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند) با استفاده از رابطه ۶ انجام شد (رن و همکاران ۲۰۲۳).

$$X_n = \frac{(X) - X_{\min}}{(X_{\max} - X_{\min})} \quad (6)$$

X: داده مشاهده‌شده، X_{\max} و X_{\min} : به‌ترتیب کمترین و بیشترین اندازه داده‌های مشاهده‌شده و X_n : داده بهنجار شده است.

سپس، آموزش شبکه انجام شد. برای رسیدن به ساختار مناسب شبکه عصبی مصنوعی، مدل‌های گوناگون با تعداد لایه مخفی و تعداد گره‌های متفاوت طراحی و آزمون شد و نتایج به‌دست آمده مقایسه شدند. در این راستا، در این پژوهش از مدل‌ها به‌شرح زیر استفاده شد.

۲- شبکه عصبی پرسپترون چند لایه (MLPs)^۱

یک نوع شبکه عصبی پیش‌خور مدرن است که از نرون‌های کاملاً متصل با تابع فعال‌سازی غیرخطی تشکیل شده است و حداقل از سه لایه یا بیشتر (یک لایه ورودی، یک لایه خروجی و یک یا چند لایه پنهان) از نرون‌های فعال‌شونده غیرخطی تشکیل شده است (نیها و همکاران ۲۰۲۳). یادگیری در این شبکه‌ها با تنظیم وزن اتصالات میان نرون‌ها انجام می‌شود. پس از پردازش هر داده، اندازه خطا میان خروجی شبکه و نتیجه مطلوب محاسبه می‌شود و وزن اتصالات بر اساس

4- Self-organizing feature maps (SOFMs)

5- Co-Active Neuro-Fuzzy Inference System (CANFIS)

1- Multilayer perceptions (MLPs)

2- Generalized feed forward (GFF)

3- Radial basis function (RBF)

ضریب کارایی (ME) و میانگین درصد خطای نسبی (RME) ارزیابی شد و بهترین روش برای پیش‌بینی رسوبات معلق در ایستگاه نارون افجه تعیین شد.

۱- ضریب تبیین (R^2)

این ضریب نسبت پراکنش متغیر وابسته پیرامون میانگین که با متغیرهای پیش‌بینی‌کننده مستقل بیان می‌شود، است.

$$R^2 = \left[\frac{\sum_{i=1}^n (O_{obs} - \bar{O})(S_{sim} - \bar{S})}{\sqrt{\sum_{i=1}^n (O_{obs} - \bar{O})^2 \sum_{i=1}^n (S_{sim} - \bar{S})^2}} \right]^2 \quad (7)$$

O_{obs} : داده مشاهده‌ای، \bar{O} : میانگین داده‌های مشاهده-ای، S_{sim} : داده شبیه‌سازی‌شده، \bar{S} : میانگین داده‌های مشاهده‌ای و n : تعداد داده‌ها است (بری و ایکسی ۱۹۹۳؛ کراس و همکاران ۲۰۰۵؛ گورپال و همکاران ۲۰۰۸). هر چه اندازه آن به ۱ نزدیک‌تر باشد معادله وایازی به‌دست‌آمده بهتر می‌توان روابط میان دو سنجه مدنظر را بیان کرد (بری و ایکسی ۱۹۹۳؛ کراس و همکاران ۲۰۰۵).

۲- ضریب کارایی (ME)

این نمایه را ناش و ساتکلیف در سال ۱۹۷۰ ارائه دادند. اندازه‌های به‌دست آمده از آن بدون بعد است و میان عدد ۱ تا منفی بی‌نهایت متغیر است. هر چه اندازه شاخص به عدد ۱ نزدیک‌تر باشد، هماهنگی میان دو گروه بیش‌تر است. در این پژوهش ضریب کارایی با استفاده از رابطه ۸ محاسبه شد.

$$ME = 1 - \frac{\sum_{i=1}^n (S_{sim} - O_{obs})^2}{\sum_{i=1}^n (O_{obs} - \bar{O}_{obs})^2} \quad (8)$$

O_{obs} : داده مشاهده‌ای، \bar{O} : میانگین داده‌های مشاهده-ای، S_{sim} : داده شبیه‌سازی‌شده، \bar{S} : میانگین داده‌های مشاهده‌ای و n : تعداد داده‌ها است (ناش و ساتکلیف ۱۹۷۰). عدد صفر برای ضریب نامبرده بیانگر آن است که برآورد مدل بیش‌تر در محدوده میانگین مشاهده‌ها است. شکل این کسر بیانگر صحت و مخرج آن بیانگر دقت آن است (گورپال و همکاران ۲۰۰۸).

لایه اتصال فازی و لایه خروجی برای افزایش کارایی استفاده کرد. در این شبکه توابع عضویت نورون‌های فازی در طول مرحله آموزش با انتشار معکوس تنظیم می‌شوند و سیناپس‌های فازی در توصیف ورودی‌هایی که به‌راحتی قابل تشخیص نیستند، مؤثر هستند. از این شبکه‌ها برای مدل‌سازی سنجه‌های آب‌شناختی مانند نوسانات سطح آب زیرزمینی و افت آن، طبقه‌بندی کیفیت آب آشامیدنی، پیش‌بینی خشک‌سالی از نظر شدت و مدت، شبیه‌سازی ورودی آبگیر سد و ... استفاده می‌شود. عملکرد این شبکه به‌دلیل ترکیب قدرت شبکه‌های عصبی و منطق فازی، در مدل‌سازی سنجه‌های پیچیده آب‌شناختی مانند نوسانات سطح آب زیرزمینی و افت آن، خوب است (زارع و بیات ۲۰۱۳).

۷- شبکه عصبی (SVM)

یک دستورالعمل یادگیری ماشین نظارت‌شده برای طبقه‌بندی داده‌ها است که با یافتن یک خط یا فضای جداکننده بهینه، می‌توان داده‌ها را به دو طبقه جدا تقسیم کرد. از SVM به‌دلیل کارا بودن در مسائل خطی و غیرخطی در طیف گسترده‌ای از کاربردها شامل طبقه‌بندی داده‌های ماهواره‌ای، مدل‌سازی سنجه‌های منابع آب و فرسایش و رسوب استفاده می‌شود (کرمی و همکاران ۲۰۲۰).

۸- مدل ترکیبی منحنی سنجه و شبکه عصبی

مصنوعی

در این روش‌ها با ترکیب منحنی‌های سنجه رسوب و شبکه عصبی مصنوعی، می‌توان دقت پیش‌بینی‌ها را بهبود بخشید. در این پژوهش در روش ترکیبی ۱، خروجی منحنی‌های سنجه به‌عنوان ورودی شبکه عصبی استفاده شد تا دقت پیش‌بینی‌ها افزایش یابد. در روش ترکیبی ۲، خروجی‌های هر دو مدل به‌شکل هم‌زمان استفاده ترکیب شدند تا نتایج بهتری به‌دست آید (خزایی پول و طالبی ۲۰۱۴).

ارزیابی دقت و کارایی هر یک از روش‌ها

سرانجام، دقت و کارایی هر یک از این روش‌ها با استفاده از معیارهای گوناگون آماری مانند ضریب تبیین (R^2),

نتایج و بحث

در این پژوهش، پیش‌بینی رسوبات معلق در ایستگاه نارون (افجه) با استفاده از مدل ترکیبی منحنی سنجۀ رسوب و شبکه عصبی مصنوعی بررسی شد. پس از برآورد معادلات منحنی سنجۀ رسوب، بر اساس مدل‌های گوناگون و با استفاده از ۲۲۲ داده متناظر آبردهی جریان و آبردهی رسوب، نتایج به‌دست آمده از رسم منحنی‌های سنجۀ رسوب با روش‌های گوناگون در جدول ۲ آورده شده است. نتایج نشان داد بهترین و ضعیف‌ترین برآورد از رسوب معلق به ترتیب مربوط به روش میانگین دسته‌ها با R^2 برابر ۰/۸۴ و روش دوخطی با R^2 برابر ۰/۵۳ بود. این یافته بیانگر دقت بیشتر روش میانگین دسته‌ها در مقایسه با دیگر روش‌ها است.

۳- میانگین درصد خطای نسبی (RME)

میانگین درصد خطای نسبی (RME) یک معیار برای اندازه‌گیری دقت یا نبودن دقت یک مدل پیش‌بینی‌کننده است. هر چه اندازه این معیار آماری کمتر باشد، بیانگر آن است که دقت معادله‌های مربوطه بیشتر است. معمولاً از این شاخص، در پیش‌بینی و برآورد معادله‌های وایازی استفاده می‌شود.

$$RME = \sum \frac{RE_i}{n} \quad (9)$$

$$RE_i = \left| \frac{S_o^n - S_c}{S_o} \right| * 100 \quad (10)$$

RME: میانگین درصد خطای نسبی، RE_i : درصد خطای نسبی هر برآورد، S_o : اندازه رسوب معلق مشاهده شده، S_c : اندازه رسوب معلق برآورد شده و n : تعداد دفعات اندازه‌های برآورد شده رسوب معلق است.

جدول ۲- نتایج رسم منحنی‌های سنجۀ رسوب با روش‌های گوناگون (a: ضریب شیب، b: ثابت معادله منحنی سنجۀ رسوب).

Table 2- Results of sediment rating curve development using different methods (a: Slope factor, b: Constant equation of sediment rating curve).

R^2	b	a	Sediment Rating Curve Method
0.72	1.49	5.66	Linear
0.70	1.53	6.07	Qw<1m3/s
0.53	0.46	6.53	Qw>1m3/s
<u>0.84</u>	<u>1.36</u>	<u>6.34</u>	<u>Midpoint of Class Intervals</u>
0.72	1.49	6.77	FAO Correction Factor
0.72	1.49	6.23	Parametric Correction Factor
0.72	1.49	8.56	Nonparametric Correction Factor

شد. نتایج این پژوهش نشان داد که روش میانگین دسته‌ها در مقایسه با دیگر روش‌ها برتری داشت و با استفاده از این روش می‌توان اندازه رسوبات معلق را با دقت زیادی پیش‌بینی کرد. سپس، روش میانگین دسته‌ها به‌عنوان بهترین روش برای رسم منحنی سنجۀ رسوب و به‌عنوان روش مبنا، تعیین شد و اندازه رسوب برآوردی هر روش با مقایسه با روش نامبرده تعیین شد. در این پژوهش، به‌منظور بررسی صحت و دقت هر یک

بر پایه نتایج جدول ۳، در تمام شاخص‌های ارزیابی، بهترین عملکرد منحنی سنجۀ رسوب مربوط به روش میانگین دسته‌ها بود. این روش با داشتن کمترین اندازه میانگین درصد خطای نسبی (RME) و بیشترین اندازه ضریب کارایی (ME) و ضریب تبیین (R^2)، به‌عنوان دقیق‌ترین روش برای پیش‌بینی رسوبات معلق شناخته شد. از این رو، این مدل به‌عنوان مناسب‌ترین روش برای برآورد رسوبات معلق در ایستگاه نارون (افجه) انتخاب

معیارهای گوناگون در جدول ۳ نشان داده شده است. با بررسی نتایج این ارزیابی‌ها بهترین روش برای پیش‌بینی رسوبات معلق در ایستگاه نارون (افجه) تعیین شد و مشخص شد که کدام روش بیشترین دقت را دارد.

از روش‌های استفاده‌شده برای پیش‌بینی رسوبات معلق و انتخاب مناسب‌ترین مدل منحنی سنجه از معیارهای گوناگونی استفاده شد و سپس دقت پیش‌بینی هر روش ارزیابی شد. نتایج ارزیابی هر یک از این روش‌ها با

جدول ۳- نتایج ارزیابی هر کدام از روش‌ها با معیارهای گوناگون.

Table 3- Evaluation of each method based on different criteria.

Coefficient of Determination (R2)	Efficiency Coefficient (ME)	Relative Mean Error (RME)	Sediment Rating Curve Method
0.72	0.09	181.49	Linear
0.67	0.61	177.91	Bilinear
0.84	<u>0.82</u>	<u>211.87</u>	<u>Midpoint of Class Intervals</u>
0.71	0.63	1675.44	FAO Correction Factor
0.73	0.14	204.93	Parametric Correction Factor
0.72	0.71	795.43	Nonparametric Correction Factor

برآورد کمتری از اندازه رسوب معلق داشتند، درحالی‌که دیگر روش‌ها برآورد بیشتری داشتند. انتخاب روش مناسب بستگی به دقت لازم و شرایط خاص منطقه دارد، اما با توجه به نتایج ارزیابی، بهترین دقت پیش‌بینی رسوبات معلق مربوط به روش میانگین دسته‌ها بود


نمودار منحنی سنجه رسوب با روش میانگین دسته‌ها برای ایستگاه نارون (افجه) در شکل ۲ ارائه شده است. این نمودار بیانگر رابطه میان آب‌دهی جریان و آب‌دهی رسوب در این ایستگاه است. از این رو، بر اساس ارزیابی‌های انجام‌شده روش میانگین دسته‌ها به‌عنوان بهترین روش پیش‌بینی رسوبات معلق با دقت زیاد تعیین شد که می‌توان به‌عنوان مرجع اصلی در تحلیل‌ها و مدیریت منابع آب منطقه از آن بهره برد.

نتایج مقایسه روش‌های یک‌خطی، دوخطی، ضریب اصلاحی فائو، ضریب اصلاحی سنجه‌ای و ضریب اصلاحی غیر سنجه‌ای با روش مبنا در جدول ۴ ارائه شده است. بر پایه این نتایج، کمترین اندازه برآورد مربوط به روش یک‌خطی با اندازه رسوب برآوردی ۰/۳۴٪ و روش ضریب اصلاحی سنجه‌ای با اندازه رسوب برآوردی ۰/۳۸٪، در مقایسه با روش میانگین دسته‌ها بود. از سوی دیگر، بیشترین اندازه برآورد مربوط به روش دوخطی با اندازه رسوب برآوردی ۱/۹۳٪، روش ضریب اصلاحی فائو با اندازه رسوب برآوردی ۲/۵۹٪، و روش ضریب اصلاحی غیر سنجه‌ای با اندازه رسوب برآوردی ۱/۲۱٪، در مقایسه با روش مبنا بود. این یافته‌ها بیانگر آن است که روش‌های یک‌خطی و ضریب اصلاحی سنجه‌ای، در مقایسه با روش میانگین دسته‌ها،

جدول ۴- اندازه رسوب برآوردی هر روش در مقایسه با روش مبنا (روش میانگین دسته‌ها).

Table 4- Estimated sediment load of each method relative to the reference method (median class method).

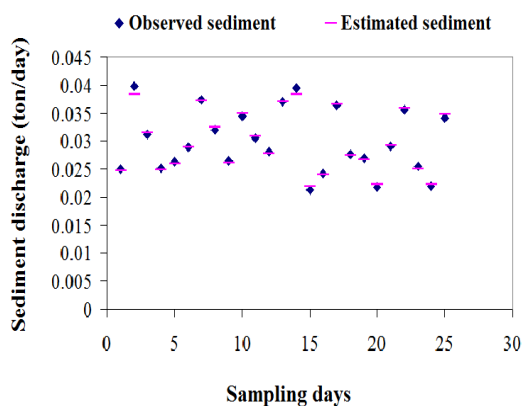
Nonparametric Correction Factor	Parametric Correction Factor	FAO Correction Factor	Bilinear	Linear
1.21	0.38	2.59	1.93	0.34



شکل ۲- نمودار سنجه رسوب با روش میانگین دسته‌ها در ایستگاه نارون (افجه).
 Figure 2- Sediment rating curve using the median class method at Narun (Afjeh) Station.


رسوب مشاهده شده بودند. این یافته یکی از نقاط ضعف عملکرد شبکه‌های عصبی در برآورد آب‌دهی رسوبات معلق بود. از سوی دیگر، اندازه رسوب برآورد شده به وسیله شبکه‌های عصبی مصنوعی با استفاده از روش‌های GFF، RBF و CANFIS به‌طور قابل‌توجهی نزدیک به اندازه‌های رسوب اندازه‌گیری شده در آب‌دهی‌های پایه و بهنجار در ایستگاه مطالعه شده بود.

نتایج اندازه‌های رسوب مشاهده شده و برآورد شده به وسیله مدل‌های گوناگون شبکه‌های عصبی مصنوعی در ایستگاه نارون (افجه) در شکل‌های ۳ تا ۸ نشان داده شده است. بر پایه شکل ۳، اندازه رسوب برآورد شده به وسیله شبکه‌های عصبی مصنوعی با استفاده از روش‌های MLPs و SOFMs در نقاط اوج اصلی به‌طور چشمگیری کمتر از اندازه‌های مشاهده شده بود، در حالی که در آب‌دهی‌های پایه، این اندازه‌ها بیشتر از




شکل ۴- نمودار اندازه‌های رسوب مشاهده‌ای و برآوردشده به وسیله شبکه عصبی مصنوعی (GFF) در ایستگاه نارون (افجه).

Figure 4- Observed and estimated sediment load using artificial neural networks (GFF) at Narun (Afjeh) Station.



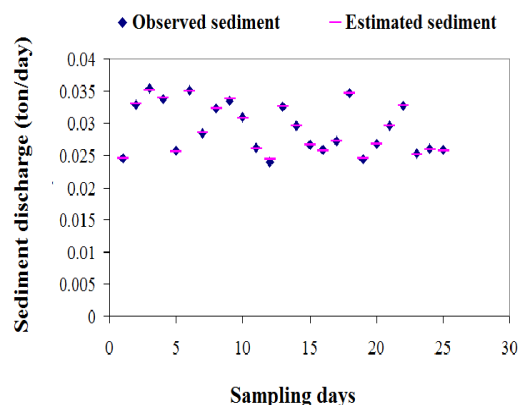
شکل ۳- نمودار اندازه‌های رسوب مشاهده‌ای و برآوردشده به وسیله شبکه عصبی مصنوعی (MLPs) در ایستگاه نارون (افجه).

Figure 3- Observed and estimated sediment load using artificial neural networks (MLPs) at Narun (Afjeh) Station.




شکل ۶- نمودار اندازه‌های رسوب مشاهده‌ای و برآورد شده به وسیله شبکه عصبی مصنوعی (SVM) در ایستگاه نارون (افجه).

Figure 6- Observed and estimated sediment load using artificial neural networks (SVM) at Narun (Afjeh) Station.




شکل ۵- نمودار اندازه‌های رسوب مشاهده‌ای و برآوردشده به وسیله شبکه عصبی مصنوعی (RBF) در ایستگاه نارون (افجه).

Figure 5- Observed and estimated sediment load using artificial neural networks (RBF) at Narun (Afjeh) Station.



شکل ۸- نمودار اندازه‌های رسوب مشاهده‌ای و برآوردشده به‌وسیله شبکه عصبی مصنوعی (CANFIS) در ایستگاه نارون (افجه).

Figure 8- Observed and estimated sediment load using artificial neural networks (CANFIS) at Narun (Afjeh) Station.



شکل ۷- نمودار اندازه‌های رسوب مشاهده‌ای و برآوردشده به‌وسیله شبکه عصبی مصنوعی (SOFMs) در ایستگاه نارون (افجه).

Figure 7- Observed and estimated sediment load using artificial neural networks (SOFMs) at Narun (Afjeh) Station


بود و می‌توان روش نامبرده را به‌عنوان روش ترجیحی برای استفاده در آبخیز مطالعه‌شده توصیه کرد. به‌منظور بهبود نتایج پیش‌بینی‌ها از مدل‌های ترکیبی ۱ و ۲ استفاده شد که نتایج آن‌ها در شکل‌های ۹ و ۱۰ در ایستگاه نارون (افجه) ارائه شده است.

بر پایه نتایج ارزیابی ارائه‌شده در جدول ۵، روش CANFIS با بیشترین ضریب کارایی (۰/۸۱۲۳) در مقایسه با دیگر روش‌ها، به‌عنوان بهترین روش تعیین شد. این یافته بیانگر عملکرد بهتر روش CANFIS در برآورد آبدهی رسوبات معلق در ایستگاه نارون (افجه)

جدول ۵- نتایج ارزیابی هرکدام از روش‌ها با معیارهای گوناگون.

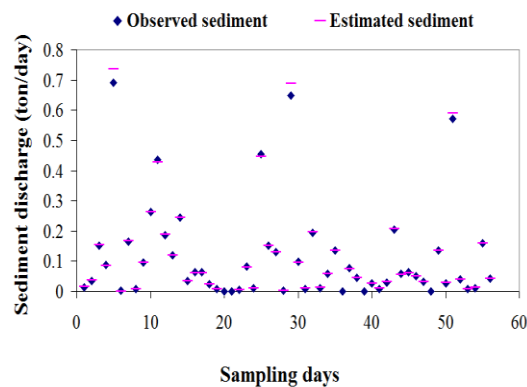
Table 5- Evaluation results of each method using different criteria.

SOFMs	Artificial Neural Network (ANN) Method					Learning Rule of Neural Networks
	CANFIS	SVM	RBF	GFF	MLPs	
4357.89	<u>248.72</u>	93.22	379.89	141.09	31838.68	Relative Mean Error (RME)
-0.1320	<u>0.8123</u>	0.1798	0.1987	0.213	0.649	Efficiency Coefficient (ME)



شکل ۱۰- نمودار اندازه‌های رسوب مشاهده‌ای و برآوردشده به وسیله مدل ترکیبی ۲ در ایستگاه نارون (افجه).

Figure 10- Observed and estimated sediment load using ensemble model 2 at Narun (Afjeh) Station.



شکل ۹- نمودار اندازه‌های رسوب مشاهده‌ای و برآوردشده به وسیله مدل ترکیبی ۱ در ایستگاه نارون (افجه).

Figure 9- Observed and estimated sediment load using ensemble model 1 at Narun (Afjeh) Station.

هر یک از روش‌های ترکیبی با معیارهای گوناگون در جدول ۵، ارائه شده است. به‌طور ویژه، بهترین عملکرد در شبیه‌سازی آبدهی رسوب معلق مربوط به مدل ترکیبی ۱ با میانگین درصد خطای نسبی (RME) ۵۹/۶۳ و ضریب کارایی (ME) ۰/۸۷۶۱ بود.

بر پایه شکل ۹ و ۱۰ مشخص شد که مدل ترکیبی ۱ هم اندازه‌های آبدهی‌های اوج و هم اندازه‌های آبدهی‌های پایه را بسیار دقیق برآورد کرد، درحالی‌که عملکرد مدل ترکیبی ۲ در برآورد آبدهی‌های پایه و به‌ویژه آبدهی‌های اوج بسیار ضعیف بود. نتایج ارزیابی

جدول ۵- نتایج ارزیابی هر کدام از روش‌ها با معیارهای گوناگون.

Table 5- Evaluation results of each method using different criteria.

Hybrid Model 2	Hybrid Model 1	Hybrid Model Type
8684.34	<u>59.63</u>	Relative Mean Error (RME)
0.5759	<u>0.8761</u>	Efficiency Coefficient (ME)

ترکیبی ۱ دقت پیش‌بینی‌ها را به‌طور قابل‌توجهی بهبود داد به‌شکلی که داده‌های برآوردشده با داده‌های مشاهده‌شده تناسب بهتری داشته باشند. این نتایج می‌توانند به پژوهشگران و متخصصان در انتخاب و استفاده از بهترین روش برای برآورد بار رسوب معلق در مناطق مختلف کمک کنند و در نتیجه، دقت و صحت پیش‌بینی‌ها و شبیه‌سازی‌ها را بهبود بخشند.

نتایج کامل ارزیابی هر یک از روش‌ها با استفاده از معیارهای گوناگون برای انتخاب بهترین روش میان روش‌های معرفی‌شده، در جدول ۶، جمع‌بندی شده است. بر اساس نتایج این پژوهش مدل ترکیبی ۱، با میانگین درصد خطای نسبی (RME) ۵۹/۶۳ و ضریب کارایی ۰/۸۷۶۱ (ME) به‌عنوان بهترین روش در شبیه‌سازی آبدهی رسوب معلق شناخته شد. این یافته‌ها بیانگر آن است که می‌توان با استفاده از مدل

جدول ۶- نتایج ارزیابی هر کدام از روش‌ها با معیارهای گوناگون.

Table 6- Evaluation results of each method using different criteria.

Efficiency Coefficient (ME)	Relative Mean Error (RME)	Method
0.813	211.87	Sediment Rating Curve
0.8123	248.72	CANFIS
<u>0.8761</u>	<u>59.63</u>	<u>Hybrid Model 1</u>
0.5759	8684.34	Hybrid Model 2

نتیجه‌گیری و پیشنهادها

نتایج به‌دست‌آمده از رسم روش‌های گوناگون منحنی سنجه رسوب، نشان داد که کمترین اندازه میانگین خطای نسبی (۲۱۱/۸۷) و بیشترین ضریب کارایی (۰/۸۲) مربوط به روش منحنی سنجه رسوب میانگین دسته‌ها بود و در مقایسه با دیگر روش‌های منحنی سنجه رسوب، بهترین نتایج پیش‌بینی را ارائه داد. از این‌رو، این مدل به‌عنوان مناسب‌ترین مدل برای برآورد رسوب معلق با استفاده از روش منحنی سنجه رسوب انتخاب شد. به دو دلیل مهم با این روش بهترین برآورد در پیش‌بینی رسوب معلق انجام شد. اولاً، این روش بر مبنای توزیع داده‌های رسوب معلق استوار است و به توزیع داده‌های باینری یا رسوبات متوسط وابسته نیست. یعنی با این روش می‌توان اندازه رسوب معلق را در تمام دامنه اندازه‌های ممکن پیش‌بینی کرد. دوماً، در روش منحنی میانگین دسته‌ها هم از ترکیب دقت و هم از انعطاف‌پذیری می‌توان بهره برد. در این روش با استفاده از تعداد کمی از دسته‌ها و انتخاب نقاط میانی آن‌ها، می‌توان پیش‌بینی اندازه رسوب معلق را در مقایسه با دیگر روش‌ها با دقت بیشتری انجام داد. با استفاده از روش نامبرده، می‌توان تناسب منحنی را با داده‌های واقعی تطبیق داد و برآوردی دقیق و قابل‌اعتماد ارائه کرد. از این‌رو، روش منحنی میانگین دسته‌ها به‌عنوان یک روش مؤثر و قابل‌اعتماد و ابزاری قدرتمند برای پیش‌بینی اندازه رسوب معلق در اختیار پژوهشگران و متخصصان در زمینه مدیریت و مهار رسوبات معلق است. نتایج این پژوهش با نتایج پژوهش‌های ایرانی و همکاران (۲۰۱۹)، بالول و همکاران (۲۰۲۳) مبنی بر دقت روش میانگین دسته‌ها تطابق دارد.

بر اساس نتایج ارزیابی هر یک از روش‌های شبکه عصبی مصنوعی با معیارهای گوناگون، روش CANFIS با

بیشترین ضریب کارایی (۰/۸۱۲۳) به‌عنوان بهترین روش پیشنهاد شد. در این پژوهش نتایج بررسی استفاده از شبکه عصبی مصنوعی نشان داد که این مدل‌ها نقاط اوج را به‌طور قابل‌توجهی کمتر از اندازه‌های مشاهده‌ای برآورد کردند، که این یافته یکی از ضعف‌های شبکه‌های عصبی در برآورد رسوبات معلق به‌شمار می‌آید. با این‌حال، عملکرد شبکه‌های عصبی مصنوعی در شبیه‌سازی رسوبات معلق مربوط به آب‌دهی‌های پایه و بهنجار خوب بود، اما در شبیه‌سازی رسوبات در زمان‌های سیلابی نامناسب بود.

نتایج استفاده از مدل‌های ترکیبی نشان داد که کمترین میانگین درصد خطای نسبی (۵۹/۶۳) و بیشترین ضریب کارایی (۰/۸۷۶۱)، در میان ۱۴ روش استفاده‌شده در این پژوهش مربوط به مدل ترکیبی ۱ بود که در آن قابلیت‌های دو روش اولیه ترکیب شده بود و از این‌رو به‌عنوان بهترین روش برای برآورد رسوب معلق شناخته شد. در این مدل، یک ساختار عصبی مصنوعی با استفاده از نتایج منحنی سنجه برتر (روش میانگین دسته‌ها) ساخته شد تا با استفاده بهترین روش شبکه عصبی مصنوعی (CANFIS) اندازه بار معلق برآورد شود. این نتایج بیانگر آن است که روش ترکیبی با بیشترین دقت در پیش‌بینی رسوبات معلق در مقایسه با استفاده از دیگر روش‌ها مناسب بود و با استفاده از مدل‌های ترکیبی مانند منحنی سنجه رسوب و شبکه عصبی مصنوعی می‌توان دقت پیش‌بینی رسوبات معلق را به‌طور قابل‌توجهی بهبود بخشید. این مدل‌ها با ترکیب داده‌های مشاهده‌ای و شبیه‌سازی‌شده، امکان ارائه برآوردهای دقیق‌تر و قابل‌اطمینان‌تر از اندازه رسوبات معلق در ایستگاه‌های آب‌سنجی را فراهم می‌کنند. نتایج این پژوهش با یافته‌های ونگ و همکاران

نتایج این پژوهش نشان داد می‌توان با استفاده از مدل‌های ترکیبی دقت پیش‌بینی رسوبات معلق را به‌طور قابل‌توجهی افزایش داد و از آن به‌عنوان ابزاری مؤثر برای مدیریت و پیش‌بینی رسوبات معلق و بهبود مدیریت منابع آب استفاده کرد. همچنین، پیشنهاد می‌شود مهندسان و مدیران منابع آب از نتایج این پژوهش برای توسعه راهکارهای بهینه برای مدیریت رسوبات معلق، بهره ببرند.

تضاد منافع نویسندگان

نویسنده مسئول این مقاله اعلام می‌دارد که هیچ‌گونه تضاد منافی در زمینه نگارش و انتشار مطالب و نتایج این پژوهش ندارد.

دسترسی به داده‌ها

داده‌ها و نتایج استفاده شده در این پژوهش، با مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

تمام بخش‌های مقاله به‌وسیله نویسنده مسئول انجام شده است.

(۲۰۲۲)، ژنگ (۲۰۲۳)، مرادی‌نژاد و همکاران (۲۰۲۳) و بسطامی و فاتح (۲۰۲۴) مبنی بر قابلیت بالای شبکه‌های عصبی مصنوعی در پیش‌بینی رسوبات، لی و همکاران (۲۰۲۱) در زمینه توانایی زیاد ترکیب مدل‌های منحنی سنجه رسوب و شبکه عصبی برای پیش‌بینی رسوبات معلق رود همخوانی دارد. همچنین، نتایج این پژوهش با یافته‌های کومار و همکاران (۲۰۲۱)، لی و همکاران (۲۰۱۹) و مردوخ‌پور و همکاران (۲۰۱۹) مبنی بر استفاده از مدل‌های ترکیبی برای پیش‌بینی رسوبات معلق در مقایسه با استفاده از مدل‌های جداگانه هم‌راستا است. بر اساس یافته‌های این پژوهش، پیشنهاد می‌شود که در پژوهش‌های آینده از مدل‌های ترکیبی برای پیش‌بینی رسوبات معلق استفاده شود. همچنین، توسعه و بهبود روش‌های ترکیبی می‌تواند سبب افزایش دقت و کارایی این مدل‌ها شود. استفاده از داده‌های بیشتر و متنوع‌تر نیز می‌تواند سبب بهبود نتایج شود و دقت پیش‌بینی را افزایش دهد. از این‌رو، پیشنهاد می‌شود برای توسعه و بهینه‌سازی روش‌های ترکیبی، در ایستگاه‌های آب‌سنجی به‌ویژه در آب‌دهی‌های زیاد و شرایط سیلابی، از امکانات پیشرفته نمونه‌گیری و تعداد نمونه‌های بیشتر استفاده شود.

فهرست منابع

- Aytek A, Ozgur K. 2008. A genetic programming approach to suspended sediment modelling. *Journal of Hydrology*. 351(3-4): 288-298. <https://doi.org/10.1016/j.jhydrol.2007.12.005>
- Baloul D, Nekkach A, Ghenim A, Megnounin A. 2023. Estimation of sediment concentration using sediment rating curve approach in Isser Watershed (North-West of Algeria). *Ecological Engineering and Environmental Technology*. 24(6): 282-291. <https://doi.org/10.12912/27197050/169308>
- Bestami T, Fatih Ü, Demirci M, Güzel, H. 2024. Suspended sediment estimation using Machine Learning Methods. (In Persian). https://doi.org/10.24193/awc2024_10
- Bray I, Xie H. 1993. A regression method for estimating Suspended sediment yield for engaged watersheds in Atlantic Canada. *Canadian Journal of Civil Engineering*. 20(2): 82-87. <https://doi.org/10.1139/193-009>
- Chen L, Chau K. 2006. Intelligent manipulation and calibration of parameters for hydrological models. *International Journal of Environment and Pollution*. 28(3-4): 432-447. <https://doi.org/10.1504/IJEP.2006.011221>
- Christian W, Dawson R, Wilby L. 1998. An artificial neural network approach to rainfall-runoff modelling. *Hydrological Sciences Journal*. 43(1): 47-66. <https://doi.org/10.1080/02626669809492102>
- Cigizoglu H. 2005. Application of artificial neural networks to suspended sediment forecasting. *Turkish Journal of Engineering and Environmental Sciences*. 29(1): 9-20. <https://doi.org/10.1016/j.envsoft.2005.09.009>
- George C. 1989. Approximation by superposition of a sigmoidal function. *Mathematics of Control, Signals, and Systems*.

- 2(4): 303-314.
<https://doi.org/10.1007/BF02551274>
- Gurpal S, Harmel D, Haggard B, Schmidt G. 2008. Evaluation of regression methodology with low-frequency water quality sampling to estimate constituent loads for ephemeral watersheds in Texas. *Journal of Environmental Quality*. 37(5): 1847-1854.
<https://doi.org/10.2134/jeq2007.0232>
- Hien T, Le T. 2023. Estimation of daily suspended sediment concentration in the Ca River Basin using a sediment rating curve, multiple regression, and long short-term memory model. *Journal of Water and Climate Change*.
<https://doi.org/10.2166/wcc.2023.229>
- Iadanza C, Napolitano F. 2006. Sediment transport time series in the Tiber River. *Physics and Chemistry of the Earth*. 31(10-17): 1212-1227.
- Irani T, Nazari Nejad H, Najafzadeh A. 2019. Estimation of suspended sediment load using rating curve method (Case study: Qareh Su Watershed). *Proceedings of the Fourteenth National Conference on Watershed Science and Engineering of Iran*. (In Persian).
- Karami F, Bayati Khatibi M, Kheirizadeh M, Mokhtari Asl A. 2020. Evaluation of performance of support vector machine algorithm in landslide susceptibility zoning in Ahar-chai Basin. *Journal of Geography and Environmental Hazards*. 8(4): 1-17. (In Persian).
- Khezayi Pool A, Talebi A. 2013. Investigating the possibility of predicting suspended sediments using a combination of sediment rating curve and artificial neural network (Case study: Ghatourchai River, Yazdkan Bridge). *Environmental Erosion Research*. 3(9): 73-82. (In Persian).
- Krause P, Boyle D, Base F. 2005. Comparison of different efficiency criteria for hydrological model Assessment. *Advances in Geosciences*. 5: 89-97. <https://doi.org/10.5194/adgeo-5-89-2005>.
- Kumar S, Girija C, Nag V. 2021. Prediction and forecasting of daily suspended sediment concentration using M5Tree, ANN and LSSVM models: a case study of river Cauvery, India. *Applied Water Science*. 11(1): 231-237.
<https://doi.org/10.1007/s11356-017-0405-4>.
- Kurt H, Maxwell B, Stinchcombe H. 1989. Multilayer feedforward networks are universal approximates. *Neural Networks*. 2(5): 359-366.
[https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
- Lee B, Yun T, Choi K, Choi J, Jeong C. 2019. Hybrid Sediment Rating Curve Model for Suspended Sediment Prediction. *Water*. 11(2):213-221.
<https://doi.org/10.3390/w11020213>
- Lee H, Yoon Y, Cho S, Choi J. 2021. Suspended sediment prediction using an integrated model of rating curve and artificial neural network for the Han River, Korea. *Water*. 13(4): 472-482.
<https://doi.org/10.3390/w13040472>
- Mardookhpour A, Jamasi H, Alipour O. 2019. Sediment load estimation using rating curve method and comparison with regression and artificial neural network methods (Case study: Babol River, Mazandaran Province). *Journal of Environmental Science and Technology*. 21(11): 79-91. (In Persian).
- Moradi Nejad A, Davod Moghaddam D, Moradi M. 2023. Evaluation of methods for estimating suspended sediment load of Qareh Chai River. *Environment and Water Engineering*. 5(4): 328-338.
- Mustapha S, Adda D, Yebdri D, Baghdadi S, Gajbhiye M. 2024. Artificial neural network for modelling the sediments accumulation in Es-Saada reservoir (North-Western Algeria). *International Journal of Hydrology Science and Technology*.
<https://doi.org/10.1504/ijhst.2024.135122>
- Nash J, Sutcliffe J. 1970. River flow forecasting through conceptual models I: A discussion of principles. *Journal of Hydrology*. 10(1): 282-290.
- Niha K, Basha S, Bhatia K, Abhishek K, Arwa M. 2023. *Multilayer Perceptron*. In *Artificial Intelligence and Machine Learning for Engineers*. Wiley. pp. 67-87.
<https://doi.org/10.1002/97811394167791.ch4>
- Peyravan H, Shariat Jafari M, Lotfollazadeh D. 2017. The impact of landslides on sediment load of Jajroud River. *Watershed Engineering and Management*. 9(2): 179-189. (In Persian).



Predicting Suspended Sediment using a Hybrid Model of Sediment Rating Curve and Artificial Neural Network in the Naroun Afjeh Station

Golaleh Ghaffari

Assistant Professor, Soil Conservation and Watershed Management Research Department, Kermanshah Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Kermanshah, Iran

Extended Abstract

Introduction and Goal

The concentration of suspended sediments is one of the most important water quality indicators in surface water resources and a significant hydrological phenomenon. However, traditional methods, such as sediment rating curves (SRCs), lack accuracy due to not considering all effective parameters. In this context, hybrid models that include SRCs and artificial neural networks (ANNs) have emerged as a promising approach for enhancing SSC prediction accuracy. These models, with their ability to use complex nonlinear patterns, outperform traditional methods. This study aims to develop and implement an SRC-ANN hybrid model for SSC prediction. The proposed model is predicted to significantly improve prediction accuracy by combining the strengths of both methods, aiding in optimal water resource management and the proper functioning of hydraulic structures.

Materials and Methods

This research introduces a novel hybrid model that integrates sediment rating curves (SRCs) and artificial neural networks (ANNs) was used for a more accuracy prediction of suspended sediment in the Naroun (Afejeh) hydrometric station. For this purpose, data from 222 sample of flow discharge and suspended sediment over a 50-years period (1971 to 2021) were used. Additionally, 14 different were employed, including 6 sediment rating curve methods, 6 artificial neural network methods and 2 hybrid methods, to simulate suspended sediment. The performance of each method was evaluated using statistical criteria such as coefficient of determination (R^2), efficiency coefficient (ME), and mean relative error percentage (RME).

Article Type: Research Article

***Corresponding Author E-mail:** g.ghaffari@areeo.ac.ir

Citation: Ghaffari, G. 2025. Predicting Suspended Sediment Using a Hybrid Model of Sediment Rating Curve and Artificial Neural Network in the Naroun Afjeh Station. *Watershed Management Research*. 38(1): 128-146.

DOI: 10.22092/wmrj.2024.366243.1589

Received: 08 July 2024, **Received in revised form:** 01 August 2024, **Accepted:** 19 September 2024

Published online: 21 March 2025

Watershed Management Research, Vol.38, No.1, Ser. No:146, Spring 2025, pp. 128-146.

Publisher: Fars Agricultural and Natural Resources Research and Education Center ©Author(s)



Results and discussion

The results showed that among the sediment rating curve methods, the most accurate simulation of the observed sediment discharge conditions compared to other methods was related to the midpoint method, with a coefficient of determination (R^2) of 0.840, a modeling efficiency (ME) of 0.820, and a mean relative error (RME) of 0.211%. Also, among the artificial neural network methods, the most accurate simulation was related to the CANFIS method, with a modeling efficiency (ME) of 0.8123 and a mean relative error (RME) of 0.248. Finally, to improve the prediction results, hybrid models 1 and 2 were used. The results showed that the best estimate of suspended sediment was related to hybrid method 1, with a modeling efficiency (ME) of 0.8761 and a mean relative error (RME) of 0.06359%.

In the mentioned method, both the estimation of peak flow discharge and the estimation of base flow discharge were very accurate, and it was introduced as the most accurate method for predicting suspended sediments. These results highlight the potential of using hybrid model 1 to significantly improve prediction accuracy and to better fit the observed data.

Conclusion and Suggestions

Among the sediment rating curve methods, the mean category sediment rating curve method was identified as the best approach for predicting suspended sediment due to its consideration of data distribution and flexibility. The performance of artificial neural networks (ANNs) in simulating sediment for base and normal flows was good, but were weaker in predicting sediment during flood events. The most accurate method for suspended sediment prediction is the Hybrid model 1, which use a MSM and ANN methods. Improper selection of a sediment prediction method can lead to inaccurate results. Also, it is essential to examine the impact of other variables beyond flow discharge on sediment. The results of this research showed that it is possible to significantly increase the accuracy of suspended sediment prediction using hybrid models, and that these models can be utilized as an effective tool for managing and predicting suspended sediments, as well as improving water resource management. It is recommended to use advanced sampling facilities and a larger number of samples at hydrometric stations, especially in high-flow and flood conditions, for the development and optimization of hybrid methods. Additionally, it is suggested that engineers and water resource managers utilize the findings of this research to develop optimal strategies for suspended sediment management.

Keywords: Discharge, Hydrometric station, Modeling, Sediment concentration, Simulation

Article Type: Research Article

Conflicts of interest:

The author declare that she has no conflicts of interest concerning the authorship or publication of this research.

Data Availability Statement:

The data and results used in this study will be made available upon reasonable request to the corresponding author.

Authors' Contribution

All parts of the article were written by the corresponding author.